

**Wybrane problemy  
optymalizacji wielokryterialnej  
we wstępnym projektowaniu  
konstrukcji kadłuba statków morskich**



Zachodniopomorski Uniwersytet Technologiczny  
w Szczecinie

Zbigniew Sekulski

**Wybrane problemy  
optymalizacji wielokryterialnej  
we wstępnym projektowaniu  
konstrukcji kadłuba statków morskich**

Szczecin 2012



Recenzenci

CZESŁAW SZYMCZAK  
WOJCIECH TARNOWSKI

Opracowanie redakcyjne

ALICJA BERNER

WYDANO ZA ZGODĄ

REKTORA ZACHODNIOPOMORSKIEGO UNIwersYTETU TECHNOLOGICZNEGO  
W SZCZECINIE

ISBN 978-83-7663-111-0

WYDAWNICTWO UCZELNIANE ZACHODNIOPOMORSKIEGO UNIwersYTETU TECHNOLOGICZNEGO W SZCZECINIE

70–311 Szczecin, al. Piastów 50, tel. 91 449 47 60, e-mail: [wydawnictwo@zut.edu.pl](mailto:wydawnictwo@zut.edu.pl)

Druk PPH „Zapół” Dmochowski, Sobczyk Sp.j., 71–062 Szczecin, al. Piastów 42, tel. 91 434 10 21

e-mail: [zarzad@zapol.com](mailto:zarzad@zapol.com)

## Spis treści

|                                                                                                                                |     |
|--------------------------------------------------------------------------------------------------------------------------------|-----|
| Wykaz ważniejszych oznaczeń.....                                                                                               | 7   |
| Objaśnienia skrótowców .....                                                                                                   | 11  |
| Objaśnienia wybranych terminów .....                                                                                           | 13  |
| 1. Wprowadzenie .....                                                                                                          | 15  |
| 1.1. Konstrukcja kadłuba statków morskich: elementy, projektowanie i optymalizacja .....                                       | 15  |
| 1.2. Ewolucyjna optymalizacja wielokryterialna .....                                                                           | 26  |
| 1.3. Problem badawczy, cel i zakres pracy .....                                                                                | 29  |
| 2. Problem optymalizacji konstrukcji kadłuba statków morskich .....                                                            | 33  |
| 2.1. Specyfika problemów optymalizacji .....                                                                                   | 33  |
| 2.2. Algorytmy rozwiązywania zadania optymalizacji .....                                                                       | 38  |
| 2.3. Wybór metody rozwiązywania zadania wielokryterialnej optymalizacji .....                                                  | 42  |
| 2.4. Narzędzia obliczeniowe do optymalizacji .....                                                                             | 44  |
| 2.5. Podsumowanie i wnioski .....                                                                                              | 46  |
| 3. Podstawowe koncepcje optymalizacji wielokryterialnej .....                                                                  | 49  |
| 3.1. Sformułowanie zadania optymalizacji wielokryterialnej .....                                                               | 49  |
| 3.2. Rozwiązywanie zadania optymalizacji wielokryterialnej – zbiór przybliżający front ocen rozwiązań optymalnych Pareto ..... | 53  |
| 3.3. Relacje preferencji zbiorów przybliżających .....                                                                         | 57  |
| 3.4. Podsumowanie i wnioski .....                                                                                              | 61  |
| 4. Poszukiwanie zbiorów przybliżających .....                                                                                  | 63  |
| 4.1. Oczekiwany rezultat optymalizacji wielokryterialnej .....                                                                 | 63  |
| 4.2. Klasyczne algorytmy optymalizacji wielokryterialnej .....                                                                 | 66  |
| 4.3. Ewolucyjne algorytmy optymalizacji wielokryterialnej .....                                                                | 68  |
| 4.4. Struktura wewnętrzna zbioru dopuszczalnego – szeregowanie i licznik dominacji .....                                       | 70  |
| 4.5. Podsumowanie i wnioski .....                                                                                              | 74  |
| 5. Ocena jakości zbiorów przybliżających .....                                                                                 | 75  |
| 5.1. Wprowadzenie .....                                                                                                        | 75  |
| 5.2. Wskaźniki jakości zbiorów przybliżających .....                                                                           | 77  |
| 5.3. Wektorowe wskaźniki jakości zbiorów przybliżających .....                                                                 | 84  |
| 5.4. Strategie oceny jakości zbiorów przybliżających .....                                                                     | 85  |
| 5.5. Ocena skuteczności ewolucyjnych algorytmów optymalizacji wielokryterialnej .....                                          | 87  |
| 5.6. Podsumowanie i wnioski .....                                                                                              | 90  |
| 6. Narzędzie obliczeniowe do ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku .....                      | 93  |
| 6.1. Podstawowe techniki obliczeniowe .....                                                                                    | 93  |
| 6.1.1. Funkcje użyteczności .....                                                                                              | 93  |
| 6.1.2. Funkcje kary za naruszenie ograniczeń .....                                                                             | 95  |
| 6.1.3. Wskaźnik dopuszczalności wariantu konstrukcji .....                                                                     | 98  |
| 6.1.4. Operatory genetyczne .....                                                                                              | 99  |
| 6.1.5. Archiwizowanie rozwiązań niezdominowanych .....                                                                         | 100 |
| 6.1.6. Odległość od rozwiązania asymptotycznego .....                                                                          | 101 |
| 6.1.7. Szeregowanie i licznik dominacji .....                                                                                  | 103 |
| 6.1.8. Kombinowana funkcja przystosowania .....                                                                                | 105 |

|                                                                                                                |     |
|----------------------------------------------------------------------------------------------------------------|-----|
| 6.1.9. Szerokość i głębokość zbioru przybliżającego.....                                                       | 107 |
| 6.1.10. Ocena jakości zbiorów przybliżających.....                                                             | 108 |
| 6.2. Program komputerowy .....                                                                                 | 111 |
| 6.3. Obliczenia testowe (próbne) .....                                                                         | 114 |
| 6.4. Podsumowanie i wnioski .....                                                                              | 115 |
| 7. Sformułowanie zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku. Modele obliczeniowe ..... | 117 |
| 7.1. Ogólna charakterystyka statku.....                                                                        | 117 |
| 7.1.1. Założenia i dane dotyczące optymalizacji .....                                                          | 117 |
| 7.1.2. Szlak żeglugowy .....                                                                                   | 118 |
| 7.1.3. Kryteria optymalizacji .....                                                                            | 119 |
| 7.2. Modele konstrukcji kadłuba statku .....                                                                   | 123 |
| 7.2.1. Geometryczny model konstrukcji .....                                                                    | 123 |
| 7.2.2. Materiałowe cechy konstrukcji .....                                                                     | 125 |
| 7.2.3. Obciążenia projektowe konstrukcji .....                                                                 | 126 |
| 7.3. Model optymalizacyjny konstrukcji kadłuba statku.....                                                     | 128 |
| 7.3.1. Zmienne konstrukcyjne .....                                                                             | 128 |
| 7.3.2. Parametry modelu optymalizacyjnego .....                                                                | 130 |
| 7.3.3. Funkcja celu .....                                                                                      | 130 |
| 7.3.4. Ograniczenia .....                                                                                      | 131 |
| 7.4. Genetyczny model optymalizacyjny konstrukcji kadłuba statku .....                                         | 134 |
| 7.4.1. Uwagi ogólne .....                                                                                      | 134 |
| 7.4.2. Struktura chromosomu .....                                                                              | 134 |
| 7.4.3. Funkcja przystosowania.....                                                                             | 136 |
| 7.4.4. Archiwizacja rozwiązań niezdominowanych.....                                                            | 137 |
| 7.4.5. Operatory genetyczne .....                                                                              | 137 |
| 7.4.6. Parametry sterujące .....                                                                               | 139 |
| 7.5. Podsumowanie i wnioski .....                                                                              | 139 |
| 8. Symulacje komputerowe – poszukiwanie zbiorów przybliżających.....                                           | 141 |
| 8.1. Plan symulacji komputerowych.....                                                                         | 141 |
| 8.2. Wyniki symulacji komputerowych .....                                                                      | 144 |
| 8.2.1. Seria 1. ....                                                                                           | 144 |
| 8.2.2. Seria 2. ....                                                                                           | 155 |
| 8.2.3. Seria 3. ....                                                                                           | 157 |
| 8.2.4. Seria 4. ....                                                                                           | 158 |
| 8.3. Analiza wyników .....                                                                                     | 160 |
| 8.4. Podsumowanie i wnioski .....                                                                              | 166 |
| 9. Ocena jakości zbiorów przybliżających wygenerowanych w trakcie symulacji komputerowych .....                | 169 |
| 9.1. Plan oceny jakości zbiorów przybliżających.....                                                           | 169 |
| 9.2. Wizualna ocena zbiorów przybliżających .....                                                              | 169 |
| 9.3. Ocena zbiorów przybliżających za pomocą relacji dominacji.....                                            | 172 |
| 9.4. Ocena zbiorów przybliżających za pomocą wskaźników jakości .....                                          | 174 |
| 9.4.1. Seria 1. ....                                                                                           | 174 |
| 9.4.2. Seria 2. ....                                                                                           | 179 |
| 9.4.3. Seria 3. ....                                                                                           | 180 |
| 9.4.4. Seria 4. ....                                                                                           | 181 |
| 9.5. Podsumowanie i wnioski.....                                                                               | 183 |
| 10. Zakończenie.....                                                                                           | 185 |
| 11. Plany badawcze.....                                                                                        | 195 |



|                      |     |
|----------------------|-----|
| Załączniki .....     | 197 |
| Załącznik A.....     | 199 |
| Załącznik B.....     | 201 |
| Załącznik C.....     | 203 |
| Załącznik D.....     | 205 |
| Załącznik E.....     | 209 |
| Załącznik F.....     | 215 |
| Załącznik G.....     | 217 |
| Załącznik H.....     | 223 |
| Załącznik I.....     | 227 |
| Załącznik J.....     | 231 |
| Załącznik K.....     | 233 |
| Załącznik L.....     | 235 |
| Literatura .....     | 237 |
| Summary.....         | 259 |
| Zusammenfassung..... | 261 |



## Wykaz ważniejszych oznaczeń

|                                       |                                                                                                                                             |
|---------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------|
| $d_{AS}$                              | – głębokość zbioru przybliżającego                                                                                                          |
| $d_{fi}$                              | – odległość oceny wariantu dopuszczalnego od oceny asymptotycznej                                                                           |
| $f(x), f(\mathbf{x})$                 | – funkcja celu, kryterium optymalizacji, wskaźnik jakości, ocena                                                                            |
| $f_s$                                 | – składowe kryterium optymalizacji, składowa wektora ocen, częściowe kryterium optymalizacji                                                |
| $f_{s,max}$                           | – największa oczekiwana w obliczeniach wartość kryterium optymalizacji $f_s$                                                                |
| $f^* = f(x^*), f^* = f(\mathbf{x}^*)$ | – ocena optymalna, optymalna wartość funkcji celu, kryterium optymalizacji, wskaźnika jakości                                               |
| $f_s^0$                               | – składowa ocena rozwiązania asymptotycznego $\mathbf{f}^0$ (w przestrzeni ocen)                                                            |
| $f_s^*$                               | – składowa ocena rozwiązania idealnego $\mathbf{f}^*$ (w przestrzeni ocen)                                                                  |
| $f_{s,m}^{\approx}(\mathbf{x})$       | – składowa ocena rozwiązania najbliższego ocenie rozwiązania asymptotycznego w $m$ -tym pokoleniu $\mathbf{f}_m^{\approx}(\mathbf{x})$      |
| $g_f(\mathbf{x}) \geq 0$              | – ograniczenie nierównościowe, składowa wektora ograniczeń nierównościowych, $j = 1, 2, \dots, J$                                           |
| $h_k(\mathbf{x}) = 0$                 | – ograniczenie równościowe, składowa wektora ograniczeń równościowych, $k = 1, 2, \dots, K$                                                 |
| $l_{ch}$                              | – długość chromosomu                                                                                                                        |
| $l_i$                                 | – długość odcinka chromosomu kodującego wartość zmiennej konstrukcyjnej $x_i$                                                               |
| $n$                                   | – liczba zmiennych konstrukcyjnych $x_i, i = 1, 2, \dots, n$                                                                                |
| $n_c$                                 | – liczba punktów krzyżowania                                                                                                                |
| $n_p$                                 | – liczba pretendentów                                                                                                                       |
| $n\_x\_site\_min$                     | – najmniejsza liczba punktów krzyżowania                                                                                                    |
| $n\_x\_site\_max$                     | – największa liczba punktów krzyżowania                                                                                                     |
| $p_c$                                 | – prawdopodobieństwo krzyżowania                                                                                                            |
| $p_m$                                 | – prawdopodobieństwo mutacji                                                                                                                |
| $p_u$                                 | – prawdopodobieństwo aktualizowania                                                                                                         |
| $r$                                   | – odległość zbioru przybliżającego od oceny asymptotycznej                                                                                  |
| $r_p$                                 | – wykładnik potęgowy dla $p$ -tej składowej funkcji kary $p = 1, 2, \dots, P$                                                               |
| $r_s$                                 | – współczynnik potęgowy funkcji użyteczności $u_s$                                                                                          |
| $u_s = u_s(f_s(\mathbf{x}))$          | – funkcje użyteczności kryteriów optymalizacji $f_s$                                                                                        |
| $w_{count}$                           | – współczynnik wagowy licznika dominacji wariantu dopuszczalnego $C_{fi}$                                                                   |
| $w_{distance}$                        | – współczynnik wagowy odległości oceny rozwiązania dopuszczalnego od oceny rozwiązania asymptotycznego $d_{fi}$                             |
| $w_p$                                 | – współczynnik wagowy naruszenia $p$ -tego ograniczenia, $p = 1, 2, \dots, P$                                                               |
| $w_{rank}$                            | – współczynnik wagowy wskaźnika szeregowania (rangi) wariantu dopuszczalnego $R_{fi}$                                                       |
| $w_s$                                 | – współczynniki wagowe kryteriów optymalizacji (kryteriów oceny) $f_s = f_s(\mathbf{x})$                                                    |
| $x$                                   | – zmienna konstrukcyjna (skalar)                                                                                                            |
| $x_i$                                 | – zmienna decyzyjna, zmienna projektowa, zmienna konstrukcyjna, składowa wektora zmiennych konstrukcyjnych $\mathbf{x}, i = 1, 2, \dots, n$ |
| $x_{i,max}$                           | – największa wartość zmiennej konstrukcyjnej $x_i$                                                                                          |
| $x_{i,min}$                           | – najmniejsza wartość zmiennej konstrukcyjnej $x_i$                                                                                         |
| $x^*$                                 | – rozwiązanie jednowymiarowego zadania optymalizacji, rozwiązanie optymalne                                                                 |

|                                                                                                                                                  |                                                                                                                                                                                                                                                                        |
|--------------------------------------------------------------------------------------------------------------------------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| $B$                                                                                                                                              | – szerokość statku, $m$                                                                                                                                                                                                                                                |
| $C_b$                                                                                                                                            | – współczynnik pełnotliwości podwodzia                                                                                                                                                                                                                                 |
| $C_{fi}$                                                                                                                                         | – licznik dominacji ocen $i$ -tego rozwiązania dopuszczalnego                                                                                                                                                                                                          |
| $F = F(\mathbf{x})$                                                                                                                              | – zastępcze kryterium optymalizacji, funkcja celu                                                                                                                                                                                                                      |
| $J$                                                                                                                                              | – liczba ograniczeń nierównościowych                                                                                                                                                                                                                                   |
| $K$                                                                                                                                              | – liczba ograniczeń równościowych                                                                                                                                                                                                                                      |
| $L$                                                                                                                                              | – długość statku, $m$                                                                                                                                                                                                                                                  |
| $N_{fi}$                                                                                                                                         | – liczba rozwiązań dopuszczalnych w bieżącej populacji                                                                                                                                                                                                                 |
| $P$                                                                                                                                              | – liczba ograniczeń; liczba składowych funkcji kary za naruszenie ograniczenia                                                                                                                                                                                         |
| $P(\mathbf{x})_p$                                                                                                                                | – składowa funkcji kary naruszenia $p$ -tego ograniczenia, $p = 1, 2, \dots, P$                                                                                                                                                                                        |
| $Q$                                                                                                                                              | – liczba skalarnych wskaźników jakości $QI_Q$                                                                                                                                                                                                                          |
| $QI(\Psi_f)$                                                                                                                                     | – skalarny wskaźnik jakości zbioru przybliżającego $\Psi_f$                                                                                                                                                                                                            |
| $QI_q(\Psi_f)$                                                                                                                                   | – składowa wektorowego wskaźnika jakości zbioru przybliżającego $\Psi_f$ , $q = 1, 2, \dots, Q$                                                                                                                                                                        |
| $QI_{AD}$                                                                                                                                        | – skalarny wskaźnik jakości zbioru przybliżającego, mierzona w unormowanej przestrzeni ocen odległość zbioru przybliżającego uzyskanego w danej symulacji do oceny asymptotycznej                                                                                      |
| $QI_B$                                                                                                                                           | – skalarny wskaźnik jakości zbioru przybliżającego, mierzona w unormowanej przestrzeni ocen i wyrażona w stopniach szerokość (rozpiętość) zbioru przybliżającego, uzyskanego w danej symulacji                                                                         |
| $QI_D$                                                                                                                                           | – skalarny wskaźnik jakości zbioru przybliżającego, mierzona w unormowanej przestrzeni ocen głębokość zbioru przybliżającego, uzyskanego w danej symulacji                                                                                                             |
| $QI_H$                                                                                                                                           | – skalarny wskaźnik jakości zbioru przybliżającego, część fizycznej przestrzeni ocen zdominowanej przez zbiór przybliżający uzyskany w danej symulacji (ang. <i>hypervolume</i> )                                                                                      |
| $QI_{NF}$                                                                                                                                        | – skalarny wskaźnik jakości zbioru przybliżającego, liczba rozwiązań z danej symulacji zaliczona do zbioru rozwiązań niezdominowanych wybranych ze wszystkich symulacji w serii lub z innego zbioru symulacji                                                          |
| $R_{fi}$                                                                                                                                         | – klasa, szeregowanie, ranga $i$ -tego rozwiązania dopuszczalnego                                                                                                                                                                                                      |
| $T$                                                                                                                                              | – zanurzenie statku, $m$                                                                                                                                                                                                                                               |
| $V_f$                                                                                                                                            | – przestrzeń kryteriów, przestrzeń ocen, przestrzeń jakości, przestrzeń celów                                                                                                                                                                                          |
| $V_x$                                                                                                                                            | – przestrzeń zmiennych decyzyjnych, przestrzeń rozwiązań, przestrzeń poszukiwań, przestrzeń konstrukcyjna, przestrzeń wariantów                                                                                                                                        |
| $\mathbf{f} = \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_s(\mathbf{x}) \ \dots \ f_S(\mathbf{x})]^T$                | – możliwa ocena zadania optymalizacji, wektor kryteriów optymalizacji, wektor kryteriów oceny                                                                                                                                                                          |
| $\mathbf{f}_c$                                                                                                                                   | – dopuszczalna ocena zadania optymalizacji                                                                                                                                                                                                                             |
| $\mathbf{f}_{rel}$                                                                                                                               | – dopuszczalna ocena zadania optymalizacji wielokryterialnej spełniająca dodatkowo relację porządkującą <i>rel</i> (jeśli <i>rel</i> oznacza relację dominacji Pareto, to $\mathbf{f}_{rel}$ oznacza ocenę optymalną Pareto – niezdominowaną, kompromisową, efektywną) |
| $\mathbf{f}^\infty$                                                                                                                              | – ocena najbliższa ocenie asymptotycznej (rozwiązanie najbliższe rozwiązaniu asymptotycznemu, wariant najbliższy rozwiązaniu asymptotycznemu)                                                                                                                          |
| $\mathbf{f}^0 = [f_1^0 \ f_2^0 \ \dots \ f_s^0 \ \dots \ f_S^0]^T$                                                                               | – ocena asymptotyczna (rozwiązanie asymptotyczne, wariant asymptotyczny)                                                                                                                                                                                               |
| $\mathbf{f}^* = [f_1^* \ f_2^* \ \dots \ f_s^* \ \dots \ f_S^*]^T$                                                                               | – ocena idealna (rozwiązanie idealne, wariant idealny)                                                                                                                                                                                                                 |
| $\mathbf{f}_m^\approx(\mathbf{x}) = [f_{1;m}^\approx(\mathbf{x}) \ \dots \ f_{s;m}^\approx(\mathbf{x}) \ \dots \ f_{S;m}^\approx(\mathbf{x})]^T$ | – rozwiązanie najbliższe rozwiązaniu asymptotycznemu w $m$ -tym pokoleniu                                                                                                                                                                                              |
| $\mathbf{f}_{sym\ i}^\approx$                                                                                                                    | – uzyskany w symulacji symi wariant niezdominowany najbliższy rozwiązaniu asymptotycznemu                                                                                                                                                                              |
| $\mathbf{f}_{\succ}$                                                                                                                             | – wariant niezdominowany, ocena niezdominowana, rozwiązanie niezdominowane                                                                                                                                                                                             |

|                                                                                                                                   |                                                                                                                                                                                                                                                                           |
|-----------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| $\mathbf{f}_{\succ}$                                                                                                              | – wariant zdominowany, ocena zdominowana, rozwiązanie zdominowane                                                                                                                                                                                                         |
| $\mathbf{g} = \mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}) \ g_2(\mathbf{x}) \ \dots \ g_j(\mathbf{x}) \ \dots \ g_J(\mathbf{x})]^T$ | – wektor ograniczeń nierównościowych, $\mathbf{g}(\mathbf{x})$ : $g_j(\mathbf{x}) \geq 0$                                                                                                                                                                                 |
| $\mathbf{h} = \mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \ h_2(\mathbf{x}) \ \dots \ h_k(\mathbf{x}) \ \dots \ h_K(\mathbf{x})]^T$ | – wektor ograniczeń równościowych, $\mathbf{h}(\mathbf{x})$ : $h_k(\mathbf{x}) = 0$                                                                                                                                                                                       |
| $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_i \ \dots \ x_n]^T$                                                                          | – wektor zmiennych konstrukcyjnych, możliwe rozwiązanie zadania optymalizacji                                                                                                                                                                                             |
| $\mathbf{x}_c$                                                                                                                    | – rozwiązanie dopuszczalne zadania optymalizacji                                                                                                                                                                                                                          |
| $\mathbf{x}_{min}, \mathbf{x}_{max}$                                                                                              | – wektory odpowiednio dolnej i górnej granicy zmiennych decyzyjnych, zmiennych projektowych, zmiennych konstrukcyjnych $x_i$                                                                                                                                              |
| $\mathbf{x}_{rel}$                                                                                                                | – rozwiązanie dopuszczalne zadania optymalizacji wielokryterialnej, spełniające dodatkowo relację porządkującą $rel$ (jeśli $rel$ oznacza relację dominacji Pareto, to $\mathbf{x}_{rel}$ oznacza rozwiązanie optymalne Pareto – niezdominowane, kompromisowe, efektywne) |
| $\mathbf{x}^*$                                                                                                                    | – rozwiązanie zadania optymalizacji, rozwiązanie optymalne                                                                                                                                                                                                                |
| $\mathbf{x}_{\succ}$                                                                                                              | – rozwiązanie (decyzja, wariant) optymalne Pareto – niezdominowane, kompromisowe, efektywne                                                                                                                                                                               |
| $\mathbf{QI}(\Psi_f)$                                                                                                             | – wektorowy wskaźnik jakości zbioru przybliżającego $\Psi_f$                                                                                                                                                                                                              |
| $\beta$                                                                                                                           | – szerokość zbioru przybliżającego                                                                                                                                                                                                                                        |
| $\mu(x_d)$                                                                                                                        | – wartość funkcji przynależności wariantu $x_d$ do zbioru wariantów dopuszczalnych                                                                                                                                                                                        |
| $\mu_{min}$                                                                                                                       | – najmniejsza wartość funkcji przynależności wariantów poddawanych ocenie                                                                                                                                                                                                 |
| $\Phi$                                                                                                                            | – zbiór dopuszczalny, zbiór rozwiązań dopuszczalnych                                                                                                                                                                                                                      |
| $\Phi_f$                                                                                                                          | – zbiór celów osiągalnych, zbiór ocen osiągalnych                                                                                                                                                                                                                         |
| $\Phi_{\succ}$                                                                                                                    | – zbiór ocen niezdominowanych, zbiór wariantów niezdominowanych                                                                                                                                                                                                           |
| $\Phi_{\succ}$                                                                                                                    | – zbiór ocen zdominowanych, zbiór wariantów, zdominowanych, zbiór rozwiązań zdominowanych                                                                                                                                                                                 |
| $\Psi$                                                                                                                            | – zbiór rozwiązań niezdominowanych w przestrzeni rozwiązań $V_x$                                                                                                                                                                                                          |
| $\Psi_1, \Psi_2, \Psi_3$                                                                                                          | – zbiory ocen rozwiązań niezdominowanych; zbiory przybliżające front ocen rozwiązań optymalnych Pareto $\Psi_P$                                                                                                                                                           |
| $\Psi_A, \Psi_B$                                                                                                                  | – zbiory ocen rozwiązań niezdominowanych; zbiory przybliżające front ocen rozwiązań optymalnych Pareto $\Psi_P$                                                                                                                                                           |
| $\Psi_f$                                                                                                                          | – zbiór przybliżający front ocen rozwiązań optymalnych Pareto $\Psi_P$                                                                                                                                                                                                    |
| $\Psi_P$                                                                                                                          | – front ocen rozwiązań optymalnych Pareto                                                                                                                                                                                                                                 |
| $\Psi_{symi}$                                                                                                                     | – zbiór przybliżający wyprodukowany w symulacji symi                                                                                                                                                                                                                      |
| $\Lambda$                                                                                                                         | – zbiór wszystkich przybliżeń zbioru rozwiązań optymalnych Pareto w przestrzeni rozwiązań $V_x$                                                                                                                                                                           |
| $\Lambda_f$                                                                                                                       | – zbiór wszystkich przybliżeń $\Psi_f$ frontu ocen optymalnych Pareto $\Psi_P$ w przestrzeni ocen $V_f$                                                                                                                                                                   |
| $\Psi_{rel}$                                                                                                                      | – zbiór ocen dopuszczalnych spełniających dodatkowo relację porządkującą $rel$ (jeśli $rel$ oznacza relację dominacji Pareto to $\Psi_{rel}$ oznacza front rozwiązań optymalnych Pareto)                                                                                  |
| $rel$                                                                                                                             | – relacja porządkująca zbiór rozwiązań dopuszczalnych ze względu na cel zadania optymalizacji                                                                                                                                                                             |
| $T$                                                                                                                               | – operator transpozycji (wektora lub macierzy)                                                                                                                                                                                                                            |
| $\Re^n$                                                                                                                           | – przestrzeń liczb rzeczywistych, $n$ -wymiarowa                                                                                                                                                                                                                          |
| $F = F(\mathbf{x}_j)$                                                                                                             | – funkcja przystosowania $j$ -tego osobnika, wariantu                                                                                                                                                                                                                     |





## Objaśnienia skrótowców<sup>1</sup>

|       |                                                                                                                                                                                                                               |
|-------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| AFM   | (ang. Attainment Function Method) – metoda funkcji osiągnięcia                                                                                                                                                                |
| AS    | (ang. Approximation Set) – zbiór przybliżający; zbiór ocen rozwiązań przybliżających front Pareto; zbiór ocen rozwiązań wielokryterialnego zadania optymalizacji, traktowany jako przybliżenie zbioru ocen optymalnych Pareto |
| BV    | (ang. Bureau Veritas) – towarzystwo klasyfikacyjne                                                                                                                                                                            |
| CFD   | (ang. Computer Fluid Dynamics) – numeryczna mechanika płynów                                                                                                                                                                  |
| CL    | (ang. Convex Linearization) – metoda linearyzacji wypukłej                                                                                                                                                                    |
| DNV   | (ang. Det Norske Veritas) – towarzystwo klasyfikacyjne                                                                                                                                                                        |
| DRM   | (ang. Dominance-Ranking Method) – metoda relacji dominacji                                                                                                                                                                    |
| DSS   | (ang. Integrated Decision Support System)                                                                                                                                                                                     |
| EAFM  | (ang. Empirical Attainment Function Method) – empiryczna funkcja osiągnięcia                                                                                                                                                  |
| EMO   | (ang. Evolutionary Multi-Objective Optimization) – ewolucyjna optymalizacja wielokryterialna                                                                                                                                  |
| ES    | (ang. Evolutionary Strategies) – strategie ewolucyjne                                                                                                                                                                         |
| FFE   | (ang. Fractional Factorial Experiments)                                                                                                                                                                                       |
| FFGA  | (ang. Fonseca and Fleming's Genetic Algorithm)                                                                                                                                                                                |
| GA    | (ang. Genetic Algorithms) – algorytmy genetyczne                                                                                                                                                                              |
| GL    | (ang. Germanischer Lloyd) – towarzystwo klasyfikacyjne                                                                                                                                                                        |
| HLGA  | (ang. Hajela and Lin's Weighting-based Genetic Algorithm)                                                                                                                                                                     |
| IACS  | (ang. International Association of Classification Societies)                                                                                                                                                                  |
| IS    | (ang. Ideal Solution) – rozwiązanie idealne, wariant idealny                                                                                                                                                                  |
| ISSC  | (ang. International Ship and Offshore Structures Congress)                                                                                                                                                                    |
| KKSM  | – konstrukcja kadłuba statków morskich                                                                                                                                                                                        |
| LNG   | (ang. Liquefied Natural Gas)                                                                                                                                                                                                  |
| LR    | (ang. Lloyd Register) – towarzystwo klasyfikacyjne                                                                                                                                                                            |
| MES   | – metoda elementów skończonych                                                                                                                                                                                                |
| MOBES | (ang. Multiobjective Evolution Strategy)                                                                                                                                                                                      |
| MOEA  | (ang. Multi-Objective Evolutionary Algorithm) – ewolucyjny algorytm optymalizacji wielokryterialnej                                                                                                                           |
| MOOM  | (ang. Multi-Objective Optimisation Method) – metoda optymalizacji wielokryterialnej                                                                                                                                           |
| MOOP  | (ang. Multi-Objective Optimization Problem) – wielokryterialne zadanie optymalizacji                                                                                                                                          |
| MOMGA | (ang. Multi-Objective Optimization with Messy Genetic Algorithms)                                                                                                                                                             |
| MOP   | (ang. Many-Objective Problem) – wielokryterialne zadanie z dużą liczbą kryteriów                                                                                                                                              |
| NDS   | (ang. Non-nominated Solution) – rozwiązanie niezdominowane wielokryterialnego zadania optymalizacji                                                                                                                           |
| NPGA  | (ang. Niched Pareto Genetic Algorithm)                                                                                                                                                                                        |
| NPOS  | (ang. Near Pareto-Optimal Solutions) – rozwiązania leżące w pobliżu frontu Pareto                                                                                                                                             |
| NSGA  | (ang. Nondominated Sorting Genetic Algorithm)                                                                                                                                                                                 |

---

<sup>1</sup> W niektórych przypadkach uznano, że nazwy własne występujące w języku angielskim nie powinny być tłumaczone na język polski.

|         |                                                                                                                       |
|---------|-----------------------------------------------------------------------------------------------------------------------|
| NSGA II | (ang. Nondominated Sorting Genetic Algorithm II)                                                                      |
| PAES    | (ang. Pareto Archived Evolution Strategy)                                                                             |
| PDBA    | (ang. Pareto Dominance-Based Algorithm) – algorytm optymalizacji wielokryterialnej oparty na relacji dominacji Pareto |
| POF     | (ang. Pareto Optimal Front) – front Pareto; front ocen rozwiązań optymalnych w sensie Pareto                          |
| POS     | (ang. Pareto-Optimal Solutions) – rozwiązanie optymalne Pareto                                                        |
| PCQI    | (ang. Pareto Compliant Quality Indicator) – wskaźnik jakości zgodny w sensie Pareto                                   |
| PNCQI   | (ang. Pareto Non-Compliant Quality Indicator) – wskaźnik jakości niezgodny w sensie Pareto                            |
| PSO     | (ang. Particle Swarm Optimization) – metoda roju cząstek                                                              |
| QI      | (ang. Quality Indicator) – wskaźnik jakości                                                                           |
| QIM     | (ang. Quality Indicator Method) – metoda wskaźników jakości                                                           |
| RWGA    | (ang. Random Weighted Genetic Algorithm)                                                                              |
| SA      | (ang. Simulated Annealing) – metoda symulowanego wyżarzania                                                           |
| SFFA    | (ang. Scalarizing Fitness Function Algorithms) – algorytmy wykorzystujące skalaryzację kryteriów oceny                |
| SLP     | (ang. Sequential Linear Programming) – metoda sekwencyjnego programowania liniowego                                   |
| SNAME   | (ang. The Society of Naval Architects and Marine Engineers)                                                           |
| SPEA    | (ang. Strength Pareto Evolutionary Algorithm)                                                                         |
| SPEA2   | (ang. Strength Pareto Evolutionary Algorithm 2)                                                                       |
| VAM     | (ang. Visual Assessment Method) – metoda oceny wizualnej                                                              |
| VEGA    | (ang. Vector Evaluated Genetic Algorithm)                                                                             |

## Objaśnienia wybranych terminów<sup>1</sup>

**Algorytm** – skończony uporządkowany ciąg ściśle zdefiniowanych czynności niezbędnych do wykonania określonego zadania.

**Algorytm ewolucyjny** – algorytm wzorowany na biologicznej ewolucji, stosowany do rozwiązywania zadań optymalizacyjnych.

**Atrybut dominacji** – wyznaczana w przestrzeni ocen, na podstawie relacji dominacji Pareto względem innych rozwiązań dopuszczalnych, cecha ilościowa dopuszczalnych rozwiązań wielokryterialnego zadania optymalizacji.

**Decydent** – osoba lub grupa ludzi podejmująca decyzję będącą wynikiem dokonania wyboru.

**Front Pareto (front optymalny Pareto)** – zbiór niezdominowanych ocen rozwiązań wielokryterialnego zadania optymalizacji; dokładne rozwiązanie zadania optymalizacji wielokryterialnej.

**Głębokość zbioru przybliżającego** – mierzona w unormowanej przestrzeni ocen różnica  $d_{AS}$  pomiędzy największą a najmniejszą odległością rozwiązań niezdominowanych od oceny asymptotycznej (6.5).

**Kryteria oceny (kryteria optymalizacji)** – zbiór zdefiniowanych wielkości pozwalających porównywać warianty projektowe i szeregować je pod względem jakości.

**Licznik dominacji** – określona dla każdego wariantu dopuszczalnego wielkość, o wartości określonej przez iloraz liczby rozwiązań dominujących nad tym wariantem i liczby wszystkich wariantów dopuszczalnych (ang. *count*) (6.3).

**Nacisk selekcyjny** – wpływ czynników środowiskowych na zmienność organizmów dzięki mechanizmowi selekcji określonych fenotypów; także intensywność działania doboru naturalnego objawiająca się wielkością zmian częstości genotypów w kolejnych pokoleniach; miarą nacisku selekcyjnego jest przystosowanie (ang. *fitness*).

**Ocena asymptotyczna (ocena wariantu asymptotycznego, ocena rozwiązania asymptotycznego)** – ocena, w kierunku której zmierzają oceny rozwiązań niezdominowanych, lecz nigdy jej nie osiągną; ocena odpowiadająca asymptotycznym wartościom kryteriów optymalizacji; niezmiennik procesu optymalizacji (6.1).

**Ocena idealna (ocena rozwiązania idealnego, ocena wariantu idealnego)** – ocena, która odpowiada najmniejszym, odszukanym w procesie optymalizacji wartościom wszystkich przyjmowanych kolejno kryteriów oceny.

**Optymalizacja** – wyznaczanie, zgodne z określonym tokiem postępowania, rozwiązań najlepszych według przyjętego kryterium oceny oraz spełniających zadane ograniczenia, a więc pochodzących ze zbioru rozwiązań dopuszczalnych.

**Optymalizacja wielokryterialna** – optymalizacja pod względem przyjętego zbioru kryteriów oceny.

**Parametry optymalizacji** – elementy opisu konstrukcji, które są niezależne od projektanta i które są niezmiennikami w procesie optymalizacji.

---

<sup>1</sup> Podane objaśnienia nie są ścisłymi definicjami podanych pojęć, mają jedynie ułatwić zrozumienie omawianych zagadnień. W nawiasach okrągłych podano numery definicji znajdujących się w pracy.

**Przystosowanie (ang. *fitness*)** – miara konkurencyjności reprodukcyjnej danego genotypu w stosunku do innych genotypów w populacji.

**Szerokość zbioru przybliżającego** – mierzony w unormowanej przestrzeni ocen kąt  $\beta$  pomiędzy wektorami wodzącymi ocen rozwiązań leżących na przeciwnych krańcach zbioru przybliżającego (6.4).

**Wariant (wariant projektowy, rozwiązanie, projekt)** – wersja rozwiązania zadania projektowego określona z dokładnością do zmiennych projektowych (zmiennych konstrukcyjnych).

**Wariant dopuszczalny** – wariant, który nie zawiera błędów logicznych i spełnia wszystkie warunki ograniczające.

**Wariant kompromisowy** – wariant dopuszczalny niezdominowany w sensie dominacji Pareto.

**Wariant niezdominowany** – wariant dopuszczalny, dla którego nie istnieje inny wariant dopuszczalny dominujący nad nim w sensie relacji dominacji Pareto (3.2).

**Wariant optymalny** – wariant dopuszczalny najlepszy ze względu na przyjęte kryterium oceny.

**Wskaźnik jakości (skalary)  $QI$**  – funkcja, która zbiorowi przybliżającemu przyporządkowuje liczbę rzeczywistą wyrażającą określony aspekt jakości zbioru (5.1).

**Wskaźnik jakości (wektorowy)  $QI$**  – funkcja wektorowa, która zbiorowi przybliżającemu przyporządkowuje wektor liczb rzeczywistych wyrażających określone aspekty jakości zbioru (5.4).

**Wskaźnik szeregowania** – określona dla każdego wariantu dopuszczalnego wielkość, o wartości określonej przez iloraz liczby rozwiązań zdominowanych przez ten wariant i liczby wszystkich wariantów dopuszczalnych (ang. *rank*) (6.2).

**Wymagania projektowe** – zbiór narzuconych ograniczeń dotyczących wartości cech konstrukcyjnych, właściwości konstrukcyjnych lub zmiennych stanu obiektu.

**Zadanie optymalizacji** – zadanie wyboru, którego rozwiązaniem jest wariant optymalny.

**Zadanie optymalizacji wielokryterialnej** – zadanie wyboru, którego rozwiązaniem jest zbiór wariantów kompromisowych względem zbioru kryteriów oceny (kryteriów optymalizacji).

**Zadanie wyboru** – zadanie gromadzenia i przetwarzania informacji w celu wskazania jednego wariantu lub zbioru wariantów, które spełniają wszystkie wymagania i są najlepsze ze względu na pewne kryterium lub zbiór kryteriów.

**Zbiór przybliżający** – zbiór ocen rozwiązań dopuszczalnych takich, że dowolny wektor oceny należący do tego zbioru nie jest zdominowany lub nie jest równy innemu wektorowi oceny w tym zbiorze; empiryczne rozwiązanie wielokryterialnego zadania optymalizacji; empiryczny front Pareto (3.3).

**Zmienne konstrukcyjne** – elementy opisu konstrukcji zależne od projektanta, których wartości poszukiwane są w procesie optymalizacji.

# 1. Wprowadzenie

## 1.1. Konstrukcja kadłuba statków morskich: elementy, projektowanie i optymalizacja

Podstawową część nośną współczesnych statków morskich, integrującą cały układ konstrukcyjny (podobnie jak w obiektach lotniczych, kolejowych i innych środkach transportu), stanowią konstrukcje kadłubowe. Pomijając, występujące niekiedy nawet w znacznej liczbie, rozwiązania specyficzne dla określonego typu statku (np. dla masowca, kontenerowca, statku ro-ro), kadłub każdego morskiego statku towarowego zbudowany jest według wspólnego podstawowego planu obejmującego cienką, zamkniętą, wodoszczelną powłokę, usztywnioną wewnątrz układem wzajemnie krzyżujących się belek, nazywanym układem wiązań (rysunek 1.1), oraz strukturami przegradzającymi, zazwyczaj wodoszczelnymi, chociaż stosuje się także struktury przegradzające niewodoszczelne, nazywane przegrodami. Belki, które biegną w poprzek kadłuba prostopadłe do kierunku rufa-dziób, są to wiązania poprzeczne, natomiast te, które biegną wzdłuż kadłuba, to wiązania wzdłużne. Pionowe wodoszczelne struktury przegradzające, dzielące przestrzeń ograniczoną zewnętrzną powłoką kadłuba na wiele części lub przedziałów, nazywa się grodziami wodoszczelnymi – poprzecznymi lub wzdłużnymi. Pierwsze z nich ustawiane są w płaszczyznach prostopadłych do kierunku rufa-dziób i dzielą wewnętrzną przestrzeń kadłuba na kilka przedziałów wzdłuż długości statku. Grodzie wzdłużne, ustawiane równoległe do tego kierunku, dzielą tę przestrzeń na wiele przedziałów wzdłuż szerokości statku. Grodzie wodoszczelne sięgają od dna do górnego pokładu, zapewniając pływalność statku w przypadku awaryjnego zalania określonych przedziałów. Oprócz pionowych struktur przegradzających wewnątrz powłoki kadłuba mogą być montowane poziome struktury przegradzające nazywane międzypokładami lub platformami, w zależności od zasięgu przestrzennego i stopnia szczelności.

Ze względu na funkcję pełnioną w zapewnieniu wytrzymałości konstrukcji kadłuba statku wiązania dzielą się na dwie podstawowe grupy. Wiazania podpierające tylko elementy poszycia, wykonane najczęściej<sup>1</sup> z kształtowników walcowanych<sup>2</sup>, nazywają się wiązaniami drugiego rzędu lub usztywnieniami. Wiazania, zazwyczaj o znacznych wymiarach, podpierające poszycie, a także wiązania drugiego rzędu, usztywnienia, nazywają się wiązaniami pierwszego rzędu lub wiazarami. Wiazary wykonuje się jako prefabrykaty spawane z elementów wykrawanych z arkuszy blach. Usztywnienia podpierające poszycie dna nazywają się wręgami dennymi. Natomiast rozstawione poprzecznie wiazary denne nazywają się dennikami, zaś zorientowane wzdłużnie – wzdłużnikami dennymi. Usztywnienia podpierające poszycie burt nazywają się wręgami burtowymi poprzecznymi lub wzdłużnymi, w zależnoś-


---

<sup>1</sup> Usztywnienia można również wykonywać, spawając je z płaskowników.

<sup>2</sup> W procesie walcowania wykonuje się kształtowniki stalowe, natomiast w procesie wyciskania wykonuje się kształtowniki ze stopów aluminium.

ci od kierunku ich przebiegu. Rozstawione poprzecznie wiązary burt nazywają się wręgami ramowymi, natomiast skierowane wzdłużnie – wzdłużnikami burtowymi. Usztywnienia podpierające pokład to pokładniki, poprzeczne lub wzdłużne, zależnie od kierunku przebiegu. Wiazary natomiast są to pokładniki ramowe, jeśli zorientowane są poprzecznie, lub wzdłużniki pokładowe, jeśli rozmieszczone są wzdłuż kadłuba. Rozmieszczone w tych samych przekrojach (płaszczyznach) oraz sztywno połączone ze sobą denniki, burtowe wręgi ramowe oraz pokładniki ramowe tworzą ramę wręgową.

Zorientowane poprzecznie wiązania kadłuba statku rozmieszczone są w regularnych odstępach nazywanych odstępem wręgowym. Wielkość ta, określana w procesie projektowania konstrukcji kadłuba, w sposób zasadniczy wpływa na jego wytrzymałość i charakterystyki eksploatacyjne statku jako całości.



Rys. 1.1. Hierarchiczna struktura konstrukcji kadłuba morskiego statku towarowego

Proces projektowania konstrukcji kadłuba statku morskiego może być opisany i realizowany podobnie jak proces projektowania innych obiektów technicznych. Kowalski (1983) na przykład przedstawił metodykę formułowania matematycznych modeli optymalizacyjnych elementów maszyn i urządzeń, przystosowanych do jednokryterialnych obliczeń komputerowych. Tarnowski (1984) przedstawił dyskusję nad procesem wyboru w projektowaniu technicznym, w różnych jego fazach, oraz zaproponował ogólny model procesu wyboru, który może dotyczyć konstrukcji całego obiektu lub jego części, systemu projektującego lub samej procedury projektowania. W pracy *Projektownawstwo. Elementy wiedzy o projektowaniu* (1988) przedstawiono jedną z pierwszych syntez wiedzy projektownawczej dotyczącej trzech

grup zagadnień: podmiotu projektowania, przedmiotu projektowania i procesu projektowania. Szczególną uwagę zwrócono na podejście systemowe do przedmiotu projektowania oraz do procesu projektowania. Omówiono procesy podejmowania decyzji oraz etapy rozwiązywania problemów projektowych. Osiński i Wróbel (1995) przedstawili zwartą teorię konstruowania maszyn oraz kompleksowe podejście do komputerowego wspomagania projektowania. W szczególności przedstawili procedury formułowania matematycznego modelu konstrukcji na potrzeby optymalizacji. W pracy *Podstawy konstrukcji maszyn* (1995) (w pierwszym tomie trzytomowej monografii dotyczącej szeroko rozumianych problemów konstruowania maszyn) przedstawiono m.in. podstawowe zagadnienia związane z konstruowaniem, modelowaniem i optymalizacją części maszyn. Tarnowski (1997) przedstawił szczegółowe wprowadzenie do projektowania technicznego i podstawy teoretyczne tego procesu. Opisał także sposoby formułowania zadania projektowego i wymagań projektowych oraz metody poszukiwania rozwiązań zadania projektowego. Omówił znaczenie optymalizacji w projektowaniu oraz zaprezentował szczegółową metodykę formułowania zadań optymalizacji. Szymczak (1998) omówił wybrane zagadnienia nowoczesnego projektowania konstrukcji inżynierskich: podstawy metodologii projektowania technicznego, elementy projektowania optymalnego, elementy teorii bezpieczeństwa i niezawodności konstrukcji oraz analizy wrażliwości konstrukcji.

Jeśli chodzi o projektowanie konstrukcji kadłuba statków morskich, klasyczne monografie koncentrują się przede wszystkim na jej opisie jako całości oraz na bardziej szczegółowym omówieniu wybranych rejonów konstrukcyjnych; szczególne miejsce zajmuje dorobek Potyrały (1967). Inne prace monograficzne polskich autorów, poświęcone projektowaniu konstrukcji statków, to prace Bielińskiego i in. (1973, 1988), Wakuły (1975), Wewiórskiego i Wituszyńskiego (1977), Jastrzębskiego (1991) i Więckiewicza (1998, 1999). Spośród publikacji zagranicznych wymienić można np. prace: *Ship Design and Construction* (1980), Taylora (1984), Eyresa (2007). Bujniewicz i in. (1971), Butnicki (1971), autorzy pracy *Konstrukcje okrętowe ze stopów aluminium* (1976), Kozłowski i in. (1982), Jastrzębski i Puchaczewski (1989), Cudny i Puchaczewski (1995), oraz Cudny (1996) poruszają przede wszystkim zagadnienia związane z własnościami materiałów oraz kryteriami ich doboru na konstrukcje kadłuba statków. Szarejko i Roguski (1974), oprócz zagadnień konstrukcyjnych, bardzo szczegółowo omawiają zagadnienia teorii okrętów i właściwości morskich jednostek pływających. Orszulok (1983) i Judziński (2001) omawiają wpływ eksploatacji statków na wytrzymałość i bezpieczeństwo konstrukcji kadłuba.

Na uwagę zasługują również monografie dotyczące architektury statków (Netzel i in. 2009, Lerch 2010), w których autorzy wiele uwagi poświęcają także zagadnieniom konstrukcyjnym w kontekście wymagań, jakie narzucają proponowane rozwiązania architektoniczne.

W ostatnich latach autorzy opublikowanych monografii koncentrują swoją uwagę nie tylko na projektowaniu konstrukcji statków jako systemu współpracujących elementów konstrukcji poszycia, usztywnień i wiązarów, ale także na obliczeniowych metodach analizy konstrukcji, np. Bai (2003), Okumoto i in. (2009) oraz Hughes i Paik (2010).

Uwagę zwracają również publikacje wydawane przez SNAME, w tym monografia dotycząca projektowania oraz konstruowania wielu typów współczesnych statków morskich Lamb (2004) oraz *The Principles of Naval Architecture Series*, w ramach której opublikowa-

no monografie dotyczące różnych aspektów projektowania i konstruowania statków (Mansour i Liu 2008, Larsson i Raven 2010, Moore 2010 i Vorus 2010).

Konstruktorzy mogą również sięgnąć do opublikowanych przez IACS wytycznych dotyczących planowania i przeprowadzania przeglądów, oceny stanu technicznego oraz proponowanych metod naprawy węzłów konstrukcyjnych IACS (1999, 2002 a, b, 2005). Zawierają one bardzo wiele istotnych wskazówek dotyczących przede wszystkim szczegółowych rozwiązań węzłów konstrukcyjnych kadłuba wybranych typów statków. Podobny charakter mają także trzy inne wytyczne: LRS (1996 a, b) oraz *Tanker Structure Co-operative Forum* (2010).

Od 1996 roku Wydawnictwo Trademar Sp. z o.o. z Gdyni w ramach serii Współczesne Technologie Transportu Morskiego, skierowanej do marynarzy floty handlowej, opublikowało siedem monografii dotyczących eksploatacji różnych typów statków (Pałucha i in. 1996, Grzybowski i in. 1997, Puchalski 1998, Wiewióra i in. 1999, Studziński 2005, Puchalski i Soliwoda 2008, Cydejko i in. 2011). Mimo że monografie te w niewielkim stopniu dotyczą samych konstrukcji kadłuba statków, stanowią jednak bardzo obszerne kompendium wiedzy o wybranych typach statków, przydatnej także dla konstruktorów.


Bieżący stan wiedzy teoretycznej i doświadczeń dotyczących konstrukcji statków jest podsumowywany podczas organizowanych co trzy lata posiedzeń ISSC skupiających ekspertów wielu dyscyplin związanych z projektowaniem konstrukcji statków. Pierwszy kongres ISSC odbył się w 1961 roku w Glasgow, natomiast ostatni, siedemnasty, w sierpniu 2009 roku w Korei Południowej.

Proces projektowania tak złożonego obiektu, jakim jest konstrukcja kadłuba statku morskiego, ma przebieg sekwencyjno-iteracyjny i obejmuje projektowanie wstępne, techniczno-klasyfikacyjne i wykonawcze (Szarejko i Roguski 1974, Wewiórski i Wituszyński 1977, Jastrzębski 1994)<sup>3</sup>, w którym wiele czynności wykonywanych jest wielokrotnie, przy jednoczesnym wzroście uszczegółowienia prac i stopniowym przybliżaniu się od początkowych założeń i podstawowych idei konstrukcji do szczegółowego zaprojektowania węzłów. Jest również procesem hierarchicznym, o strukturze zstępującej. Bardzo często, a zwłaszcza w przypadku zupełnie nowych typów statków, cały proces projektowania przedstawiany jest w zaproponowanej przez Evansa (1959) postaci – tak zwanej spirali projektowej (rysunek 1.2), która w końcowym etapie doprowadza do uzyskania pożądanych charakterystyk jednostki, a w efekcie prób morskich – do ich potwierdzenia. W najbardziej ogólnej postaci projektowanie konstrukcji kadłuba statku to dobór materiału i przestrzenne rozmieszczenie go w postaci elementów konstrukcji (pokładów, grodzi, bloków kadłuba itd.), spośród których każdy składa się z mniejszych jednostek strukturalnych (wiązarów, usztywnień, poszyc itd.) – rysunek 1.1. Ważne jest, aby przy spełnieniu narzuconych wymagań projektowych kadłub zapewniał bezpieczną eksploatację statku, przy najmniejszych kosztach.

---

<sup>3</sup> W projektowaniu wstępnym zazwyczaj wyróżnia się kolejno: projektowanie koncepcyjne, ofertowe i kontraktowe. Do projektowania wstępnego zalicza się także formułowanie założeń projektowych.






Rys. 1.2. Projektowanie statku jako proces osiągania kolejnych poziomów uszczegółowienia w kolejnych przybliżeniach – spirala projektowa. Etapy projektowania statków: I – projektowanie koncepcyjne, II – projektowanie ofertowe, III – projektowanie kontraktowe, IV – projektowanie techniczno-klasifikacyjne, V – projektowanie wykonawcze, VI – dokumentacja zdawcza; etapy I, II i III łączy się często, nazywając je projektowaniem wstępnym

Proces projektowania konstrukcji kadłuba statku oznacza zatem uściślanie opisu elementów, polegające na podejmowaniu decyzji projektowych i gromadzeniu informacji dotyczących: (1) materiału do budowy konstrukcji, czyli doboru materiału na elementy konstrukcyjne (materiału); (2) rozmieszczenia elementów konstrukcyjnych w przestrzeni (topologii); (3) kształtu elementów konstrukcyjnych (kształtu); (4) wymiarów przekrojów poprzecznych elementów konstrukcyjnych (wymiarowania), zapewniających osiągnięcie na odpowiednim poziomie wyspecyfikowanych wcześniej właściwości konstrukcji – kryteriów oceny. W praktyce projektowej postępowanie to ma zazwyczaj charakter iteracyjny, to znaczy polega na stopniowym uszczegóławianiu konstrukcji, poczynając od wariantu lub wariantów przyjętych jako wyjściowe (początkowe).

Dla osiągnięcia celów projektowania kluczowe znaczenie mają decyzje podjęte na etapie projektowania wstępnego, ponieważ wtedy ustala się podstawowe cechy statku – w tym tkwi główne niebezpieczeństwo popełnienia zasadniczych błędów w projektowaniu jednostki. Błędy popełnione na tym etapie uwidocznione są w cechach użytkowych oraz eksploatacyjnych i nie mogą być w sposób zadowalający zrekompensowane w późniejszym projektowaniu detali na niższych poziomach hierarchicznych projektowania. Jeśli nie zostaną usunięte, mogą powodować największe straty (rysunek 1.3). Jednocześnie decyzje podjęte trafnie i szybko przynoszą największe korzyści i w sposób istotny wpływają na sukces przedsięwzięcia finansowego związanego z budową nowego statku. W związku z tym w pracy założono, że opracowane modele konstrukcji kadłuba i dokładność przeprowadzonych analiz będą odpowiednie dla projektu wstępnego statku.



Rys. 1.3. Ilustracja relacji pomiędzy kosztami (korygowania, naprawy) błędów projektowych oraz ilością informacji o projekcie w trakcie rozwoju projektu statku. Etapy projektowania: I – projektowanie koncepcyjne, II – projektowanie ofertowe, III – projektowanie kontraktowe, IV – projektowanie techniczno-klasyfikacyjne, V – projektowanie wykonawcze, VI – dokumentacja zdawcza

W środowisku stoczniowych biur projektowych przyjętą praktyką jest oparcie się na zgromadzonym doświadczeniu projektowym dotyczących jednostek zbudowanych wcześniej. Teoretycznie projektanci mogą opracować nieskończoną liczbę wariantów projektowych spełniających określone wymagania, lecz nie są w stanie zbadać wszystkich wariantów jedynie na podstawie własnego doświadczenia i wiedzy o zbudowanych statkach. W praktyce więc konstrukcja kadłuba statku projektowana jest na podstawie doświadczenia i danych dotyczących podobnych statków zbudowanych, przy założeniu, że przyjęte wzorce reprezentują warianty bliskie optymalnym i że wprowadzenie małych zmian dostosowujących projekt do założonych wymagań nie wpłynie ujemnie na ekonomiczną efektywność zaprojektowanych jednostek. Takie podejście jest akceptowane w przypadku konwencjonalnych statków towarowych, takich jak masowce, tankowce i kontenerowce, które po dziesięcioleciach rozwoju mają ustaloną formę konstrukcyjno-architektoniczną.

Problem projektowania konstrukcji kadłuba statku morskiego uwzględnia nie jedno, a wiele kryteriów oceny, które zazwyczaj pozostają we wzajemnym konflikcie. Formułowanie zatem problemu projektowego na podstawie modelu jednokryterialnego okazuje się odległe od rzeczywistości, a uwzględnienie więcej niż jednego kryterium powoduje konieczność rozwiązania zadania wielokryterialnego. Wymaga to pełniejszego zbadania przestrzeni wariantów, bez możliwości wyboru wariantu jednoznacznie uznanego jako najlepszy. Uzyskany zbiór wariantów kompromisowych stanowi podstawę podjęcia ostatecznej decyzji projektowej, czyli wskazania wariantu (ew. wariantów) do dalszej analizy na kolejnym poziomie procesu projektowania. Podejmowanie decyzji, czyli wybór wariantu, obciążone jest w tym wypadku subiektywnością oceny, połączoną z brakiem pełnej wiedzy; można jedynie dążyć do ich minimalizacji. Celowe jest zatem właściwe zidentyfikowanie możliwie najlepszego rozwiązania jako rezultatu wielokryterialnego procesu projektowania konstrukcji. Wariant konstrukcji, przyjęty na tej podstawie jako rezultat procesu projektowania, determinuje charakterystyki statku (np. koszt budowy i cenę zakupu, szybkość eksploatacyjną, ładowność, zużycie paliwa) w akceptowanym obszarze tolerancji, przyjętym w danym etapie projektowania.

Mimo że stosowanie metod optymalizacji w projektowaniu konstrukcji kadłuba statków morskich nadal jest bardzo skomplikowane, budzi ono coraz większe zainteresowanie, podobnie jak w innych gałęziach nauk i praktyce inżynierskiej. Prowadzone są prace badawcze, których celem jest zdobycie wiedzy o obciążeniach działających na konstrukcję i jej odpowiedzi na zadane obciążenia, poszukiwanie bardziej efektywnych metod matematycznych i algorytmów numerycznych. Stosowanie różnorodnych uproszczeń podczas formułowania modeli obliczeniowych oraz stosowanie uproszczonych metod analizy konstrukcji kadłuba, a także odpowiednia dekompozycja zadań optymalizacji powodują, że zastosowanie metod optymalizacji w projektowaniu konstrukcji kadłuba statku jest już możliwe. Pomimo istniejących możliwości nie wdrożono metod optymalizacji do praktyki.

Biorąc pod uwagę wymiarowanie wiązań, podstawą projektowania konstrukcji statków są (1) albo wymagania towarzystw klasyfikacyjnych (np. DNV, LR, GL), opublikowane w postaci przepisów klasyfikacyjnych zawierających uproszczone formuły szacowania wartości obciążeń konstrukcji i wymiarów elementów konstrukcyjnych zapewniających przeniesienie tych obciążeń, albo (2) bardziej racjonalne podejście oparte bezpośrednio i całkowicie na numerycznych metodach mechaniki konstrukcji. Mimo że formułuje się niekiedy opinie, że przepisy klasyfikacyjne nie spełniają oczekiwań konstruktorów dotyczących projektowania konstrukcji o nowatorskich rozwiązaniach, są one zbiorem zaleceń wywodzących się z dobrej praktyki projektowej, w związku z czym ich stosowanie w przypadku konwencjonalnych statków jest w pełni uzasadnione. W przedstawionej pracy autor zakłada, że wymiary elementów konstrukcyjnych określone zostaną zgodnie z odpowiednimi wymaganiami towarzystw klasyfikacyjnych, umożliwiającymi szybkie i automatyczne zwymiarowanie wielu wariantów konstrukcji generowanych przez algorytm optymalizacyjny.

Pierwsze próby optymalizacji konstrukcji kadłuba statków morskich polegały na przeprowadzaniu ręcznych obliczeń przy zastosowaniu prostych metod analizy (np. badań parametrycznych kilku wariantów projektowych). Systematyczne badania, wykorzystujące analityczne algorytmy optymalizacyjne, stały się możliwe po powszechnym wprowadzeniu komputerów. Pierwsze programy komputerowe realizujące optymalizację uruchomiono na początku 60. lat XX wieku. Do tego czasu konstrukcje kadłuba projektowano, wykonując obliczenia ręcznie z wykorzystaniem odpowiednio przygotowanych wykresów i tabel (m.in. Harlander 1960, Mero i Spunt 1965).

Postępujący rozwój komputerów i zwiększenie ich mocy obliczeniowych stymulowały rozwój numerycznych algorytmów optymalizacyjnych oraz umożliwiły prowadzenie kolejnych badań nad rozwiązywaniem różnorodnych problemów optymalizacji konstrukcji statków. Evans i Khoushy (1963), Moe (1968), Moe i Lund (1968), Lund (1970) oraz Nowacki i in. (1970) podjęli pierwsze próby optymalizacji konstrukcji zbiornikowców. Natomiast Kavlie (1966) oraz Moses i Onoda (1969) zoptymalizowali model kadłuba statku w postaci belki poddanej zginaniu. Caldwell i Hewitt (1976) przedstawili metodę optymalizacji panelu okrętowego. Jendo (1979) przeprowadził optymalizację konstrukcji ramowej zbiornikowca. Bardziej szczegółowy opis ówczesnego stanu wiedzy, dotyczącego optymalizacji konstrukcji statków, przedstawiono w pracach Evansa (1975) i ISSC (1976).

Nowym bodźcem do dalszych prac, dotyczących optymalizacji konstrukcji kadłuba statków, były prace kierowane przez Hughesa, zwieńczone zbudowaniem programu kompu-

terowego, wykorzystującego MES, umożliwiającego optymalizację dużych złożonych struktur, z uwzględnieniem wielu nieliniowych ograniczeń. Pierwsza wersja programu została zaprezentowana pod nazwą AUSTROSHIP (Hughes i Mistree 1977). Od tamtego czasu opracowano dwie nowe wersje tego programu – SHILOPT (Hughes i in. 1980) i MAESTRO (Hughes 1985, 1988).

W dwóch ostatnich dziesięcioleciach XX wieku stosowano coraz więcej różnych technik obliczeniowych do optymalizacji konstrukcji statków; przykłady optymalizacji konstrukcji kadłuba statków przedstawiają między innymi Miura i in. (1973), Jendo (1979), Lyon (1982), Hughes (1987), Hung (1987), Jang i Na (1987, 1991), Kriezis (1991), Krol (1991), Rahman (1992), Hatzidakis i Bernitsas (1994), Konieczny i in. (1994), Nobukawa i in. (1995), Rahman i Caldwell (1995), Jang i Seo (1996), Liang i in. (1997), Augusto i Kawano (1998) oraz Ahuja i Ulfvarson (2006). Rodionov (1990) omówił teoretyczne podstawy jednokryterialnej optymalizacji konstrukcji statków, ilustrując je przykładami optymalizacji prostych elementów konstrukcyjnych. Stan ówczesny podsumowano w kolejnych raportach ISSC (1988, 1997, 1991, 1994, 2000) oraz w pracy Catley i in. (1990).

Prace o charakterze przeglądowym, opublikowane już w nowym stuleciu, to m.in. *Optimistic – Optimization in Marine Design* (2003) oraz publikacja Rigo (2003). W pierwszej pracy przedstawiono przegląd problemów oraz współczesny stan wiedzy dotyczący zastosowania metod optymalizacyjnych w projektowaniu statków i obiektów oceanotechnicznych, w tym także optymalizacji konstrukcji kadłuba statków. Jest to jedyna znana autorowi praca o charakterze monograficznym, dotycząca metod stosowanych do optymalizacji obiektów morskich. Nowacki (2010) dokonał syntetycznego przeglądu najważniejszych koncepcji i osiągnięć dotyczących komputerowego wspomaganie projektowania statków, w tym także optymalizacji konstrukcji kadłuba statków morskich. Niestety, przegląd ten zakończył na początku lat osiemdziesiątych poprzedniego wieku, nie odnosząc się do osiągnięć najnowszych, w tym do zastosowań ewolucyjnych algorytmów optymalizacji wielokryterialnej. Kontynuowano także publikowanie podsumowań w kolejnych raportach ISSC (2006 b, 2009 b).

W ostatnich latach podjęto wysiłki zmierzające do stosowania w rozwiązywaniu zadań optymalizacji konstrukcji kadłuba statków nowoczesnych algorytmów optymalizacyjnych. Okada i Neki (1992, 1995), Nobukawa i Zhou (1996), Zhou i in. (1997 a, b), Nobukawa i in. (1998), Sekulski i Jastrzębski (1998, 1999 a, b), Sekulski (2000, 2009 a, b) wskazali, że algorytmy genetyczne mogą być skutecznym narzędziem stosowanym w jednokryterialnej optymalizacji konstrukcji kadłuba statków morskich.

Podjęte próby wielokryterialnej optymalizacji konstrukcji kadłuba statków morskich nie są liczne. Początkowo badacze nie wykorzystywali pojęcia dominacji Pareto i nie przeszukiwali systematycznie przestrzeni ocen w celu uzyskania zbioru rozwiązań niezdominowanych. Moe i Lund (1968) przedstawili dwukryterialną optymalizację kosztu i ciężaru konstrukcji kadłuba tankowca. Wynikiem obliczeń były wykresy obrazujące zmiany kryteriów optymalizacji w odniesieniu do zmiennych decyzyjnych. Rahman (1992) oraz Rahman i Caldwell (1995) zaprezentowali wyniki optymalizacji kosztu i ciężaru konstrukcji statków śródładowych. Jang i Shin (1997) oraz Shin i in. (2006) zastosowali strategię ewolucyjną do wielokryterialnej optymalizacji konstrukcji kadłuba zbiornikowca pod względem ciężaru i kosztu. Zastosowanie strategii ewolucyjnej do optymalizacji wielokryterialnej pozwoliło na

odszukanie zbioru rozwiązań niezdominowanych. Praca Jang i Shin (1997) jest pierwszą znaną autorowi publikacją przedstawiającą wyniki poszukiwania zbioru rozwiązań niezdominowanych w przypadku wielokryterialnej optymalizacji konstrukcji kadłuba statku morskiego. Yang i Hwang (2002) zastosowali algorytm genetyczny do optymalizacji kształtu grodzi falistej pod względem ciężaru i kosztu konstrukcji. Autorzy ci zastosowali skalaryzację funkcji celu i nie poszukiwali zbioru rozwiązań niezdominowanych. Klanac i Kujala (2004) zastosowali algorytm genetyczny do optymalizacji sandwichowych paneli okrętowych pod względem ciężaru i kosztu. Jastrzębski i in. (2007) zastosowali prostą metodę obliczeń parametrycznych do optymalizacji konstrukcji kontenerowca pod względem ciężaru konstrukcji, długości spoin spawalniczych i powierzchni elementów konstrukcyjnych do konserwacji. Autorzy przeanalizowali kilka wybranych przez siebie wariantów, jednak nie poszukiwali zbioru rozwiązań niezdominowanych. Klanac i Jelovica (2007 a, b) zastosowali algorytm genetyczny do optymalizacji konstrukcji szybkiego promu pasażersko-samochodowego pod względem ciężaru i wysokości środka ciężkości konstrukcji. Jelovica i Klanac (2009) zastosowali algorytm genetyczny do optymalizacji konstrukcji chemikaliowca, a Klanac i in. (2009) – do optymalizacji konstrukcji chemikaliowca pod względem odporności kolizyjnej mierzonej wielkością energii zaabsorbowanej podczas kolizji, masy konstrukcji i masy stali nierdzewnej zastosowanej do budowy statku. Caprace i in. (2010) zaprezentowali wyniki optymalizacji konstrukcji zbiornikowca LNG pod względem ciężaru i kosztu konstrukcji. Do optymalizacji użyli deterministycznej metody linearyzacji nieliniowego zadania optymalizacyjnego i agregacji kryteriów optymalizacji z odpowiednio dobieieranymi współczynnikami wagowymi. Sekulski (2010) wykorzystał różne strategie wielokryterialnego algorytmu genetycznego do optymalizacji szybkiego promu pasażersko-samochodowego pod względem ciężaru i pola powierzchni elementów konstrukcyjnych. Sekulski (2011 a, b, c) zastosował własną metodę ewolucyjnej optymalizacji wielokryterialnej z kombinowaną funkcją celu do optymalizacji konstrukcji statku szybkiego. Opracowana metoda pozwoliła na zbudowanie zbioru rozwiązań niezdominowanych. Metodę tę szczegółowo omówiono w niniejszej rozprawie.

Podsumowując dokonany przegląd, można stwierdzić, że skuteczne poszukiwanie zbioru niezdominowanych rozwiązań konstrukcji kadłuba statku morskiego umożliwiło dopiero zastosowanie ewolucyjnych algorytmów optymalizacji wielokryterialnej w 90. latach XX wieku oraz że w większości omawianych przypadków optymalizacji konstrukcji kadłuba statków morskich przyjęto dwa kryteria optymalizacji – ciężar i koszt wykonania konstrukcji.

Pierwszą znaną autorowi pracą polskiego badacza, dotyczącą optymalizacji wielokryterialnej w projektowaniu okrętowym, jest opublikowana w 1975 roku propozycja metody oceny wielokryterialnych rozwiązań projektowych (Jagoda 1975) zastosowanej do projektowania siłowni okrętowej.

Termin „optymalizacja konstrukcji kadłuba statku” jest różnie rozumiany przez różne osoby lub zespoły prowadzące analizę. Dla zamawiającego statek w stoczni optymalizacja konstrukcji nowej jednostki oznacza określenie wymiarów głównych zapewniających maksymalizację zysków z eksploatacji (Buxton 1976). Dla projektanta jednostki optymalizacja konstrukcji (struktury) oznacza jednoczesne projektowanie kształtu i projektowanie wiązań (ang. *scantling*) – Keane i in. (1991). Dla konstruktora optymalizacja konstrukcji to tak naprawdę znalezienie optymalnych wymiarów wiązań dna, burt i pokładów.

Optymalną konstrukcję kadłuba statku można otrzymać, przeprowadzając analizę optymalizacyjną w różnych obszarach, takich jak: optymalizacja wymiarów (ang. *sizing optimisation*), optymalizacja kształtu (ang. *shape optimisation*), optymalizacja topologii (ang. *topological optimisation*). Można również prowadzić optymalizację materiału konstrukcyjnego (ang. *material optimisation*).

Optymalizacja wymiarów może być rozumiana jako proces poszukiwania optymalnych wymiarów elementów konstrukcyjnych, przy ustalonych kształtach tych elementów i topologii. Wymiary główne i kształt kadłuba są ustalone. Pierwsze optymalizacyjne programy komputerowe, takie jak: SUMT (Moe i Lund 1968, Moses i Onoda 1969, Lund 1970), umożliwiły poszukiwanie optymalnych wymiarów elementów konstrukcyjnych, wykorzystując analityczne obliczenia odpowiedzi konstrukcji w postaci naprężeń lub odkształceń w poszczególnych punktach lub przekrojach elementów konstrukcyjnych. Takie podejście umożliwiło przeprowadzenie szybkich obliczeń optymalizacyjnych, lecz algorytm odpowiedzi konstrukcji musiał być formułowany specjalnie dla każdego konkretnego przypadku konstrukcji. Zastosowanie w latach 80. (Hughes i in. 1980, Zanic i in. 2000) MES do oceny odpowiedzi konstrukcji wymagało długich obliczeń niezbędnych do optymalizacji wymiarów elementów konstrukcyjnych. W celu uniknięcia tej niedogodności zaproponowano opracowanie bardziej efektywnych matematycznych algorytmów optymalizacji (Fleury 1989, 1993), a także rozdzielenie zadania optymalizacyjnego na dwa etapy (Hughes 1988, Sen i in. 1989, Krol 1991, Rahman i Caldwell 1995, Rigo 2001 a, b, Rigo i Fleury 2001) w tzw. procedurze racjonalnego projektowania (ang. *rational design*).

W ciągu ostatnich 20 lat nastąpił intensywny rozwój narzędzi do optymalizacji kształtu jednostek pływających (Beckers 1991). Opracowanie bardziej zaawansowanych metod obliczeniowych mechaniki płynów oraz losowych odpornych algorytmów optymalizacyjnych umożliwiło optymalizację kształtu kadłubów statków. Wadą takich procedur optymalizacyjnych są jednak wątpliwości dotyczące możliwości budowy kadłubów o kształtach sugerowanych przez wyniki optymalizacji, z uwzględnieniem wymagań stawianych konstrukcji kadłuba. Jako przykłady można wymienić prace Dejhalla i in. (2001, 2002), Chena i Huang (2002) oraz Yanga i in. (2002). Trudnym do rozwiązania problemem pozostaje wzajemne oddziaływanie płynu i konstrukcji.

Stale postępujący rozwój możliwości obliczeniowych komputerów i algorytmów optymalizacyjnych stwarza szansę na pojawienie się już niedługo możliwości optymalizacji również topologii konstrukcji (Rigo 2001 b). Przez topologię konstrukcji rozumieć należy liczbę i typ elementów konstrukcji (kratowych, cięgowych, belkowych, cienkościennych, płytowych, tarczowych, powłokowych itp.) oraz sposób ich połączeń. Możliwość rozwiązywania takich zadań optymalizacyjnych oznaczać będzie znaczny postęp w projektowaniu konstrukcji statków, dając szansę na nowatorskie podejście do projektowania konstrukcji opartych na nowej filozofii projektowania. Zostały już podjęte badania dotyczące zadań o niewielkiej liczbie zmiennych (Bendsoe i Kikuchi 1988, Jastrzębski i Sekulski 2005).

Problem doboru optymalnych własności mechanicznych i struktury materiału konstrukcyjnego (izotropowego, ortotropowego, anizotropowego) oraz stałych określających poszczególne rodzaje materiałów nie został dotychczas podjęty w odniesieniu do konstrukcji statków morskich. Istnieją w tym zakresie doświadczenia z zastosowania metod optymalizacji do projektowania struktur laminatów poliestrowo-szklanych, stymulowane przez potrzeby

przemysłu lotniczego i motoryzacyjnego. Z punktu widzenia konstrukcji statków, budowanych przede wszystkim ze stali, należy w pierwszej kolejności podjąć próbę rozwiązania zadania optymalnego doboru asortymentu stali przeznaczonej na odpowiednie elementy konstrukcyjne.

Zmienne projektowe, określające właściwości materiału konstrukcyjnego, zwykle są zmiennymi dyskretnymi, ponieważ wybór dokonywany jest z pewnego skończonego zbioru przyjętego asortymentu. Jeżeli rozpatruje się małą liczbę przewidywanych materiałów, najbardziej efektywna jest optymalizacja w odniesieniu do innych zmiennych (oddzielnie dla każdego materiału), a następnie porównanie otrzymanych rezultatów optymalizacji częściowych. Zastosowanie materiałów kompozytowych w elementach konstrukcji rozszerza zakres zadań, w których charakterystyki materiału występują jako zmienne projektowe. Choćby charakterystyki materiałów kompozytowych można uważać za ciągłe (np. granica plastyczności, objętość wypełniacza), problem ostatecznego wyboru materiału na konstrukcję w większości przypadków ma charakter dyskretny. W związku z tym także w tym wypadku najbardziej odpowiednim sposobem wykorzystania metod optymalizacji przy wyborze materiału jest uzyskanie kilku niezależnych rozwiązań przy zadanych wartościach zmiennych opisujących mechaniczne własności materiału. Procedury optymalizacji, dotyczące wyboru materiału konstrukcyjnego, stosuje się rzadko.

Poszukiwanie optymalnej konstrukcji kadłuba statków morskich odbywa się dziś w czterech obszarach: optymalizacji kształtu, optymalizacji materiału, optymalizacji topologii i optymalizacji wymiarów elementów konstrukcyjnych. Ze względu na specyfikę zadań optymalizacji nie sposób jest rozwiązywać jedno projektowe zadanie optymalizacji jednocześnie we wszystkich tych obszarach. Powszechną praktyką jest zatem to, że w każdym z nich formułuje się zadanie optymalizacji, niezależnie od pozostałych. Zadania te z kolei rozwiązywane są w zespołach eksperckich pracujących niezależnie w różnych miejscach i różnym czasie. Tak zorganizowany proces projektowania nazwać można projektowaniem rozproszonym. Podział ten wydaje się sztuczny i wynika z braku odpowiednich narzędzi pozwalających prowadzić jednocześnie projektowanie-optymalizację we wszystkich obszarach.

Rozwiązywanie oddzielnych zadań optymalizacyjnych w projektowaniu rozproszonym wydłuża znacznie proces projektowania konstrukcji kadłuba statku oraz bardzo ogranicza lub wręcz uniemożliwia skuteczne poszukiwanie zadowalających rozwiązań kompromisowych. Niemożliwe jest również w takim wypadku zbudowanie narzędzia obliczeniowego pozwalającego na automatyczne (bez udziału projektanta lub z jego ograniczonym bezpośrednim udziałem) generowanie projektów statków. Jeśli więc w przyszłości narzędzie takie ma powstać, powinno umożliwiać skuteczne rozwiązywanie zunifikowanych zadań optymalizacji kształtu–materiału–topologii–wymiaru (Sekulski 2009 a). Sekulski (2009 a, b) wykazał, że algorytmy genetyczne mogą być rozważane jako metoda umożliwiająca rozwiązywanie takiego zunifikowanego zadania optymalizacji.

Ponieważ zunifikowane zadania optymalizacji konstrukcji kadłuba statków morskich nie są jeszcze formułowane i rozwiązywane, dokonuje się prób racjonalnego projektowania konstrukcji kadłuba statków na drodze integrowania prac projektowych realizowanych w rozproszeniu. Odbywa się to przede wszystkim poprzez odpowiednie skoordynowanie prac projektowych oraz opracowywanie procedur wymiany informacji pomiędzy poszcze-

gólnymi zespołami realizującymi zadania szczegółowe. Próba zbudowania systemu integrującego projektowanie rozproszone konstrukcji statków morskich (DSS) był realizowany w latach 2006–2009 projekt IMPROVE finansowany z budżetu UE w ramach 6. programu ramowego (Giuglea i in. 2008, Rigo i in. 2010). Siedemnastu partnerów podjęło się opracowania kolejnych generacji trzech typów statków na podstawie systemu wspierania podejmowania decyzji, przy wykorzystaniu zaawansowanych technik analizy i syntezy na wczesnym etapie projektowania. Projekt dotyczył nowej generacji gazowców LNG i chemikaliowców oraz innowacyjnego rozwiązania dużego statku ro-pax. Konstrukcja, technologia wykonania, aspekty eksploatacyjne, funkcjonalność oraz wymogi bezpieczeństwa statku rozpatrywane były równocześnie. Osiągnięte rezultaty wykazały, że odpowiednio zintegrowane zespoły, realizujące w rozproszeniu cząstkowe zadania projektowe, miały wiele trudności i że zaplanowany cel nie został w pełni zrealizowany.

## **1.2. Ewolucyjna optymalizacja wielokryterialna**

Powszechnie akceptowanym rozwiązaniem zadania z wieloma sprzecznymi kryteriami oceny jest zbiór rozwiązań niezdominowanych w sensie Pareto<sup>4</sup>. W przypadku, gdy pełen front Pareto, zawierający oceny rozwiązań niezdominowanych, nie może być otrzymany, można zadowolić się jego przybliżeniem, to znaczy skończonym zbiorem rozwiązań niezdominowanych pokrywających go z akceptowalną rozdzielczością. Takie przybliżenie może być potraktowane przez decydenta jako źródło intuicji o charakterze konfliktu i możliwych kompromisach pomiędzy różnymi kryteriami. Na tej podstawie może on podjąć decyzję o wyborze kompromisu, który uzna za najbardziej zadowalający.

Do intensywniej rozwijających się w ostatnich latach obszarów poszukiwań skutecznych metod rozwiązywania wielokryterialnych zadań optymalizacyjnych należy ewolucyjna optymalizacja wielokryterialna (EMO). Algorytmy ewolucyjnej optymalizacji wielokryterialnej (MOEA) były z powodzeniem stosowane do rozwiązywania różnych zadań optymalizacji wielokryterialnej (Deb 2001, Coello Coello 2006). Prawie wszystkie dobrze znane MOEA, a przede wszystkim uważane za najsukcesowniej algorytmy NSGA-II (Deb i in. 2000) i SPEA2 (Zitzler i in. 2001, 2002) wykorzystują relację dominacji Pareto, łącznie z miarami skupienia, do szacowania funkcji przystosowania dla każdego wygenerowanego wariantu. W tym znaczeniu nazywa się je algorytmami opartymi na relacji dominacji Pareto (PDBA). Oparte na relacji Pareto algorytmy są zazwyczaj bardzo skuteczne w poszukiwaniu rozwiązań optymalnych Pareto lub rozwiązań leżących w pobliżu frontu Pareto w przypadku zadań z dwoma lub trzema kryteriami. Skuteczność tych algorytmów pogarsza się znacznie, gdy liczba kryteriów optymalizacji rośnie (Hughes 2003, 2005, Khara i in. 2003, Purshouse i Fleming 2003, Jaszkiwicz 2004, Ishibuchi i in. 2008 a, b). Powodem jest to, że w przypadku wielu kryteriów prawie wszystkie warianty w populacji okazują się wariantami niezdominowanymi. Jeśli zaś w populacji wszystkie warianty są niezdominowane, relacja dominacji Pareto nie może wytworzyć „ciśnienia” selekcyjnego w kierunku frontu Pareto. W takim

---

<sup>4</sup> Podstawowe koncepcje optymalizacji wielokryterialnej, w tym zaproponowaną przez Pareto koncepcję dominacji w wielokryterialnych problemach wyboru, omówiono w rozdziale 3 niniejszego opracowania.



przypadku w każdym algorytmie opartym na relacji dominacji Pareto wartości funkcji przystosowania szacuje się dla każdego wariantu tylko na podstawie miary skupienia wytwarzającej nacisk selekcyjny jedynie na zróżnicowanie zbioru generowanych wariantów, bez uwzględnienia położenia względem frontu Pareto. Zatem skuteczność metod założonych na relacji dominacji Pareto pogarsza się w przypadku wzrostu liczby kryteriów optymalizacji.

Hughes (2005) wykazał, że w przypadku zadań z wieloma kryteriami optymalizacji wielokrotne uruchomienie optymalizacji jednokryterialnej, z funkcją celu skalaryzującą kryteria optymalizacji, jest lepsze od pojedynczego uruchomienia ewolucyjnego algorytmu optymalizacji wielokryterialnej, wykorzystującego szeregowanie pod względem relacji dominacji Pareto. Podobne rezultaty uzyskał Jaszkievicz (2004). Purshouse i Fleming (2003) oraz Hughes (2005) wykazali zmniejszającą się wraz ze wzrostem liczby kryteriów skuteczność algorytmu NSGA-II (Deb i in. 2002). Wagner i in. (2007) potwierdzili pogorszenie się skuteczności zachowania uznanych algorytmów opartych na dominacji Pareto NSGA-II i SPEA2, dostrzeżone wcześniej przez Purshouse'a i Fleminga (2003) oraz Hughesa (2005). Wykazali szybkie pogorszenie skuteczności związane ze wzrostem liczby kryteriów, a nawet to, że algorytmy mogą w ogóle nie generować rozwiązań zbieżnych z frontem Pareto lub że mogą one utknąć daleko od niego. Wspomniane rezultaty badań sugerują, że użycie ewolucyjnych algorytmów optymalizacji wielokryterialnej, wykorzystujących w procesie selekcji atrybuty dominacji Pareto, może nie być skuteczne w przypadku poszukiwania rozwiązań problemów z czterema lub większą liczbą kryteriów oceny.

Podsumowując, Kruisselbrink i in. (2009) twierdzą, że pełne odwzorowanie przybliżenia frontu Pareto jest użyteczne, jednak w praktyce możliwe jest tylko w przypadku, gdy liczba kryteriów jest nie większa niż cztery.

Wykazano także, że w przypadku rozwiązywania wielokryterialnych zadań optymalizacyjnych z liczbą kryteriów większą niż trzy skuteczniejsze mogą być algorytmy skalaryzacji kryteriów oceny SFFA (Jaszkievicz 2002, 2004, Hughes 2003, 2005, 2007, Ishibuchi i Nojima 2006). SFFA mają wiele zalet, np. możliwość różnorodnego skalowania wielu kryteriów optymalizacji oraz wysoką zdolność rozwiązywania problemów optymalizacji kombinatorycznej. Ponadto szacowanie funkcji celu oparte na skalaryzacji kryteriów oceny wymaga znacznie mniej nakładów obliczeniowych w porównaniu z algorytmami opartymi na relacji dominacji Pareto. Zatem wydajność obliczeniowa jest kolejną zaletą SFFA.

Obiecującym kierunkiem, umożliwiającym zwiększenie skuteczności MOEA, jest także sprzęgnięcie ich z lokalnymi metodami poszukiwania (Ishibuchi i Murata 1996, Jaszkievicz 2002, 2004, Ishibuchi i in. 2003, Khara i in. 2003, Sindhya i in. 2008). W lokalnym poszukiwaniu w takich sprzęgniętych ewolucyjnych algorytmach optymalizacji wielokryterialnej wykorzystuje się zwykle skalaryzację funkcji celu, np. ważoną sumę w lokalnych algorytmach genetycznych (Ishibuchi i Murata 1998), lub skalaryzację ze współczynnikami wagowymi zależnymi od położenia ocenianego wariantu względem najlepszych i najgorszych rozwiązań w zbiorze (Sindhya i in. 2008). Łatwe jest również włączenie poszukiwania lokalnego do algorytmów opartych na skalaryzacji kryteriów oceny; włączenie poszukiwania lokalnego do algorytmów opartych na relacji dominacji Pareto zazwyczaj jest trudne. Wysoka zgodność z algorytmami lokalnymi jest zatem kolejną zaletą SFFA.

Kluczowe znaczenie w skutecznym zastosowaniu SFFA ma wybór odpowiedniego sposobu skalaryzacji. Powszechnie wiadomo, że metody ważonych celów są nieskuteczne w przypadku niewypukłego frontu Pareto, jednakże – jak sugerują Hang i Li (2007) – SFFA może być skuteczna w rozwiązywaniu MOOP w przypadku wypukłego frontu; jednak, gdy jest on niewypukły, poszukiwać należy innej metody szacowania funkcji przystosowania. W związku z tym kształt frontu Pareto może być dobrym wskaźnikiem określającym wybór metody skalaryzacji. Niestety, kształt frontu Pareto zazwyczaj nie jest znany przed rozpoczęciem obliczeń optymalizacyjnych, a do jego wyznaczenia potrzeba bardzo dużej liczby obliczeń, np. pojedynczych przebiegów z ustalonymi wartościami współczynników wagowych (problem można częściowo rozwiązać, stosując generowane losowo wartości współczynników wagowych).

Wydaje się, że SFFA mogą być skuteczne, gdy bieżąca populacja jest odległa od frontu Pareto, nawet jeśli jego kształt nie jest wypukły. Jeśli populacja zbliża się do niewypukłego frontu Pareto, skuteczniejsze mogą być inne metody szacowania funkcji przystosowania. Można również dla osobników w tej samej populacji stosować SFFA, jeśli są odległe od niewypukłej części frontu, a inne metody szacowania, jeśli leżą w jego pobliżu.

MOEA zazwyczaj skutecznie znajdują rozwiązania optymalne Pareto lub im bliskie, zlokalizowane wokół centralnych obszarów frontu Pareto zadań dwukryterialnych. Jednak nie zawsze okazują się skuteczne w znalezieniu dobrych rozwiązań leżących w pobliżu jego krawędzi. Metodą zmniejszenia tych trudności może być większe zróżnicowanie rozwiązań uzyskiwane poprzez zwiększenie wartości prawdopodobieństwa krzyżowania i prawdopodobieństwa mutacji. Jednak ceną za większe zróżnicowanie rozwiązań w pobliżu krawędzi frontu Pareto jest gorsze dopasowanie zbioru rozwiązań do prawdziwego frontu.

W obszarze ewolucyjnej optymalizacji wielokryterialnej rozwiązano dotychczas wiele zadań testowych i praktycznych dla dwu- lub trzykryterialnych zadań optymalizacyjnych. Zadania uwzględniające więcej niż trzy kryteria, które nazywa się także problemami z dużą liczbą kryteriów (MOP) – Farina i Amato (2002), próbowano rozwiązywać bardzo rzadko (Wagner i in. 2007). Przewiduje się, że wiele metod skutecznych w rozwiązywaniu zadań uwzględniających niewielką liczbę kryteriów nie będzie tak skutecznych w przypadku zadań z wieloma kryteriami. Zatem MOP stanowią znacznie większe wyzwanie niż rozwiązywane dotychczas wielokryterialne zadania optymalizacyjne (MOOP).

Procedury selekcji wykorzystywane w MOEA wymagają odwzorowania wektora celów (wektora ocen) do odpowiedniej wielkości wprowadzającej porządek w ocenianym zbiorze rozwiązań. MOEA zawierają zwykle dwa operatory selekcji. Zasadniczy operator selekcji oparty jest na relacji dominacji Pareto i preferuje rozwiązania niezdominowane przed rozwiązaniami zdominowanymi. Drugi operator umożliwia zachowanie zróżnicowania i klasyfikowanie rozwiązań, które nie mogą być porządkowane według relacji dominacji (np. rozwiązania niedopuszczalne)<sup>5</sup>. Przy takich metodach realizowania operacji selekcji relacja

---

<sup>5</sup> W propozycji autora funkcja przystosowania reprezentuje takie dwa operatory selekcji; suma kryteriów oceny określana jest dla wszystkich generowanych wariantów konstrukcji; atrybuty dominacji i odległość od rozwiązania asymptotycznego określone są dodatkowo jedynie dla wariantów dopuszczalnych.

dominacji Pareto może nie być istotna jako założenie podstawowego operatora selekcji, z powodu dużej liczby rozwiązań, które nie mogą być ze sobą porównywane. Znaczenie drugiego mechanizmu selekcji rośnie wraz ze wzrostem wymiaru przestrzeni celów od momentu, gdy operator selekcji opartej na relacji dominacji Pareto coraz mniej skutecznie rozróżnia selekcyjonowane warianty.

W tym miejscu należy stwierdzić, że ewolucyjne algorytmy optymalizacji wielokryterialnej, skalaryzujące kryteria oceny, były pierwszymi próbami wykorzystania algorytmów ewolucyjnych do rozwiązywania MOOP (Schaffer 1985, Murata i Ishibuchi 1995). Jednak po opracowaniu skutecznych metod wykorzystujących atrybuty dominacji Pareto metody skalaryzujące zostały potraktowane jako zakończony etap rozwoju MOEA i nie były w istotny sposób rozwijane. Omówione wyniki badań wskazują jednak na uzasadnioną potrzebę powrotu do tej grupy metod i ponownego podjęcia prób opracowania skutecznych MOEA, wykorzystujących w procesie selekcji skalarne funkcje celu (skalaryzujące kryteria optymalizacji) z ewentualnym połączeniem z innymi strategiami wspomagającymi szacowanie funkcji przystosowania.

### **1.3. Problem badawczy, cel i zakres pracy**

Dokonany przegląd problematyki optymalizacji konstrukcji kadłuba statków morskich oraz problematyki ewolucyjnej optymalizacji wielokryterialnej wskazuje na to, że (1) istnieje potrzeba formułowania oraz skutecznego rozwiązywania, na etapie projektu wstępnego, zunifikowanych zadań wielokryterialnej optymalizacji konstrukcji kadłuba statków morskich oraz że (2) istnieje potrzeba opracowania skutecznych ewolucyjnych algorytmów optymalizacji wielokryterialnej konstrukcji kadłuba statków morskich, wykorzystujących w procesie selekcji, oprócz atrybutów dominacji w odniesieniu do relacji dominacji Pareto, także skalaryzację kryteriów optymalizacji, ponieważ algorytmy takie mogą okazać się skuteczne w przypadku rozwiązywania zadań z wieloma, tzn. z więcej niż trzema, kryteriami optymalizacji.

Autor zaproponował metodę optymalizacji wielokryterialnej, w której algorytm optymalizacyjny wykorzystuje własną koncepcję sformułowania kombinowanej funkcji celu integrującej w jednym wyrażeniu, oprócz kryteriów optymalizacji, także atrybuty dominacji w odniesieniu do relacji dominacji Pareto. Po sformułowaniu koncepcji kombinowanej funkcji celu autor sformułował następujące pytania: (1) czy ewolucyjny algorytm optymalizacji wielokryterialnej z kombinowaną funkcją celu może być skuteczny do rozwiązania zunifikowanego zadania optymalizacji wymiarów i topologii elementów konstrukcyjnych kadłuba statku morskiego na etapie projektu wstępnego?, (2) w jaki sposób algorytm obliczeniowy budować będzie zbiór rozwiązań niezdominowanych przybliżających front optymalny Pareto?, (3) w jaki sposób przeprowadzać ocenę jakości otrzymanych rezultatów – zbiorów przybliżających?, (4) w jaki sposób przeprowadzać ocenę skuteczności obliczeniowych algorytmów optymalizacyjnych?

Dostrzeżone potrzeby oraz postawione pytania pozwoliły na sformułowanie następującego problemu badawczego, stanowiącego podstawę niniejszej pracy: czy ewolucyjny algorytm optymalizacji wielokryterialnej, wykorzystujący narzędzia algorytmów genetycznych oraz sformułowaną w pracy skalarną funkcję celu ujmującą w jednym wyrażeniu kry-

teria oceny oraz atrybuty dominacji, może być skuteczny w rozwiązywaniu zunifikowanych częściowo zadań wielokryterialnej optymalizacji wymiarów elementów oraz topologii konstrukcji kadłuba statków morskich na etapie projektu wstępnego?

Z przedstawionego problemu badawczego wynika cel ogólny pracy, którym było opracowanie metody modelowania wielokryterialnego procesu decyzyjnego na etapie projektu wstępnego konstrukcji kadłuba statku morskiego oraz wskazanie, w jaki sposób podejmujący decyzje, dotyczące projektu konstrukcji kadłuba statku (projektant, decydent), może uzyskać za pomocą zastosowanej metody (ewolucyjnego algorytmu optymalizacji wielokryterialnej z kombinowaną funkcją celu) pogląd na temat decyzji ekstremalnych (np. o najmniejszych lub największych wartościach kryteriów oceny) i rozwiązań kompromisowych, aby następnie – przy uwzględnieniu dodatkowych warunków nieuwzględnionych w wykorzystanych algorytmach, swojego doświadczenia oraz intuicji – podjąć decyzję w sposób najbardziej uzasadniony. Przedstawiony w sposób ogólny cel pracy można uszczegółowić w postaci (1) celu poznawczego, badawczego, oraz (2) celu użytecznego, praktycznego.

Celem poznawczym pracy jest zbadanie, czy ewolucyjny algorytm optymalizacji wielokryterialnej z kombinowaną funkcją celu może być skutecznym narzędziem służącym do rozwiązania częściowo zunifikowanego zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku na etapie projektu wstępnego.

Celem użytecznym pracy jest opracowanie metody oraz narzędzia obliczeniowego umożliwiającego skuteczne rozwiązanie zunifikowanych zadań optymalizacji wymiarów elementów i topologii konstrukcji kadłuba statku morskiego na etapie projektu wstępnego, a także opracowanie metody oceny jakości osiągniętych wyników oraz skuteczności algorytmów obliczeniowych.

Celami pośrednimi procesu badawczego są: (1) rozważania teoretyczne dotyczące metod formułowania i rozwiązywania zadań optymalizacji wielokryterialnej, (2) opracowanie algorytmu ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, (3) opracowanie szczegółowych technik obliczeniowych, (4) opracowanie procedur obliczeniowych kontroli sformułowanych ograniczeń, (5) opracowanie metod śledzenia ewolucji populacji podczas symulacji, (6) opracowanie metod oceny jakości zbiorów przybliżających, (7) opracowanie metod oceny skuteczności algorytmów optymalizacji wielokryterialnej, (8) zbudowanie narzędzia obliczeniowego systemu programów komputerowych, (9) opracowanie modeli obliczeniowych konstrukcji kadłuba statku, (10) zaplanowanie symulacji komputerowych, (11) przeprowadzenie symulacji komputerowych, (12) przeanalizowanie wyników symulacji komputerowych, (13) sformułowanie wniosków i podsumowanie przeprowadzonych badań.

Zakres pracy ograniczono do pierwszego kroku unifikacji zadania optymalizacji konstrukcji kadłuba statku, czyli do sformułowania i rozwiązania zunifikowanego zadania optymalizacji topologii–wymiaru elementów konstrukcyjnych. Przeprowadzono szczegółową analizę podstaw teoretycznych i praktycznych zastosowań ewolucyjnych algorytmów optymalizacji wielokryterialnej w projektowaniu konstrukcji kadłuba statku. Odpowiedziano na pytanie, czy wybrana metoda optymalizacyjna może być zastosowana do rozwiązania sformułowanego zadania optymalizacji konstrukcji kadłuba statków morskich. Sformułowano założenia ewolucyjnego algorytmu optymalizacji wielokryterialnej do skutecznej optymalizacji

zacji konstrukcji statków na etapie projektowania wstępnego. Opracowane procedury obliczeniowe przedstawiono w postaci systemu programów komputerowych. Zbudowane narzędzie obliczeniowe zastosowano do serii symulacji komputerowych na opracowanym specjalnie modelu konstrukcji kadłuba wybranego statku morskiego. Wyniki symulacji, w tym w szczególności jakość uzyskanych zbiorów rozwiązań niezdominowanych oraz skuteczność algorytmów obliczeniowych, szczegółowo przedyskutowano i wykorzystano jako założenie do sformułowania ogólnych wniosków dotyczących skuteczności opracowanej metody.

Przystępując do realizacji sformułowanych celów, przyjęto następujące założenia: (1) przedmiotem badań będzie morski statek towarowy, (2) praca dotyczyć będzie konstrukcji kadłuba statku, (3) ilość informacji o projekcie oraz stopień złożoności analiz wytrzymałościowych będą właściwe dla projektu wstępnego, (4) modele oraz procedury obliczeniowe będą właściwe dla kadłuba statku wykonanego z materiałów metalowych, (5) do rozwiązania wielokryterialnego zadania optymalizacji wykorzystana zostanie koncepcja dominacji Pareto, (6) do formułowania ograniczeń wytrzymałościowych z punktu widzenia wytrzymałości ogólnej i lokalnej wykorzystane zostaną przepisy towarzystwa klasyfikacyjnego, (7) opracowana metoda zostanie zweryfikowana za pomocą symulacji komputerowych, (8) symulacje przeprowadzone zostaną na jednym przykładzie statku – demonstratorze.

W celu potwierdzenia skuteczności opracowanej metody oraz zbudowanego narzędzia obliczeniowego zastosowana zostanie technika symulacji komputerowej, ponieważ zdaniem autora: (1) brakuje właściwej metody analitycznego rozwiązywania problemu wielokryterialnej optymalizacji konstrukcji kadłuba statku; (2) dostępna jest dostateczna liczba danych i informacji o modelowanej konstrukcji kadłuba statku, przy dokładności odpowiedniej dla projektu wstępnego, a zatem istnieje możliwość zapewnienia realizmu modelu obliczeniowego; (3) ewolucyjna optymalizacja wielokryterialna wymaga wykonania wielu obliczeń, a zastosowanie komputera znacznie przyspiesza uzyskanie informacji o poszukiwanym zbiorze przybliżającym; (4) rozpatrzone inne sposoby rozwiązania są nieodpowiednie, co oznacza, że w przypadku sformułowanego problemu nie można zastosować ani obserwacji na rzeczywistych obiektach, ani eksperymentu fizycznego; (5) symulacja procesu optymalizacji, czyli poszukiwania zbioru przybliżającego, może dostarczyć cennych i pouczających informacji o procesach zachodzących w zbiorach przybliżających, których nie można byłoby uzyskać za pomocą innych metod badawczych, np. badań empirycznych na rzeczywistych obiektach lub eksperymentów na modelach fizycznych.

Dokonany przegląd opublikowanych prac różnych autorów wskazuje, że wielokryterialna optymalizacja konstrukcji kadłuba statku morskiego nie jest często podejmowanym tematem badań i że nieliczne są jej praktyczne zastosowania w projektowaniu konstrukcji kadłuba statków morskich. Napotykanie trudności, związane przede wszystkim z formułowaniem odpowiednio szczegółowych modeli optymalizacyjnych oraz z budową skutecznych metod obliczeniowych, powodują, że problemy te są przedmiotem zainteresowania przede wszystkim ośrodków badawczych. Brakuje także systematycznych badań skuteczności ewolucyjnych algorytmów optymalizacji wielokryterialnej do optymalizacji konstrukcji kadłuba statków morskich.

W rozdziale 2 omówiono zasadnicze grupy zadań optymalizacyjnych rozwiązywanych w procesie projektowania konstrukcji statków. Zwrócono uwagę na istniejące odseparowanie poszczególnych obszarów optymalizacji konstrukcji i potrzebę unifikacji takich zadań. Omó-

wiono wybrane metody i narzędzia obliczeniowe wykorzystywane do optymalizacji konstrukcji statków. Uzasadniono wybór algorytmów genetycznych jako metody rozwiązywania sformułowanego w pracy zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku.

W rozdziale 3 przedstawiono podstawowe koncepcje optymalizacji wielokryterialnej, ogólne sformułowanie zadań optymalizacji wielokryterialnej oraz szczegółowo omówiono możliwe do sformułowania warianty relacji dominacji Pareto, mającej zasadnicze znaczenie w poszukiwaniu rozwiązań wielokryterialnych zadań optymalizacji. Przyjęto, że rozwiązaniem zadania optymalizacji wielokryterialnej jest zbiór przybliżający front rozwiązań optymalnych w sensie Pareto.

W rozdziale 4 przedstawiono klasyczne i ewolucyjne metody optymalizacji wielokryterialnej. Szczególną uwagę zwrócono na atrybuty dominacji jako skuteczne narzędzie badań wewnętrznej struktury zbioru rozwiązań dopuszczalnych.

W rozdziale 5 przedyskutowano rzadko poruszany w literaturze problem oceny jakości rezultatów optymalizacji wielokryterialnej zbiorów przybliżających. Szczegółowo omówiono koncepcję wskaźników jakości oraz sformułowano koncepcję wektorowych wskaźników jakości.

W rozdziale 6 przedstawiono zbudowany system programów komputerowych, stanowiący narzędzie obliczeniowe służące do ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku. Szczegółowo omówiono oryginalne techniki obliczeniowe oraz koncepcję procedury oceny jakości uzyskanych rozwiązań oraz algorytmów obliczeniowych.

W rozdziale 7 przedstawiono szczegółowo proces formułowania zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku, zmierzający do opracowania modelu umożliwiającego zastosowanie zbudowanego narzędzia obliczeniowego.

W rozdziale 8 przedstawiono program, przebieg oraz rezultaty obliczeń badawczych. Celem przeprowadzenia serii symulacji komputerowych było sprawdzenie skuteczności zaproponowanych algorytmów ewolucyjnej optymalizacji wielokryterialnej oraz opracowanego narzędzia obliczeniowego.

W rozdziale 9 przedyskutowano szczegółowo jakość rozwiązań uzyskanych w trakcie obliczeń oraz oceniono skuteczność zastosowanych algorytmów optymalizacyjnych.

W rozdziale 10 dokonano podsumowania i sformułowano ogólne wnioski. W rozdziale 11, kończącym pracę, wskazano kierunki dalszych badań.

Pracę uzupełniają załączniki oraz wykaz wykorzystanej literatury.

## 2. Problem optymalizacji konstrukcji kadłuba statków morskich

### 2.1. Specyfika problemów optymalizacji

Zadanie optymalizacji konstrukcji kadłuba statków morskich (KKSM) można sformułować w następujący sposób: znaleźć zbiór wartości zmiennych konstrukcyjnych  $\mathbf{x}$ , reprezentujących materiał konstrukcyjny, rozmieszczenie przestrzenne elementów konstrukcyjnych oraz wymiary elementów konstrukcyjnych, dla którego zadana funkcja celu  $f(\mathbf{x})$  przyjmuje wartość ekstremalną, przy skończonej liczbie ograniczeń nałożonych na wartości zmiennych konstrukcyjnych. Można dodatkowo sformułować wymaganie, aby wszystkie występujące w zadaniu optymalizacji funkcje były funkcjami rzeczywistymi. Ponieważ maksimum funkcji  $f$  jest jednocześnie minimum funkcji  $-f$ , ogólne sformułowanie zadania optymalizacji konstrukcji można podać w postaci matematycznej:

$$\begin{array}{ll} \text{dla zmiennych konstrukcyjnych} & \mathbf{x} = [x_1 \ x_2 \ \dots \ x_i \ \dots \ x_n]^T: x_{i,min} \leq x_i \leq x_{i,max} \\ & i = 1, 2, \dots, n \\ \text{zminimalizować} & f(\mathbf{x}) \\ \text{spełniając ograniczenia} & h_k(\mathbf{x}) = 0, k = 1, 2, \dots, K \\ & g_j(\mathbf{x}) \geq 0, j = 1, 2, \dots, J \end{array} \quad (2.1)$$

Specyfika projektowania i optymalizacji KKSM powoduje, że formułowane zadania optymalizacji mają także pewne szczególne cechy podane w następujących akapitach.

Nie wszystkie kryteria oceny i ograniczenia mogą być wyrażone wprost jako funkcje zmiennych konstrukcyjnych  $\mathbf{x}$ . W konsekwencji model matematyczny projektowania optymalnej KKSM może reprezentować wielostopniowy proces obliczeń, wykorzystujący różne narzędzia analizy. Stwierdzenie to narzuca przy rozwiązywaniu zadania znaczne ograniczenia dostępnym algorytmom optymalizacji, które realizuje się w systemach komputerowych z bardzo ograniczonym udziałem użytkownika na etapie obliczeń. Niesprecyzowany model funkcji celu utrudnia zastosowanie sformalizowanych metod optymalizacyjnych oraz zwykle wymaga numerycznej aproksymacji pochodnych funkcji, co jest wadą wszystkich metod wymagających obliczania gradientów funkcji.

Bardzo duże skomplikowanie KKSM i konieczność odpowiednio dokładnego reprezentowania konstrukcji jako całości oraz poszczególnych rejonów konstrukcyjnych, składających się na tę konstrukcję, powoduje konieczność formułowania zadania optymalizacji z dużą liczbą zmiennych konstrukcyjnych.

Podstawowe, z punktu widzenia projektowania KKSM, wielkości, takie jak grubość blach poszycia i wymiary profili walcowanych, ograniczone są do skończonej liczby podawanej w handlowych katalogach wyrobów hutniczych. Drugą grupą wielkości, o wartościach zawartych w zbiorach skończonych, są liczby wiązań podpierających poszycie w poszczególnych rejonach konstrukcyjnych, np. liczba odstępów wręgowych, liczba wzdłużni-

ków dennych. Część zmiennych konstrukcyjnych może być ciągła, lecz można przyjąć, że są one zmiennymi dyskretnymi, takimi jak wysokość środników i szerokość mocników wiązarów spawanych. Odległość między wiązaniami (odstęp wręgowy) ze swojej natury jest ciągłą zmienną projektową. Jednak przy projektowaniu KKSM trzeba mieć na względzie ograniczenia technologiczne i ekonomiczne, dlatego wartości odstępu wręgowego wybiera się z zadanego zbioru wartości zalecanych. Odstępem wręgowym można posługiwać się jak wielkością pseudodyskretną. Odległość między wiązaniami w zadanym przedziale konstrukcyjnym określona jest przez ich liczbę. W tym wypadku również ona jest zmienną dyskretną. Można więc stwierdzić, że projektowanie KKSM jest dyskretnym zadaniem poszukiwania najlepszej konstrukcji w skończonym zbiorze wariantów dopuszczalnych. Dyskretność zadania wyklucza możliwość zastosowania metod opartych na rachunku różniczkowym.

W projektowaniu KKSM podstawowe kryteria i ograniczenia wyprowadzane są z analizy wytrzymałościowej i zazwyczaj mają nieliniowy charakter w odniesieniu do zmiennych konstrukcyjnych. Nieliniowy charakter zależności funkcyjnych stwarza duże trudności w zastosowaniu rachunku różniczkowego.

Optymalizacja tak złożonego systemu technicznego, jakim jest konstrukcja KKSM, realizowana jest zazwyczaj pod względem wielomodalnych funkcji oceny. Wówczas globalnemu optimum towarzyszy nieznana liczba optimumów lokalnych. Nawet, jeśli same funkcje oceny są jednomodalne, ograniczenia zadania optymalizacji mogą być wielomodalne. W takim przypadku nieefektywne są lokalne metody optymalizacji bardzo zależne od wyboru punktu początkowego. Poszukiwać należy globalnej metody optymalizacji, która umożliwi odnalezienie optimum lub bliskiego otoczenia optimum.

W niektórych przypadkach ograniczenia mogą podzielić przestrzeń poszukiwań na osobne części. Wówczas deterministyczne algorytmy optymalizacji mogą nie być zdolne do przekroczenia nieciągłości pomiędzy różnymi częściami przestrzeni poszukiwań.

Formułowane ograniczenia równościowe są bardzo rygorystyczne i w skrajnych przypadkach mogą spowodować, że zadania optymalizacji nie będą miały żadnego rozwiązania. Jednak, jeśli jest to możliwe, należy sprawdzić, czy można zastosować ograniczenia równościowe, by usunąć część zmiennych konstrukcyjnych przez uzależnienie ich od innych zmiennych. W ten sposób można zmniejszyć wymiarowość zadania i jednocześnie zwiększyć prawdopodobieństwo uzyskania zadowalającego rozwiązania.

Projektowanie KKSM może wymagać rozwiązania wielokryterialnych zadań optymalizacji, z którymi związane jest pojęcie rozwiązania w rozumieniu optimum Pareto. W takim wypadku polepszanie niektórych kryteriów oceny pogarsza inne, w związku z czym projektant musi zdecydować się na wybór rozwiązania kompromisowego.

Okres eksploatacji statków morskich wynosi zazwyczaj ok. 20–30 lat. W tym czasie konstrukcja kadłuba ulegać może znacznym zmianom pod wpływem czynników związanych z eksploatacją. Część z nich, nazywanych obciążeniami, działa na konstrukcję w postaci sił i momentów sił generowanych przez środowisko, ładunek, zapasy i wyposażenie. Część z nich, nazywanych narażeniami, związana nie z działaniem sił, ale z działaniem pól fizycznych (np. niskiej lub wysokiej temperatury) oraz związków chemicznych (np. korozyjnego oddziaływania wody morskiej, korozyjnego oddziaływania ładunku). Pomijając przebudowy



i modernizacje, które można uznać za celowe i kontrolowane zmiany konstrukcji kadłuba, obciążenia i narażenia powodują niepożądane zmiany, którymi są odkształcenia i ubytki materiałowe. Uogólniając, KKSM ulega z upływem czasu osłabieniu, powodując wzrost prawdopodobieństwa awarii. W procesie optymalizacji KKSM należałoby zatem formułować i rozwiązywać zadania optymalizacji konstrukcji, której charakterystyki zmieniają się w czasie. Ze względu na trudności, wynikające przede wszystkim z braku odpowiednich danych pochodzących z eksploatowanych statków, nie formułuje się zadań zależnych od czasu.

Podczas projektowania KKSM dane o geometrycznych i fizycznych cechach konstrukcji oraz dane o obciążeniach eksploatacyjnych przyjmuje się w postaci deterministycznych wielkości liczbowych. Tymczasem w rzeczywistości są one wielkościami probabilistycznymi. Powszechnie stosowane podejście deterministyczne można uważać za przybliżenie podejścia probabilistycznego. KKSM powinna być zatem optymalizowana z uwzględnieniem probabilistycznej natury wielkości opisujących obciążenie i wydolność konstrukcji. W projektowaniu KKSM z sukcesem podjęto już pewne próby probabilistycznego projektowania konstrukcji. Nie podjęto dotychczas podobnych prób w przypadku probabilistycznej optymalizacji konstrukcji.

Zmienne konstrukcyjne, reprezentujące właściwości materiału konstrukcyjnego, zwykle są zmiennymi dyskretnymi, ponieważ wybór dokonywany jest z pewnego skończonego zbioru zawierającego określony asortyment wyrobów. Jeżeli rozpatruje się małą liczbę przewidywanych materiałów, najbardziej efektywna okazuje się optymalizacja przeprowadzona oddzielnie dla każdego materiału, a następnie porównanie otrzymanych rezultatów optymalizacji częściowych. Najbardziej odpowiednim sposobem wykorzystania metod optymalizacji przy wyborze materiału jest więc uzyskanie kilku niezależnych rozwiązań, przy zadanych wartościach zmiennych opisujących mechaniczne właściwości materiału.

Zadania projektowania KKSM zawierają wiele zmiennych konstrukcyjnych, o wartościach zawartych w dużym zakresie zmienności. Oznacza to bardzo dużą liczbę zbioru wariantów możliwych w danej przestrzeni rozwiązań. W takim przypadku zastosowanie metod systematycznego lub losowego przeszukiwania przestrzeni rozwiązań jest bardzo nieefektywne pod względem czasu i w praktyce nie do przyjęcia.

Można zetknąć się z cechami optymalizowanej konstrukcji, które nie mogą być przedstawione w postaci liczbowej, takimi jak: komfort pomieszczeń, estetyczna bryła architektoniczna. W przypadku takich niemierzalnych wielkości można zastosować metody wnioskowania rozmytego.

Podsumowując powyższą dyskusję, można przyjąć, że po dokonaniu niezbędnych uproszczeń podstawowymi cechami formułowanych zadań optymalizacji KKSM są: nieliniowość funkcji celu (rzadziej) i funkcji ograniczeń; duża liczba zmiennych konstrukcyjnych; nieciągłość (dyskretność) większości zmiennych konstrukcyjnych; możliwość wystąpienia optimum lokalnych w przestrzeni rozwiązań i brak przesłanek do zlokalizowania obszaru wystąpienia optimum globalnego; potrzeba sformułowania więcej niż jednego kryterium oceny; interdyscyplinarność sformułowanych ograniczeń, takich jak wytrzymałość, nośność graniczna, odporność kolizyjna, niezawodność, technologiczność, koszt budowy, naprawialność; brak zmienności cech konstrukcji w czasie, przede wszystkim pomijanie ubytków korozyjnych


blach i profili; deterministyczne związki pomiędzy wartościami funkcji reprezentujących kryteria optymalizacji i ograniczenia oraz pomiędzy zmiennymi konstrukcyjnymi.

Dyskusja nad optymalizacją KKSM powinna być ściśle związana z określeniem etapu projektowania statku, na jakim optymalizacja ta ma być prowadzona. Jeśli celem jest projekt koncepcyjny, optymalizacja (narzędzia obliczeniowe i kryteria optymalizacji) będą zupełnie inne niż wówczas, gdy optymalizacja będzie przeprowadzana na etapie projektu technicznego. Oczywiście jest to, że wraz z postępem procesu projektowania dostępnych jest coraz więcej informacji, jednocześnie jednak coraz bardziej rosną koszty poprawek usuwających skutki popełnionych błędów. Im więcej jest dostępnej rzetelnej wiedzy technicznej i ekonomicznej, tym większa jest szansa na podejmowanie racjonalnych i trafnych decyzji projektowych. Koncepcję tę ilustruje rysunek 2.1 przedstawiający klasy podejmowanych decyzji oraz zmniejszającą się możliwość wpływania na wynik projektowania.

Najważniejsze strategiczne decyzje (ang. *strategic decisions*) podejmowane są w pierwszych, wstępnych, fazach projektowania. Nie ma sformalizowanych narzędzi podejmowania decyzji strategicznych. Zazwyczaj podejmowane są one heurystycznie na podstawie dotychczasowych doświadczeń. Decyzje te określają zasadnicze cechy projektowanej konstrukcji i określają sposób projektowania i budowy. Bardzo rzadko ulegają zmianom pod wpływem wyników osiągniętych w kolejnych etapach projektowania. Decyzje te mają największy zasięg przestrzenny (dotyczą całego kadłuba statku) i czasowy (obowiązują w całym okresie życia statku). Decyzjami strategicznymi mogą być wybór materiału konstrukcyjnego, wybór układu wiązań, wybór odstępów wręgowego. Następujące po tym etapie projektowanie szczegółowe (techniczne) to czas podejmowania decyzji taktycznych (ang. *tactical decisions*), wspierających decyzje strategiczne. Zasięg tych decyzji, znaczenie i konsekwencje są mniejsze. Oto przykłady decyzji taktycznych: jeśli podjęto strategiczną decyzję o budowie konstrukcji ze stali, to decyzją taktyczną będzie decyzja o wyborze określonego gatunku stali; jeśli podjęto decyzję o wyborze mieszanego układu wiązań konstrukcji kadłuba, to decyzją taktyczną może być wybór wartości odstępów wręgowego oraz wartości odstępów usztywnień wzdłużnych w poszczególnych rejonach. Decyzje takie podejmowane są częściej od decyzji strategicznych, przy czym możliwe są ich zmiany w trakcie projektowania – np. można zastosować różne gatunki stali w różnych rejonach kadłuba statku.

Decyzje operacyjne (ang. *operational decision*) podejmowane są bardzo często. Mówiąc kolokwialnie, są to decyzje codzienne wspierające decyzje taktyczne. Podejmowane są one na podstawie bardzo krótkich analiz i w bardzo krótkim czasie. Konsekwencje podjęcia błędnych decyzji operacyjnych są najmniejsze, a skutki – łatwe do usunięcia. Decyzje operacyjne mogą być wsparte ścisłymi algorytmami, narzędziami obliczeniowymi i sformułowanymi wymaganiami o charakterze normatywnym. Decyzjami operacyjnymi mogą być przede wszystkim decyzje dotyczące wyboru wymiarów wiązań, podejmowane na podstawie wymagań towarzystw klasyfikacyjnych. Decyzją operacyjną może być także zmiana konstrukcji na podstawie numerycznych obliczeń drgań konstrukcji w celu uniknięcia niepożądanych częstotliwości rezonansowych.

Można spróbować zidentyfikować miejsce i zadania optymalizacji KKSM (ang. *ship hull structure optimization*) w odniesieniu do optymalizacji statku (ang. *ship optimization*).



Rys. 2.1. Główne fazy projektowania oraz klasy podejmowanych decyzji w projektowaniu konstrukcji kadłuba statków morskich

Optymalizacja statku jest rodzajem naturalnego, oczywistego, zadania, jakie projektant stara się rozwiązać podczas różnych pętli spirali projektowej. Spirala projektowa jest ostatecznie procesem optymalizacji. Każda pętla może być traktowana jako iteracja procesu optymalizacyjnego. Jednak według wielu specjalistów w każdym kroku projektowania optymalizacja okazuje się optymalizacją lokalną (ang. *local optimization*).

Przez optymalizację lokalną rozumieć należy optymalizację przeprowadzaną w pojedynczym specyficznym obszarze projektowania statków (takim jak: hydrodynamika, napęd, podłóg, konstrukcja, bezpieczeństwo); prace projektowe prowadzone w pozostałych obszarach są w tym czasie zamrożone. Na przykład bardzo często kształt kadłuba i rozplanowanie przestrzenne traktuje się jako ustalone, jeśli optymalizuje się konstrukcję kadłuba statku (wymiały elementów konstrukcyjnych, ang. *scantling*) w celu obniżenia ciężaru i/lub kosztów produkcji.

Oczywiście, można zadać pytanie: Czy uzasadnione jest mówienie o optymalizacji globalnej i lokalnej tylko w przypadku projektowania konstrukcji kadłuba statku? Postawione pytanie może również brzmieć nieco inaczej: Czy można projektowanie konstrukcji kadłuba statku rozdzielić na zadania, rozwiązywane następnie niezależnie od pozostałych? Wydaje się, że jest to możliwe. Na przykład jeden zespół opracowuje projekt konstrukcji na podstawie wymagań przepisów klasyfikacyjnych, następnie różne zespoły mogą weryfikować ten projekt poprzez np. numeryczne obliczenia wytrzymałości ogólnej, numeryczne obliczenia wytrzymałości zmęczeniowej, obliczenia nośności granicznej, obliczenia wytrzymałości w stanach awaryjnych (kolizje, wejście na mieliznę, wybuch itd.), numeryczną analizę drgań, technologię wykonania. Wiele z tych czynności można wykonywać równocześnie na przygotowanych wcześniej modelach. Otrzymane rezultaty mogą wpłynąć na przepisowe wymiały wiązań. Odpowiednia wymiana danych umożliwia aktualizację modelu wyjściowego *on line* i prowadzenie analiz na stale zmieniającej się aktualnej wersji modelu.

Lokalna optymalizacja stała się praktyką przemysłową ok. 20–25 lat temu, gdy dostępne stały się wyspecjalizowane zaawansowane narzędzia do obliczeń numerycznych, w jednym zadaniu projektowym, np. (1) w modyfikacji kształtu kadłuba w celu zwiększenia szybkości, zmniejszenia zużycia paliwa lub polepszenia właściwości morskich; (2) w ulepszeniu konstrukcji kadłuba w celu zmniejszenia ciężaru lub kosztów produkcji; (3) w zmianie rozplanowania przestrzenno-architektonicznego, rozplanowania ogólnego w celu zwiększenia bezpieczeństwa (drogi ewakuacji), zwiększenia liczby kabin pasażerskich.<sup>1</sup>

Przeprowadzenie optymalizacji globalnej przy obecnych technologiach dostępnych w przemyśle okrętowym nie wydaje się możliwe. Rozwiązaniem jest przeprowadzenie serii optymalizacji lokalnych (ang. *local optimization*); tak to się dzisiaj robi.

Na tym tle obiecującym kierunkiem prac badawczych jest rozwój platform optymalizacji współbieżnej, w której kilka lub kilkanaście narzędzi obliczeniowych pracuje jednocześnie, używając tych samych danych i na podstawie tego samego projektu początkowego (geometria, obciążenia itd.). Optymalizacja taka może być krokiem pośrednim pomiędzy sekwencją następujących po sobie optymalizacji lokalnych a globalną optymalizacją (której zrealizowanie wydaje się trudnym do osiągnięcia celem jeszcze przez długi czas).

Optymalizacja globalna wymaga sformułowania i rozwiązania zadań optymalizacji unifikujących do jednej formy cząstkowe zadania optymalizacji rozwiązywane w procesach optymalizacji lokalnej.

W ramach zarysowanych współbieżnej i wielodyscyplinarnej optymalizacji statku praca niniejsza prezentuje wizję autora dotyczącą ograniczonego obszaru, którym jest optymalizacja konstrukcji kadłuba statku.

## 2.2. Algorytmy rozwiązania zadania optymalizacji

Przedstawiona w poprzednim podrozdziale dyskusja nad podstawowymi cechami zadania optymalizacji KKSMM powinna być założeniem podczas wyboru algorytmu optymalizacji skutecznie rozwiązującego takie zadanie. Liczba znanych i stosowanych algorytmów optymalizacyjnych jest bardzo duża, a podręczniki, monografie i czasopisma rejestrują zazwyczaj jedynie ich rodzaj, podając pewne ogólne właściwości. Na przykład Fox (1971), Gallagher i Zienkiewicz (1973), Goliński (1974), Findeisen i in. (1980), Reklaitis i in. (1983), Brandt i in. (1984), Vanderplaats (1984), Haftka i Kamat (1985), Fletcher (1987), a także autorzy pracy *Multiobjective Optimization in Engineering and in the Sciences* (1988), Statnikov i Matosov (1995), Rao (1996), Stadnicki (2006) oraz Kusiak i in. (2009) zaproponowali sposoby klasyfikacji i opisali zasadnicze cechy algorytmów.

W pracy tej zaproponowano następującą klasyfikację metod (algorytmów) rozwiązywania zagadnień optymalizacji. Za pierwotne kryterium podziału przyjęto realizowany przez algorytm sposób wyboru kolejnych punktów próbnych w przestrzeni rozwiązań:

---

<sup>1</sup> Zdaniem autora nie jest to optymalizacja (rozumiana jako przeszukiwanie przestrzeni wariantów), lecz modyfikacja, strojenie, tuning, czyli wprowadzanie zmian do istniejących rozwiązań. Niestety, w praktyce przemysłowej bardzo często używa się terminu „optymalizacja”, mając na myśli właśnie modyfikowanie/tuningowanie.

(1) przeszukiwania (przeglądowe, enumeratywne, symultaniczne): systematyczne, losowe, proste przeszukiwanie losowe (Monte-Carlo), algorytm losowego spadku i in.;

(2) poszukiwania (iteracyjne, sekwencyjne, analityczne): pośrednie (ściśle, analityczne); bezpośrednie (przybliżone, iteracyjne):

– zerowego rzędu: Hooke’a-Jeevsa, Rosnebrocka, Neldera-Meada, spadku względem współrzędnych, Gaussa-Seidle’a, najszybszego spadku, losowego kierunku i in.;

– pierwszego rzędu: gradientu prostego, najszybszego spadku, kierunków sprzężonych, kierunków sprzężonych Powella, gradientu sprzężonego i in.;

– drugiego rzędu: Newtona, quasi-newtonowska metoda Davidona–Fletcher–Powella i in.;

(3) adaptacyjny (inne używane nazwy: uczący się, ze sztuczną inteligencją, heurystyczny, inspirowany mechanizmami biologicznymi): symulowanego wyżarzania, algorytmy ewolucyjne (strategie ewolucyjne, algorytmy genetyczne), sieci neuronowe, przeszukiwanie z tabu, algorytmy mrówkowe i in.

Zaproponowana klasyfikacja nie może być uznana ani za kompletną, ani za jedyną, ponieważ nie zaproponowano dotychczas jednej klasyfikacji powszechnie uznanej w środowisku badaczy; pozwala jednak przedstawić duże zróżnicowanie dostępnych metod. Poniżej omówiono krótko zasadnicze cechy wymienionych grup metod. Szczegółowe opisy algorytmów optymalizacji, należących do poszczególnych grup, można znaleźć w dostępnych publikacjach, m.in. w przywołanych powyżej.

W metodach przeszukiwania punkty próbne w przestrzeni rozwiązań wybierane są w zależności od przyjętej strategii jeszcze przed rozpoczęciem eksperymentu numerycznego. Cała seria eksperymentów jest przeprowadzana bez uwzględniania wyników osiągniętych w pojedynczej próbie. Optimum (a dokładniej przedział, w którym optimum się znajduje) określone jest na podstawie analizy wartości funkcji celu w punktach próbnych. W każdej z tych metod najlepszy wynik określa sąsiedztwo optimum; może on też stanowić punkt wyjścia dla poszukiwania sekwencyjnego. Zastosowanie tych metod nie generuje istotnych wymagań dotyczących matematycznej struktury zadania optymalizacji, ponieważ obliczane są tylko wartości funkcji celu i ograniczeń. Przestrzeń rozwiązań może być dyskretna, a przestrzeń ocen – wielomodalna. Metody wymagają dużej liczby obliczeń w celu przeszukiwania przestrzeni rozwiązań i identyfikacji rozwiązania optymalnego.

W metodach systematycznego przeszukiwania obliczane są wartości funkcji celu we wszystkich kolejnych punktach przestrzeni rozwiązań. Można przyjąć, że próby wykonywane są w punktach węzłowych regularnej siatki rozpiętej w przestrzeni rozwiązań.

W metodach losowego przeszukiwania kolejne wartości zmiennych decyzyjnych są zmiennymi losowymi (o rozkładzie równomiernym) wewnątrz przestrzeni rozwiązań. Dla każdego wybranego losowo punktu wyznaczana jest wartość funkcji celu. Algorytm „błądzi” w przestrzeni rozwiązań.

W metodach poszukiwania wybór kolejnego punktu próby, a także zakończenie poszukiwań polega na obliczaniu i porównywaniu wartości funkcji celu w poszczególnych punktach próby. Na tej podstawie ustalany jest kolejny punkt. Metody te są wydajniejsze od metod przeszukujących, ponieważ pozwalają uniknąć poszukiwań w obszarze, w którym znalezienie korzystnych wartości funkcji celu jest mało realne. Wymagają jednak bardziej skomplikowanego postępowania. Metody te pozwalają zazwyczaj znaleźć lokalne ekstre-

mum i wymagają istnienia ciągłych pochodnych. Algorytmy „uczą się”, ale tylko lokalnie – w otoczeniu punktu próbnego bieżącej iteracji. Algorytmy nie „gromadzą wiedzy” z poprzednich iteracji i o całej przestrzeni rozwiązań. Zastosowanie tych metod generuje bardzo wysokie wymagania dotyczące matematycznej struktury zadania optymalizacji, ponieważ obliczane są nie tylko wartości funkcji celu i ograniczeń, ale także ich pochodnych. Przestrzeń rozwiązań powinna być ciągła, a przestrzeń ocen – jednomodalna. Liczba niezbędnych obliczeń nie jest istotnym ograniczeniem w stosowaniu tych metod.

W metodach pośrednich poszukiwanie lokalnych ekstremów odbywa się poprzez rozwiązywanie układu równań (zazwyczaj nieliniowych) otrzymanych przez przyrównanie gradientu funkcji celu do zera. W przypadku funkcji celu zależnych od wielu zmiennych jest to uogólniona metoda punktów krytycznych stosowana w przypadku funkcji jednej zmiennej.

W metodach bezpośrednich poszukiwanie rozpoczyna się od punktu początkowego w przestrzeni rozwiązań, np. wybranego w ramach jednej z metod przeszukiwania symultanicznego. Kolejne punkty w przestrzeni rozwiązań generowane są w kolejnych iteracjach, poprzez dodanie do punktu poprzedniego poprawek zależnych od wartości i kształtu funkcji w tym właśnie punkcie. Postępowanie to prowadzone jest tak długo, jak długo osiągnięta jest poprawa funkcji celu. W pewnych przypadkach metody te zawodzą, np. w przypadku istnienia punktu siodłowego w przestrzeni rozwiązań.

Metody adaptacyjne stosowane są w przypadku zadań, które mają skończoną liczbę rozwiązań dopuszczalnych. W celu określenia kierunku poszukiwań lepszych rozwiązań stosuje się procesy losowe wykorzystujące informacje o dotychczasowym przebiegu poszukiwań. Do pozyskiwania i wykorzystywania informacji wykorzystuje się mechanizmy przyjęte z metalurgii, fizyki oraz z nauk biologicznych. Metody te bardzo efektywnie łączą cechy metod poszukujących i przeszukujących. Zastosowanie tych metod nie generuje istotnych wymagań dotyczących matematycznej struktury zadania, przestrzeni rozwiązań oraz przestrzeni ocen, ponieważ – podobnie jak w przypadku metod przeszukiwania – potrzebują do obliczeń tylko wartości funkcji celu i ograniczeń. Wymagają dużej liczby obliczeń w celu identyfikacji optymalnego rozwiązania, jednak w przypadku dużych zadań optymalizacyjnych (dużej liczby możliwych rozwiązań sformułowanego zadania optymalizacji) liczba analizowanych punktów próbnych jest znacznie ograniczona dzięki wykorzystaniu przez algorytm informacji nt. historii poszukiwania. Algorytmy są bardzo skuteczne szczególnie w przypadku rozwiązywania wielokryterialnych zadań optymalizacyjnych.

Metody symulowanego wyżarzania, przekształcając pojedyncze rozwiązania, wykorzystują pojęcia zaczerpnięte z mechaniki statystycznej do konstruowania procesów losowych przeprowadzanych w celu określenia kierunku poszukiwań stanów o najmniejszej energii, reprezentujących rozwiązania optymalne.

Metody ewolucyjne, wykorzystując zaczerpnięte z biologii koncepcje kodowania informacji o wariantach rozwiązania w postaci ciągu znaków (chromosomów) oraz mechanizmy mutacji, krzyżowania i reprodukcji do eksploracji i eksploatacji przestrzeni rozwiązań, pozwalają na efektywne poszukiwanie rozwiązań optymalnych, przekształcając jednocześnie jedno rozwiązanie (w przypadku strategii ewolucyjnych) lub zbiór rozwiązań (w przypadku algorytmów genetycznych).

Strategie ewolucyjne, przekształcając pojedyncze rozwiązanie, wykorzystują procesy losowe do wprowadzania kolejnych zmian w rozwiązaniu i promowania zmian prowadzących do polepszenia kryterium.

Metody wykorzystujące algorytmy genetyczne polegają na generowaniu populacji pewnych obiektów, utożsamianych z alternatywnymi rozwiązaniami zadania, które dopasowują się do danych wymagań. Koncepcyjną bazą algorytmów genetycznych jest Darwinowska teoria doboru naturalnego na drodze eliminowania z populacji osobników słabiej przystosowanych do danych warunków, przy jednoczesnym zwiększaniu liczby osobników lepiej przystosowanych. Warianty rozwiązań reprezentujące populację w danym pokoleniu reprodukuja i krzyżują się między sobą, stopniowo przekazując pożądane cechy coraz większej liczbie osobników – wariantów rozwiązań w następnych pokoleniach. Osobniki ulegają losowym mutacjom, w związku z czym co pewien czas próbkowane są różne obszary przestrzeni rozwiązań. Za rozwiązanie optymalne przyjmuje się wariant najlepiej przystosowany w ustalonej liczbie pokoleń. Algorytm realizuje losowe, lecz ukierunkowane, poszukiwanie obiecujących obszarów w przestrzeni rozwiązań. Przestrzeń rozwiązań jest próbkowana w kolejnych pokoleniach jednocześnie przez wiele wariantów. Metoda jest szczególnie efektywna w przypadku dyskretnych i niespójnych przestrzeni rozwiązań.

W metodach opartych na sieciach neuronowych obliczenia wykonywane są przez jednostki przetwarzające zwane neuronami. Każdy neuron jest połączony z pewną liczbą innych neuronów, tworząc układ rozproszony. Duża liczba połączeń, a także zdolność do równoległego przetwarzania informacji, prowadzi do pewnych unikatowych cech takich struktur, które ze względu na osiągane rezultaty czynią je podobnymi do systemów nerwowych organizmów żywych.

Zwróćmy uwagę na ważną cechę metod optymalizacji. Metody poszukiwania są metodami lokalnymi. Oznacza to, że umożliwiają odnalezienie ekstremum zlokalizowanego w otoczeniu punktu początkowego poszukiwania. W przypadku funkcji niewypukłej lub wypukłej będzie to oznaczało oczywiście jednocześnie odnalezienie optimum globalnego. Jednak w przypadku funkcji wielomodalnych będzie to zazwyczaj optimum lokalne, przy czym możliwość odnalezienia optimum globalnego będzie przypadkowa. Metody przeszukiwania i metody adaptacyjne są metodami globalnymi. Przy odpowiednio gęstym próbkowaniu (małej ziarnistości, dużej rozdzielczości) metody przeszukiwania dają szansę na odnalezienie optimum globalnego lub rozwiązania bliskiego optimum globalnego. Metody adaptacyjne mają wbudowane mechanizmy, które pozwalają im uczyć się przestrzeni rozwiązań i w ten sposób ukierunkowywać poszukiwania na obszary zawierające ekstremum globalne.

Omówione metody optymalizacji można również, zdaniem autora, podzielić na dwie duże rodziny – w zależności od swobody w wyborze punktu początkowego procesu optymalizacji lub inaczej – w zależności od stopnia wykorzystania wiedzy nt. historii procesu optymalizacji; są to:

- rodzina stacjonarnych metod optymalizacji, w których historia optymalizacji nie ma znaczenia dla przebiegu procesu optymalizacji; oznacza to, że dowolny moment (krok, iteracja, próba) optymalizacji może być przyjęty za jej początek; algorytmy z tej rodziny nie gromadzą i nie wykorzystują wiedzy nt. przebiegu procesu optymalizacji; do tej rodziny metod należą przeglądowe algorytmy optymalizacji;

– rodzina dynamicznych (niestacjonarnych, ewolucyjnych, z historią, z pamięcią) metod optymalizacji, w których historia optymalizacji ma znaczenie dla przebiegu procesu optymalizacji; oznacza to, że wybór momentu w procesie optymalizacji nie jest dowolny i obojętny dla przebiegu poszukiwania; algorytmy z tej rodziny gromadzą i wykorzystują wiedzę nt. przebiegu optymalizacji; do tej rodziny metod autor zalicza metody poszukiwania i metody adaptacyjne.

Racjonalny wybór algorytmu do rozwiązania sformułowanego w pracy zadania optymalizacji KKSM powinien być dokonany na podstawie znajomości sformułowanego problemu. W szczególności należy odpowiedzieć na pytania:

- jakie zadanie należy rozwiązać – statyczne czy dynamiczne?, bez ograniczeń czy z ograniczeniami?, liniowe czy nieliniowe?;
- ile kryteriów optymalizacji należy uwzględnić – jedno czy więcej?;
- ile zmiennych decyzyjnych należy przyjąć do odpowiedniego opisu optymalizowanej konstrukcji i w jakiej przestrzeni są one definiowane (zmienne rzeczywiste, całkowitoliczbowe, binarne)?;
- jakich danych o optymalizowanej konstrukcji może używać wybrany algorytm optymalizacji – tylko wartości kryterium (kryteriów) optymalizacji?, gradientu funkcji (pierwszy rząd)?, pochodnych drugiego rzędu (drugi rząd)?;
- jakie zasoby (czas i koszty) mają być przeznaczone na przeprowadzenie optymalizacji?

### **2.3. Wybór metody rozwiązania zadania wielokryterialnej optymalizacji**

Na podstawie przeprowadzonej w podrozdziale 2.1 analizy zadania optymalizacji KKSM można uznać, że typowe zadanie wielokryterialnego projektowania KKSM jest zagadnieniem: (1) wielomodalnym, (2) z ograniczeniami, (3) nieliniowym, (4) dyskretnym, (5) niezależnym od czasu, (6) deterministycznym. Rozwiązanie tak złożonego zadania optymalizacyjnego jest bardzo trudne. W wielu przypadkach ceną jest wprowadzenie znacznych uproszczeń modelu, przy znacznych kosztach obliczeniowych. Przedstawiona w podrozdziale 2.2 dyskusja nad podstawowymi cechami algorytmów optymalizacyjnych uzasadnia stwierdzenie, że istnieją metody, które pozwalają na znalezienie wariantów optymalnych KKSM, przy możliwej do przyjęcia liczbie niezbędnych obliczeń funkcji celu i ograniczeń. Do tych metod należą metody adaptacyjne oparte na sieciach neuronowych, strategiach ewolucyjnych, algorytmach genetycznych i inne (Bentley 1999, Pham i Karaboga 2000), które mogą „zdobywać doświadczenie” w poszukiwaniu wariantu optymalnego, „ucząc się” struktury przestrzeni rozwiązań i kierując poszukiwania do obszarów, w których znalezienie rozwiązań niezdominowanych jest najbardziej prawdopodobne, ograniczając tym samym liczbę koniecznych obliczeń funkcji celu. W porównaniu z metodami przeszukiwania liczba obliczeń funkcji celu jest znacznie mniejsza, jednak znacznie większa niż w przypadku metod poszukiwania.

Prace badawcze nad zastosowaniem metod optymalizacji do KKSM prowadzone są już w różnych ośrodkach na świecie. Część opublikowanych prac omówiono już w podrozdziale 1.1. Przykładowe wyniki opublikowali m.in. Hughes i in. (1980), Rahman (1992), Konieczny i in. (1994), Rahman i Caldwell (1995), Jang i Seo (1996), Liang i in. (1997), Au-



gusto i Kawano (1998). W ostatnich latach w projektowaniu konstrukcji kompozytowych, stalowych konstrukcji prętowych i innych z powodzeniem stosowano algorytmy genetyczne (GA). Callahan i Weeks (1992), Nagendra i in. (1992), Riche i Haftka (1993), Kogiso i in. (1994), Soremekun i in. (2001) oraz inni zastosowali GA do optymalizacji struktury laminatu przeznaczonego dla przemysłu lotniczego. Hajela i in. (1993), Adeli i Cheng (1994), Koumousis i Georgiou (1994), Ramasamy i Rajasekarn (1996) oraz inni zastosowali GA do optymalizacji układów prętowych. Lin i Hajela (1992) zastosowali GA do optymalizacji połączeń nitowych, parametrów sprężyn i struktur prętowych. Pyrz (1998) wykorzystał ten algorytm do optymalizacji grubości płyt poddanych zginaniu. Rafiq i Southcombe (1998) użyli GA do optymalizacji struktur z betonu zbrojonego. Opublikowano również prace dotyczące zastosowania GA do rozwiązywania różnorodnych zadań związanych z projektowaniem i budową statków. Chung i Jung (2004) wykorzystali GA do optymalizacji elastycznego fartucha poduszkowca. Lee i Kim (1996) zastosowali GA sprzężony z lokalnym algorytmem Hooke'a-Jeevsa do optymalizacji projektu statku do przewozu skroplonego gazu. Lee (1997) zastosował GA do wielokryterialnej optymalizacji projektu statku morskiego. Zadanie wielokryterialne rozwiązał on poprzez optymalizację jednokryterialną w odniesieniu do kolejnych kryteriów optymalizacji i przy włączaniu pozostałych kryteriów do zbioru ograniczeń. Doctors i Day (1995), Day i Doctors (1996, 1997), Birmingham i Smith (1998), Islam i in. (2001) wykorzystali GA do optymalizacji kształtu kadłuba jednostek pływających. Henra i in. (1995), Henra i Wright (1997) zastosowali GA do optymalizacji właściwości morskich i oporowych katamarana. Turkmen i Turan (2007) zastosowali GA do wielokryterialnej optymalizacji rozplanowania przestrzeni wewnętrznej promu pasażersko-samochodowego. Sanecka i in. (1996) wykorzystali GA do optymalizacji parametrów eksploatacyjnych oceanicznego systemu wydobywczego. Sommersel (1997) zastosował GA do projektu ogólnego statku dostawczego. Birk i in. (2004) zastosowali GA do optymalizacji projektu półzanurzonej platformy wydobywczej. Wolf i in. (2005) użyli GA do optymalizacji projektu głównego okrętów wojennych.

Podjęto także pewne próby, aczkolwiek nieliczne, zastosowania GA do optymalizacji KKSM. Katoh i in. (1998) wykorzystali GA do optymalizacji masy konstrukcji kadłuba masowca. Lee i Kim (1996) przeprowadzili techniczno-ekonomiczną optymalizację statku typu LNG, uwzględniając w niej także konstrukcję kadłuba. Nobukawa i in. (1998), Kitamura i in. (2000) zastosowali GA do optymalizacji konstrukcji przedziału siłowni statku towarowego, z uwzględnieniem dynamicznych wymuszeń konstrukcji. Okada i Neki (1992, 1995) zastosowali GA do optymalizacji konstrukcji pokryw lukowych oraz konstrukcji kadłuba zbiornikowca. Nobukawa i Zhou (1996), Zhou i in. (1997 a, b) zastosowali GA do optymalizacji konstrukcji kadłuba drobnicowca. Lee i Roh (2001) wykorzystali GA do optymalizacji konstrukcji grodzi falistej masowca i konstrukcji kadłuba zbiornikowca w środkowej części statku. Yang i Hwang (2002) zaprezentowali wyniki optymalizacji konstrukcji grodzi falistej. Jelovica i Klanac (2009) przedstawili wyniki optymalizacji konstrukcji zbiornikowca. Klanac i in. (2009) zaprezentowali wyniki optymalizacji konstrukcji zbiornikowca, z uwzględnieniem wymagań odporności kolizyjnej konstrukcji. Doi i in. (1997) zastosowali GA do projektowania stoczniowych kart wykroju. Todd i Sen (1997) poinformowali o zastosowaniu GA do planowania produkcji stoczniowej. Klanac i Kujala (2004) zastosowali GA

do optymalizacji konstrukcji paneli sandwiczowych przeznaczonych na przekrycia kadłubowe. Kong i in. (2006) wykorzystali GA do optymalizacji konstrukcji kadłuba statku w celu minimalizacji poziomu drgań konstrukcji. Klanac i Jelovica (2007, 2009) zastosowali algorytm do optymalizacji konstrukcji kadłuba szybkiego promu pasażersko-samochodowego. Hamada i in. (2009) zaprezentowali wykorzystanie GA do optymalizacji zładu poprzecznego statku. Jang i in. (2009) przeprowadzili wielokryterialną optymalizację konstrukcji statku w celu zwiększenia odporności zmęczeniowej.

Wyniki przedstawionych badań wskazują, że algorytmy genetyczne mogą stać się efektywnym narzędziem służącym do optymalizacji KKSM. Wiele problemów związanych z praktycznym zastosowaniem GA nie zostało jednak dotychczas przebadanych i rozwiązanych. Dotyczy to w szczególności wielokryterialnej optymalizacji KKSM.

Na podstawie przeprowadzonej dyskusji oraz wcześniejszych własnych doświadczeń w zakresie jednokryterialnej optymalizacji konstrukcji kadłuba statku (Sekulski 2009 a, b, Sekulski i Jastrzębski 1998, 1999 a, b) autor zdecydował o wyborze algorytmu genetycznego do rozwiązania sformułowanego w pracy wielokryterialnego zadania optymalizacji konstrukcji kadłuba statku morskiego.

## **2.4. Narzędzia obliczeniowe do optymalizacji**

W rozdziale 1 dokonano przeglądu prac dotyczących optymalizacji KKSM oraz wskazano najważniejsze etapy w rozwoju zastosowań metod optymalizacji w tym obszarze. W dalszej części rozdziału zaprezentowano ostatnie lata ewolucji metod i przykłady zastosowań optymalizacji w projektowaniu KKSM przedstawionych syntetycznie w ostatnich raportach ISSC. W dwóch kolejnych raportach ISSC zamieszczono zestawienia obejmujące łącznie 41 prac opublikowanych w latach 1997–2008 (ISSC 2006 a, 2009 a). Wśród tych prac są 34 prace dotyczące optymalizacji KKSM. Wynika z nich, że optymalizacja KKSM odbywa się przede wszystkim pod względem ciężaru konstrukcji lub kosztów budowy. Coraz częściej przeprowadzana jest również optymalizacja wielokryterialna pod względem obu tych kryteriów. Rzadziej przeprowadza się optymalizację pod względem wskaźników bezpieczeństwa generowanych wariantów, drgań konstrukcji, a także pod względem wysokości wiązań ramowych. Zmienne konstrukcyjne reprezentują przede wszystkim wymiary oraz liczbę elementów konstrukcyjnych. Liczba zmiennych konstrukcyjnych jest różna, podobnie jak natura sformułowanych ograniczeń (uplastycznienie, wyboczenie, odkształcenie, ciężar, koszt, zmęczenie, częstotliwość drgań własnych itd.). Różne są także sposoby poszukiwania odpowiedzi konstrukcji. Stosowana jest przede wszystkim dwu- oraz trójwymiarowa metoda elementów skończonych. Metody rozwiązywania zadań optymalizacyjnych to przede wszystkim metody optymalizacji nieliniowej (metody newtonowskie i quasi-newtonowskie, gradientu sprzężonego i in.), metody optymalizacji liniowej (CL, SLP i in.). Stosowane są również algorytmy genetyczne (GA) 13 raportowanych przypadków. Znacznie rzadziej podejmowane są próby wykorzystania innych niekonwencjonalnych metod optymalizacji, np. metody roju cząstek (PSO), metody symulowanego wyżarzania (SA) – w dwóch raportowanych przypadkach. Podejmuje się także próby sprzężenia różnych algorytmów optymalizacji, np. globalnego algorytmu genetycznego z lokalnym algorytmem gradientowym.

Zdaniem autora najbardziej znane obecnie programy komputerowe wykorzystywane do optymalizacji konstrukcji kadłuba statków to: MAESTRO, LBR5, OCTOPUS, CONSTRUCT.

System MAESTRO integruje szybkie, zorientowane na konstrukcje okrętowe, moduły, przeznaczone do modelowania konstrukcji i analizy dużych sekcji przestrzennych, metodą elementów skończonych, analizy stanów zniszczenia konstrukcji oraz procedury optymalizacji konstrukcji. System umożliwia również analizę drgań konstrukcji, także z uwzględnieniem wpływu wody towarzyszącej. System pozwala na wykorzystanie metod racjonalnego projektowania do optymalizacji dużych, złożonych, cienkościennych struktur modelujących konstrukcję kadłuba statków.

W procesie optymalizacji MAESTRO wykorzystuje metodę SLP. Optymalizacja prowadzona jest pod względem kryteriów sformułowanych przez użytkownika, którymi mogą być ciężar konstrukcji, koszt produkcji lub oba kryteria łącznie. W następujących kolejno po sobie iteracjach wymiary elementów konstrukcyjnych ulegają zmianie, a taka zmieniona konstrukcja zostaje poddana analizie metodą elementów skończonych; oceniane jest spełnienie przez elementy konstrukcyjne odpowiednich warunków wytrzymałości w założonych stanach obciążenia. Ten powtarzany wielokrotnie proces trwa aż do czasu, gdy konstrukcja osiągnie optimum spełniające wszystkie nałożone ograniczenia.

LBR5 jest zintegrowanym systemem programów przeznaczonym do optymalizacji kosztu produkcji, ciężaru i środka ciężkości usztywnionych konstrukcji okrętowych (Rigo i Fleury 2001, Rigo 2001 a, b, 2003). System umożliwia analizę 3D zachowania się konstrukcji (zazwyczaj w obrębie jednej ładowni). Bezpośrednia analiza wytrzymałości konstrukcji daje możliwość uwzględnienia wielu istotnych stanów granicznych konstrukcji – stanu granicznego użytkowania (ang. *serviceability limit state*) oraz stanu granicznego wytrzymałości (ang. *ultimate limit state*). Procedury optymalizacji konstrukcji umożliwiają optymalizację wymiarów i odstępów między elementami konstrukcyjnymi. W optymalizacji kosztów produkcji możliwe jest uwzględnienie jednostkowych kosztów produkcji oraz kolejności czynności produkcyjnych. Dzięki wymianie danych system LBR5 zintegrowano z systemem MARS opracowanym przez towarzystwo klasyfikacyjne Bureau Veritas.

OCTOPUS jest narzędziem do projektowania koncepcyjnego rozwiniętym w środowisku systemu MAESTRO (Zanic i in. 2002, Zanic i Prebeg 2004). System, który przeznaczony jest do projektowania powtarzalnych cienkościennych struktur (skrzydła, kadłuba samolotu, kadłuba statku), zawiera moduły obliczeniowe umożliwiające generowanie modelu, generowanie obciążeń, obliczanie wytrzymałości wiązań pierwszego (wiązary) i drugiego rzędu (usztywnienia), uwzględniające także wyboczenie, zmęczenie i nośność graniczną. Moduły do obliczeń optymalizacyjnych wykorzystują strategie ewolucyjne ES, GA i FEE. System ma bardzo rozbudowane środowisko graficzne.

CONSTRUCT jest systemem programów komputerowych o strukturze modułowej, umożliwiającym analizę wytrzymałości i optymalizacji konstrukcji statków we wczesnych etapach projektowania. Stosowany jest przede wszystkim do projektowania dużych statków pasażerskich z wieloma pokładami i dużymi otworami w konstrukcji (np. z szybami, oknami, balkonami). Może być jednak stosowany także do projektowania konstrukcji kadłuba statków o prostszych układach konstrukcyjnych, np. zbiornikowców, kontenerowców, statków ro-ro. CONSTRUCT może wygenerować cyfrowy model konstrukcji automatycznie albo poprzez

import danych o topologii konstrukcji opracowanych za pomocą innych, bardziej uniwersalnych, programów komputerowych, np. NAPA.

W celu szybkiego znalezienia odpowiedzi konstrukcji kadłuba na założone obciążenia projektowe oraz w celu zidentyfikowania podstawowych form zniszczenia (tzn. uplastycznienia, wyboczenia, skręcenia itd.) CONSTRUCT wykorzystuje metodę Coupled Beams Method (Naar i in. 2004) opracowaną na potrzeby analizy wytrzymałości wzdłużnej kadłuba statku z długą nadbudówką, której kondygnacje modelowane są jako osobne belki sprzężone z belkami modelującymi pozostałe kondygnacje i z kadłubem. CONSTRUCT umożliwia zastosowanie dwóch algorytmów optymalizacji wielokryterialnej – VOP wykorzystującego koncepcję transformacji ograniczeń do zbioru kryteriów (ang. *vectorization*) lub rozwiązywanie jednokryterialnych i wielokryterialnych zadań jako jednokryterialnych zadań optymalizacji (ang. *omni-optimization*) – Klanac i Jelovica (2007 a, 2009) oraz NSGA-II – Deb i in. (2000, 2002).

## 2.5. Podsumowanie i wnioski

Dzięki postępowi w produkcji ogólnie dostępnych komputerów oraz rozwojowi algorytmów obliczeniowych od ponad 30 lat następuje stały rozwój optymalizacji konstrukcji statków. Świadczą o tym publikacje przygotowywane, niestety, prawie wyłącznie w środowiskach akademickich lub centrach badawczych współpracujących z uczelniami. Pomimo stałego postępu w opracowywaniu algorytmów oraz narzędzi obliczeniowych bardzo mało jest przykładów zastosowania metod optymalizacyjnych do realizacji rzeczywistych projektów. Współpraca zespołu ANAST z Uniwersytetu w Liege z Ateliers et Chantiers de Nantes (Nantes Shipyard, France) (Rigo 2001 a, b, 2003, Rigo i Fleury 2001) jest rzadkim przykładem praktycznego wdrożenia w stoczni systemu optymalizacyjnego w produkcji paneli usztywnionych. Niestety, nie jest dzisiaj jasne, czy system ten jest nadal stosowany.

Dlaczego istnieje tak duży rozdźwięk pomiędzy badaniami a praktycznym zastosowaniem optymalizacji wielokryterialnej w projektowaniu KKSMM pomimo już kilkudziesięciu lat rozwoju? Optymalizacja wykorzystuje zwykle zaawansowane metody matematyczne (utożsamiane przez wielu ze sferą zastrzeżoną dla aktywności akademickiej) do formułowania oraz obliczania wartości funkcji celu oraz zbioru ograniczeń. Przeprowadzana dzisiaj optymalizacja wymaga automatycznego generowania potencjalnych rozwiązań, które są następnie poddawane analizie wykonywanej przez zaawansowane wyspecjalizowane programy komputerowe. Wiąże się to z koniecznością wykorzystania drogiego oprogramowania. Programy do optymalizacji wymagają specjalistycznej wiedzy i umiejętności ich obsługi. Wymagają również zainwestowania znacznych środków na zakup komputerów o odpowiednio dużej mocy oraz licencji na programy komputerowe. Jednocześnie ich zastosowanie jest okazjonalne i dotyczy bardzo specjalistycznych problemów. Niestety, pomimo wielu wysiłków wkładanych w opracowanie przyjaznego oprogramowania, pozwalającego z łatwością generować modele optymalizowanej konstrukcji, sytuacja zmienia się nieznacznie, w związku z czym bez fundamentalnych zmian optymalizacją nadal będą zajmować się jedynie ośrodki akademickie (ISSC 2006 b).

Przeprowadzona dyskusja nad zasadniczymi cechami zadania optymalizacji konstrukcji kadłuba statku morskiego oraz znanych z literatury algorytmów optymalizacyjnych pozwoliła na dokonanie racjonalnego wyboru algorytmu rozwiązania sformułowanego w pracy zadania optymalizacji. Jest to algorytm genetyczny, w przypadku którego przedyskutowane właściwości, doświadczenia wielu autorów oraz pewne doświadczenie autora tej pracy wskazują, że może on być podstawą opracowania własnego narzędzia obliczeniowego wielokryterialnej optymalizacji konstrukcji statku morskiego.

W kolejnym rozdziale omówiono podstawowe koncepcje teoretyczne optymalizacji wielokryterialnej.



### 3. Podstawowe koncepcje optymalizacji wielokryterialnej

#### 3.1. Sformułowanie zadania optymalizacji wielokryterialnej

Zadanie optymalizacji wielokryterialnej, czyli wyboru najlepszego rozwiązania pod względem ustalonej listy kryteriów oceny (kryteriów optymalizacji), powstaje wówczas, gdy istnieją cele, które należy osiągnąć oraz gdy istnieją różne sposoby realizacji tych celów. Z punktu widzenia matematyki przez optymalizację wielokryterialną należy rozumieć, w sposób ogólny, postępowanie polegające na wyborze elementu z zadanego zbioru na podstawie relacji ustalających pewien porządek w tym zbiorze. W projektowaniu okrętowym elementy zbioru są na ogół reprezentacjami rozwiązań konkretnych problemów, takich jak: różne warianty konstrukcji kadłuba statku, różne wartości sterowania napędu głównego statku, zapewniające realizację określonego celu sterowania (np. najmniejszych kosztów eksploatacji statku) itp. Zbiór ten, nazywany zbiorem rozwiązań możliwych<sup>1</sup>, jest podzbiorem przestrzeni zmiennych decyzyjnych  $V_x$ . Ponieważ praca dotyczy projektowania konstrukcji inżynierskich, zamiast pojęcia „zmiennie decyzyjne” używane będzie pojęcie „zmiennie konstrukcyjne”. W praktyce zbiór takich rozwiązań możliwych zawężany jest przez wprowadzenie różnych ograniczeń i taki zawężony zbiór nazywany jest zbiorem rozwiązań dopuszczalnych  $\Phi$ . Z oczywistych względów zbiór rozwiązań dopuszczalnych  $\Phi$  jest także podzbiorem przestrzeni zmiennych konstrukcyjnych  $V_x$ , a każdy element tej przestrzeni jest wektorem zmiennych konstrukcyjnych  $\mathbf{x} \in V_x$ . Warianty w zbiorze rozwiązań dopuszczalnych  $\Phi$  nadają się do realizacji. Przestrzeń konstrukcyjna  $V_x$  może być przestrzenią funkcyjną lub przestrzenią euklidesową, jeśli wszystkie jej współrzędne są liczbami:

$$\mathbf{x} = [x_1 \ x_2 \ \dots \ x_i \ \dots \ x_n]^T \in V_x \quad (3.1)$$

Przypadek, w którym przestrzeń zmiennych konstrukcyjnych jest  $n$ -wymiarową przestrzenią euklidesową  $\mathcal{R}^n$ , najczęściej występuje w praktyce. W niniejszej pracy przez przestrzeń zmiennych konstrukcyjnych rozumieć należy przestrzeń  $\mathcal{R}^n$ .

Wektor kryteriów optymalizacji  $\mathbf{f}(\mathbf{x})$  jest operatorem, który przekształca przestrzeń zmiennych konstrukcyjnych w przestrzeń kryteriów  $V_f$  (przestrzeń ocen, przestrzeń jakości), co można zapisać w postaci:

$$\mathbf{f}(\mathbf{x}): V_x \rightarrow V_f \quad (3.2)$$

Przy uwzględnieniu ograniczeń wektor kryteriów optymalizacji  $\mathbf{f}(\mathbf{x})$  jest operatorem, który przekształca zbiór dopuszczalny  $\Phi$  w zbiór  $\Phi_f$  nazywany zbiorem celów (ocen) osiągalnych:

$$\mathbf{f}(\mathbf{x}): \Phi \rightarrow \Phi_f \quad (3.3)$$

---

<sup>1</sup> Rozwiązanie możliwe jest więc reprezentowane przez dowolną kombinację wartości zmiennych decyzyjnych i może być zupełnie nie do przyjęcia z praktycznego, technicznego, punktu widzenia.

Jeśli przestrzeń ocen  $V_f \subset \mathfrak{R}^s$  jest co najmniej dwuwymiarowa ( $s = 2, 3, \dots, S$ ), to operator  $\mathbf{f}(\mathbf{x})$ , będący wektorową funkcją składającą się z  $s$  składowych  $\mathbf{f} = [f_1 \ f_2 \ \dots \ f_s]^T$ , przyporządkowuje każdemu elementowi należącemu do zbioru dopuszczalnego  $\Phi$  wektor  $s$  liczb określających łącznie jakość tego elementu. Mówi się wtedy o zadaniu optymalizacji wielokryterialnej, gdyż  $s$  składowych funkcji wektorowej  $\mathbf{f}(\mathbf{x})$  to  $s$  różnych kryteriów optymalizacji. Zbiór ocen osiągalnych jest podzbiorem  $s$ -wymiarowej przestrzeni euklidesowej, a element tego zbioru  $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_s(\mathbf{x})]^T$ , nazywany wektorem ocen (wskaźników jakości), dotyczących ustalonego wektora zmiennych konstrukcyjnych, jest zbiorem  $s$  liczb określających wartość liczbową poszczególnych ocen.

Zadanie optymalizacji wielokryterialnej (w literaturze polskiej używa się także krótszego terminu „polioptymalizacja”<sup>2</sup>) jest bardzo ważne ze względu na zastosowania praktyczne, a jednocześnie nie jest tak proste jak zadanie optymalizacji jednokryterialnej, w którym przyjęcie rozwiązania optymalnego jest oczywiste. Gdy jakość rozwiązania oceniana jest nie jedną, lecz wieloma liczbami, pojęcia rozwiązania wielokryterialnego zadania optymalizacji nie można zdefiniować, korzystając z relacji porządku liniowego w zbiorze rozwiązań dopuszczalnych. Wprowadzić trzeba nowe pojęcie, które dla zadań optymalizacji wielokryterialnej będzie odpowiednikiem pojęcia optymalności. Powszechnie zaakceptowaną miarę jakości wariantów w wielokryterialnych problemach optymalizacji sformułował pierwotnie Edgeworth (1881), a następnie uogólnił ją Pareto (1896). Dzisiaj rozwiązanie takie nazywa się rozwiązaniem optymalnym Edgeworth-Pareto lub krótko: rozwiązaniem optymalnym Pareto. Podstawowym pojęciem pozwalającym zdefiniować takie rozwiązanie jest pojęcie dominacji sformułowane przez Pareto (1896). Zostanie ono szczegółowo przedyskutowane w dalszej części niniejszego rozdziału.

W przeciwieństwie do celu rozwiązania zadania optymalizacji jednokryterialnej, polegającego na takim wyborze wartości zmiennych konstrukcyjnych  $\mathbf{x}$ , aby kryteria optymalizacji  $f(\mathbf{x})$ , które są od nich zależne, osiągnęły wartości ekstremalne (minimalne lub maksymalne), przy spełnieniu wszystkich przyjętych ograniczeń, cel zadania optymalizacji wielokryterialnej można sformułować w sposób następujący: znaleźć kombinację wartości zmiennych konstrukcyjnych  $\mathbf{x}$ , która zoptymalizuje jednocześnie wszystkie składowe zadanego wektora funkcji celu  $\mathbf{f}(\mathbf{x})$ , którymi są kryteria optymalizacji (kryteria oceny). Możliwe jest również nałożenie ograniczeń na przedziały zmienności zmiennych konstrukcyjnych. Zakłada się przy tym, że wszystkie występujące w zadaniu funkcje są rzeczywiste i że liczba ograniczeń jest skończona. Biorąc pod uwagę czynnik nakładów obliczeniowych i ich kosztów, można dodatkowo postawić wymaganie, że wybór ma być dokonany przy możliwie najniższych kosztach. Uzgodnienie rozumienia słowa „optymalizuje” w przypadku optymalizacji wielokryterialnej ma znaczenie zasadnicze. W dalszej części pracy znaczenie tego słowa zostanie dokładniej przedyskutowane. Ogólne sformułowanie zadania optymalizacji wielokryterialnej można zapisać w postaci matematycznej:

---

<sup>2</sup> Tarnowski (2009) rozróżnia w następujący sposób pojęcia optymalizacji wielokryterialnej i polioptymalizacji: (1) w problemach optymalizacji wielokryterialnej formułuje się jedno skalarnie kryterium optymalizacji na podstawie kryteriów cząstkowych, (2) w przypadku polioptymalizacji nie formułuje się skalarnego kryterium optymalizacji.



$$\begin{aligned}
&\text{dla zmiennych} & \mathbf{x} = [x_1 \ x_2 \ \dots \ x_i \ \dots \ x_n]^T: x_{i,min} \leq x_i \leq x_{i,max} \\
&\text{konstrukcyjnych} & i = 1, 2, \dots, n \\
&\text{zoptimalizować} & \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_s(\mathbf{x}) \ \dots \ f_S(\mathbf{x})]^T \quad s = 1, 2, \dots, S \\
&\text{spełniając ograniczenia} & \mathbf{h}(\mathbf{x}) = [h_1(\mathbf{x}) \ h_2(\mathbf{x}) \ \dots \ h_k(\mathbf{x}) \ \dots \ h_K(\mathbf{x})]^T, h_k(\mathbf{x}) = 0 \quad k = 1, 2, \dots, K \\
& & \mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}) \ g_2(\mathbf{x}) \ \dots \ g_j(\mathbf{x}) \ \dots \ g_J(\mathbf{x})]^T, \quad j = 1, 2, \dots, J \\
& & g_j(\mathbf{x}) \geq 0,
\end{aligned} \tag{3.4}$$

Prawidłowo sformułowane zadanie wielokryterialnej optymalizacji KKSM powinno zawierać:

(1) określenie wektora kryteriów optymalizacji  $\mathbf{f}(\mathbf{x}) \in V_f$ , które będą miarą spełnienia przez projektowaną KKSM celów w przestrzeni ocen  $V_f$ ;

(2) ustalenie takich wielkości opisujących projektowaną KKSM, będącą przedmiotem optymalizacji, które nie zależą od projektanta rozwiązującego zadanie optymalizacji; zmienne te nazywamy parametrami optymalizacji; są to np. wymiary główne statku, architektoniczne i funkcjonalne rozplanowanie przestrzeni wewnętrznych;

(3) określenie wektora zmiennych konstrukcyjnych  $\mathbf{x} \in V_x$ , którymi są wielkości opisujące projektowaną KKSM w przestrzeni rozwiązań  $V_x$ , zależne od projektanta, których wartości są poszukiwane w trakcie optymalizacji, np. materiał konstrukcyjny i jego charakterystyki, przestrzenne rozmieszczenie elementów konstrukcyjnych i ich wymiary;

(4) przyjęcie ograniczeń zakresów zmienności zmiennych konstrukcyjnych; określenie zbioru rozwiązań dopuszczalnych  $\Phi = \Phi(\mathbf{x}) \subset V_x$ ;

(5) po wyborze algorytmu (metody) rozwiązania zadania oraz narzędzia obliczeniowego także przyjęcie wartości parametrów algorytmu optymalizacyjnego i parametrów sterujących obliczeniami optymalizacyjnymi.

W sposób bardziej ogólny zadanie optymalizacji można traktować (Knowles i in. 2006) jako zbiór czterech elementów  $(V_x, V_f, f, rel)$ , gdzie  $f: V_x \rightarrow V_f$  jest funkcją przyporządkowującą każdemu rozwiązaniu  $x \in V_x$  lub wektorowi konstrukcyjnemu  $\mathbf{x} \in V_x$  odpowiednią ocenę  $f(x) \in V_f$  lub  $f(\mathbf{x}) \in V_f$  (dla skrócenia wypowiedzi często pisać będziemy, że  $f$  jest funkcją przyporządkowującą rozwiązaniu odpowiednią ocenę:  $f: \text{rozwiązanie} \rightarrow \text{ocena}$ ), a  $rel$  reprezentuje dwuargumentową relację określoną w przestrzeni ocen  $V_f$ , która ustala częściowy porządek w tej przestrzeni. Spośród czterech elementów występujących w tym określeniu  $(V_x, V_f, f, rel)$  relacji porządkującej  $rel$  poświęcono w dalszej części opracowania szczególnie dużo uwagi, ponieważ będzie ona miała kluczowe znaczenie w określeniu rozwiązania wielokryterialnego zadania optymalizacji.

W przypadku zadania optymalizacji relacja  $rel$  pozwala uporządkować zbiór rozwiązań  $V_x$ . Argumentami tej relacji są dwa dowolne rozwiązania tego zadania. Na przykład, jeśli relacją porządkującą jest „>” oraz  $f(\mathbf{x}_3) = 20$ ,  $f(\mathbf{x}_6) = 7$ , to można napisać, że  $f(\mathbf{x}_3) > f(\mathbf{x}_6)$ . Wówczas wniosek można sformułować w sposób następujący: jeśli relacja  $rel \equiv „>”$  jest relacją porządkującą zbiór rozwiązań sformułowanego zadania optymalizacji w ten sposób, że rozwiązaniem lepszym jest rozwiązanie o większej wartości kryterium optymalizacji  $f(\mathbf{x})$  oraz  $f(\mathbf{x}_3) > f(\mathbf{x}_6)$ , to można uznać, że rozwiązanie  $\mathbf{x}_3$  jest lepsze od rozwiązania  $\mathbf{x}_6$ .

Jeśli uwzględni się sformułowanie ograniczeń nałożonych na zmienne decyzyjne, to zadanie optymalizacji można traktować jako zbiór elementów  $(\Phi, \Phi_f, f, rel)$ , gdzie  $f: \Phi \rightarrow \Phi_f$  jest funkcją przyporządkowującą każdemu dopuszczalnemu rozwiązaniu lub dopuszczalnemu

wektorowi decyzyjnemu  $x \in \Phi$  lub  $\mathbf{x} \in \Phi$  odpowiednią ocenę dopuszczalną  $f(x) \in \Phi_f$  lub  $f(\mathbf{x}) \in \Phi_f$ . Celem optymalizacji jest znalezienie takiego rozwiązania  $x^* \in V_x$  (lub  $\Phi$ ) lub  $\mathbf{x}^* \in V_x$  (lub  $\Phi$ ), którego obrazem w przestrzeni ocen  $V_f$  (lub  $\Phi_f$ ) jest najmniejszy (lub największy w przypadku maksymalizacji) element  $f^* = f(x^*)$  lub  $f^* = f(\mathbf{x}^*)$  funkcji  $f(V_x)$  lub  $f(\Phi)$ .

W przypadku optymalizacji jednokryterialnej  $\mathbf{f} \equiv f \equiv f_1$  liczba kryteriów optymalizacji  $S = 1$ ; do zdefiniowania odpowiedniego zadania minimalizacji służy powszechnie przyjęta relacja „mniejsze lub równe”:  $(V_x, \mathfrak{R}, f_1, \geq)$  lub  $(\Phi, \mathfrak{R}, f_1, \geq)$ . Ponieważ relacja „ $\geq$ ” ustanawia porządek w zbiorze ocen  $V_f = \mathfrak{R}$ , zawsze istnieje unikatowa optymalna wartość  $f_1^* = f_1(\mathbf{x}^*) \in f(V_x)$ , co oznacza, że najmniejszy element w zbiorze  $f(V_x)$  jest tylko jeden<sup>3</sup>.

W zadaniach optymalizacji wielokryterialnej  $S > 1$  określona jest nie jedna funkcja odwzorowująca  $f_1$ , ale więcej kryteriów optymalizacji<sup>4</sup>  $f_1, f_2, \dots, f_S$  interpretowanych jako skalarne składowe wektorowej funkcji celu  $\mathbf{f} = [f_1 \ f_2 \ \dots \ f_s \ \dots \ f_S]^T$ . Bez utraty ogólności dalszych rozważań można założyć, że  $V_f = \mathfrak{R}^S$  i że wszystkie składowe funkcji celu  $f_s: V_x \rightarrow \mathfrak{R}$  dla  $1 < s \leq S$  są zminimalizowane.

W przypadku wielu kryteriów oceny  $S > 1$  jako relację *rel* ustalającą (częściowy) porządek w przestrzeni ocen zazwyczaj wykorzystuje się relację  $\succeq: f_s(\mathbf{x}_1) \succeq f_s(\mathbf{x}_2) \Leftrightarrow \forall s \in \{2, 3, \dots, S\}: f_s(\mathbf{x}_1) \geq f_s(\mathbf{x}_2)$ . Tak zdefiniowana relacja jest naturalnym rozszerzeniem relacji „ $\geq$ ” na przestrzeń  $\mathfrak{R}^S$ ; w literaturze jest nazywana także słabą dominacją Pareto (ang. *weak Pareto dominance*). Relacja  $\succ: \mathbf{f}_1 \succ \mathbf{f}_2 \Leftrightarrow \mathbf{f}_1 \succeq \mathbf{f}_2 \wedge \neg \mathbf{f}_2 \succeq \mathbf{f}_1$ , wprowadzająca ściśle uporządkowanie w zbiorze ocen, nazywana jest relacją dominacji Pareto (ang. *Pareto dominance*). W przypadku tej relacji stwierdza się krótko, że ocena  $\mathbf{f}_1$  dominuje nad oceną  $\mathbf{f}_2$ . Dodatkowo można także wprowadzić i zastosować określenia „silnie dominujący” (ang. *strictly dominates*), „nieporównywalne ze sobą” (ang. *incomparable*) i „obojętne” (ang. *indifferent*) – patrz także tablica A.1<sup>5</sup>. Relacje pomiędzy wektorami decyzyjnymi są zdefiniowane na podstawie relacji pomiędzy odpowiednimi wektorami ocen, to znaczy  $\mathbf{x}_1 \text{ rel } \mathbf{x}_2 \Leftrightarrow \mathbf{f}(\mathbf{x}_1) \text{ rel } \mathbf{f}(\mathbf{x}_2)$  (inaczej  $\mathbf{x}_1 \text{ rel } \mathbf{x}_2 \Leftrightarrow \mathbf{f}_1 \text{ rel } \mathbf{f}_2$ ) – na podstawie Zitzlera i in. (2002 c):

**Definicja 3.1. Relacje dominacji (ang. *dominance relations*).** Jeśli  $V_f$  jest  $S$ -wymiarową przestrzenią ocen oraz  $\mathbf{f}_1 = [f_1(\mathbf{x}_1) \ f_2(\mathbf{x}_1) \ \dots \ f_S(\mathbf{x}_1)]^T$ ,  $\mathbf{f}_2 = [f_1(\mathbf{x}_2) \ f_2(\mathbf{x}_2) \ \dots \ f_S(\mathbf{x}_2)]^T \in V_f$  są dwoma dowolnymi wektorami ocen, to można określić następujące relacje w zbiorze  $V_f$ :

- $\mathbf{f}_1 \succ \mathbf{f}_2$  ( $\mathbf{f}_1$  dominuje nad  $\mathbf{f}_2$ ), jeśli ocena  $\mathbf{f}_1$  jest nie gorsza niż ocena  $\mathbf{f}_2$  ze względu na wszystkie kryteria oceny i jeżeli jest lepsza ze względu na co najmniej jedno kryterium;
- $\mathbf{f}_1 \succ\!\succ \mathbf{f}_2$  ( $\mathbf{f}_1$  silnie dominuje nad  $\mathbf{f}_2$ ), jeśli ocena  $\mathbf{f}_1$  jest lepsza niż ocena  $\mathbf{f}_2$  ze względu na wszystkie kryteria oceny;
- $\mathbf{f}_1 \succeq \mathbf{f}_2$  ( $\mathbf{f}_1$  słabo dominuje nad  $\mathbf{f}_2$ ), jeśli ocena  $\mathbf{f}_1$  nie jest gorsza niż ocena  $\mathbf{f}_2$  ze względu na wszystkie kryteria oceny;
- $\mathbf{f}_1 \parallel \mathbf{f}_2$  ( $\mathbf{f}_1$  i  $\mathbf{f}_2$  są nieporównywalne ze sobą), jeśli ocena  $\mathbf{f}_1$  nie dominuje słabo nad oceną  $\mathbf{f}_2$  i jeśli ocena  $\mathbf{f}_2$  nie dominuje słabo nad oceną  $\mathbf{f}_1$ .


<sup>3</sup> w przypadku silnego ekstremum; w przypadku słabego ekstremum może to być przedział lub nawet wiele przedziałów wartości zmiennej decyzyjnej, w których funkcja celu ma tę samą ekstremalną wartość.

<sup>4</sup> Autor przyjął, że w przypadku optymalizacji jednokryterialnej kryteria optymalizacji i funkcja celu są tożsame. W przypadku optymalizacji wielokryterialnej przyjął konwencję o rozróżnianiu tych określeń i stosowaniu nazwy „kryteria optymalizacji” na składowe wektorowej funkcji celu.

<sup>5</sup> Tablice oraz rysunki oznaczone dużymi literami oraz cyframi zamieszczono w załącznikach na końcu pracy.

Relacje  $\prec$ ,  $\ll$  i  $\preceq$  są definiowane w odpowiedni sposób, np. relacja  $\mathbf{f}_1 \prec \mathbf{f}_2$  jest równoważna relacji  $\mathbf{f}_2 \succ \mathbf{f}_1$ , itd. ■

Przykłady wzajemnych relacji dominacji pomiędzy parami wektorów celów zilustrowano na rysunku 3.1.



Rys. 3.1. Ilustracja możliwych relacji dominacji wektorów ocen; gdy oba kryteria oceny są minimalizowane, możliwe są następujące przypadki:  $\mathbf{f}_1 \succ \mathbf{f}_2$ ,  $\mathbf{f}_1 \succ \mathbf{f}_3$ ,  $\mathbf{f}_1 \succ \mathbf{f}_4$ ,  $\mathbf{f}_2 \succ \mathbf{f}_4$ ,  $\mathbf{f}_3 \succ \mathbf{f}_4$ ,  $\mathbf{f}_1 \gg \mathbf{f}_4$ ,  $\mathbf{f}_1 \geq \mathbf{f}_2$ ,  $\mathbf{f}_1 \geq \mathbf{f}_3$ ,  $\mathbf{f}_1 \geq \mathbf{f}_4$ ,  $\mathbf{f}_2 \geq \mathbf{f}_4$ ,  $\mathbf{f}_3 \geq \mathbf{f}_4$  i  $\mathbf{f}_2 \parallel \mathbf{f}_3$

Źródło: opracowanie własne na podstawie: Zitzler i in. (2002 d).

### 3.2. Rozwiązanie zadania optymalizacji wielokryterialnej – zbiór przybliżający front ocen rozwiązań optymalnych Pareto

Z wcześniejszych rozważań wiadomo, że w wielokryterialnych zadaniach optymalizacji powszechnie akceptowaną miarą jakości ocenianych rozwiązań zadania jest optymalność w sensie Pareto – optymalność Pareto (Pareto 1896). Określone rozwiązanie konstrukcji kadłuba statku morskiego może być uważane za optymalne w sensie Pareto, jeśli nie istnieje inne rozwiązanie tej konstrukcji, które jest lepsze pod względem przynajmniej jednego kryterium i jeżeli nie jest tak samo dobre pod względem wszystkich pozostałych kryteriów oceny. Oznacza to, że rozwiązanie optymalne Pareto KKSM nie może być ulepszone bez pogorszenia przynajmniej jednego kryterium oceny. Rozwiązania optymalne Pareto nazywa się w literaturze także rozwiązaniami niezdominowanymi (ang. *nondominated*), kompromisowymi (ang. *trade-off*), nie niższej jakości (ang. *noninferior*) lub efektywnymi Pareto (ang. *Pareto-efficient*). Rozwiązanie KKSM nie jest optymalne Pareto, jeśli istnieje inne rozwiązanie, w przypadku którego lepsze (korzystniejsze) jest przynajmniej jedno kryterium oceny i jeżeli jednocześnie nie są gorsze wszystkie pozostałe kryteria. Takie rozwiązania nazywa się także zdominowanymi (ang. *dominated*) lub podrzędnymi (ang. *inferior solutions*).

Formalizując powyższe stwierdzenia oraz wykorzystując pojęcie dominacji sformułowane przez Pareto, można zdefiniować rozwiązanie zadania optymalizacji wielokryterialnej:


**Definicja 3.2. Rozwiązanie niezdominowane (NDS)** wielokryterialnego zadania optymalizacji to każde rozwiązanie dopuszczalne, w przypadku którego nie istnieje inne

rozwiązanie dopuszczalne dominujące nad nim, przy czym uznaje się, że rozwiązanie  $\mathbf{x}_1$  dominuje (jest „lepsze” niż) nad rozwiązaniem  $\mathbf{x}_2$ , jeśli:

$$\begin{aligned} f_s(\mathbf{x}_1) &\leq f_s(\mathbf{x}_2), \text{ dla wszystkich } s = 1, 2, \dots, S, \text{ oraz} \\ f_{s'}(\mathbf{x}_1) &< f_{s'}(\mathbf{x}_2), \text{ dla przynajmniej jednego } s' = 1, 2, \dots, S \quad \blacksquare \end{aligned} \quad (3.5)$$


Z definicji NDS wynika więc, że w zbiorze rozwiązań poprawnych (dopuszczalnych) nie istnieje rozwiązanie, w przypadku którego wartość wszystkich kryteriów byłaby „lepsza” od odpowiednich wartości dla dowolnego NDS. Innymi słowy, NDS to takie rozwiązanie dopuszczalne, dla którego nie można znaleźć w zbiorze rozwiązań dopuszczalnych rozwiązania lepszego. Określenie „lepszy” należy tu rozumieć w sensie dominacji Pareto. W takim też znaczeniu określenie to będzie rozumiane w dalszej części pracy.

Koncepcję optymalności Pareto można przedstawić w postaci punktowego wykresu ocen rozwiązań (rysunek 3.2), na którym każde kryterium optymalizacji jest reprezentowane przez poszczególne osie układu współrzędnych, a istniejące oceny rozwiązań dopuszczalnych  $f_1, f_2, \dots, f_S$  reprezentowane są przez punkty na wykresie. Z oczywistych względów wykonanie takiego wykresu jest łatwe w przypadku zadań z dwoma kryteriami  $S = 2$ , ale jest dużo trudniejsze lub nawet niemożliwe w przypadku zadań z trzema lub większą liczbą kryteriów oceny. W przypadku zadania z dwoma kryteriami oceny  $f_1$  i  $f_2$ , które powinny być minimalizowane, rozwiązaniem optymalnym Pareto jest każde rozwiązanie, w przypadku którego nie istnieją inne rozwiązania, których oceny leżą poniżej i na lewo od oceny tego rozwiązania (optymalnego Pareto). Rozwiązaniem optymalnym Pareto jest zatem każde rozwiązanie, którego ocena nie jest zdominowana przez ocenę jakiegokolwiek innego rozwiązania. Oceny rozwiązań optymalnych Pareto nazywać będziemy ocenami optymalnymi Pareto. Zbiór rozwiązań optymalnych Pareto nazywać będziemy zbiorem Pareto, a zbiór ocen rozwiązań optymalnych Pareto – frontem Pareto. Rozwiązanie zdominowane to każde rozwiązanie, którego ocena leży powyżej i na prawo od oceny jakiegokolwiek innego rozwiązania. Oceny rozwiązań zdominowanych nazywać będziemy ocenami zdominowanymi.



Rys. 3.2. Ilustracja możliwych relacji pomiędzy rozwiązaniami w przestrzeni ocen; zaznaczono oceny zdominowane przez wybraną ocenę dopuszczalną oraz oceny dominujące nad tą oceną; oceny niezdominowane przez jakiejkolwiek inne oceny w zbiorze tworzą zbiór ocen optymalnych Pareto

Gdyby w konkretnym zadaniu zbiór dopuszczalny był nieprzeliczalny i był podzbiorem  $\mathfrak{R}^n$ , wówczas zbiór ocen osiągalnych byłby również ciągły i byłby podzbiorem  $\mathfrak{R}^2$  (dwa kryteria jakości,  $S = 2$ ). W wyniku analizy zbioru ocen osiągalnych można zatem otrzymać nie tylko skończoną liczbę rozwiązań niezdominowanych, ale całą krzywą ocen niezdominowanych, co przedstawiono na rysunku 3.3.



Rys. 3.3. Ilustracja występujących w pracy oznaczeń i nazw elementów, zbiorów oraz relacji:  $V_x$  – przestrzeń poszukiwań (przestrzeń rozwiązań, przestrzeń wariantów); zbiór rozwiązań możliwych;  $\Phi$  – przestrzeń rozwiązań dopuszczalnych (zbiór rozwiązań dopuszczalnych);  $\Psi$  – przestrzeń dopuszczalnych rozwiązań zadania optymalizacji wielokryterialnej, dla których spełniona jest dodatkowo relacja porządkująca  $rel$  (jeśli  $rel$  oznacza relację dominacji Pareto,  $\Psi$  oznacza zbiór rozwiązań optymalnych Pareto);  $V_f$  – przestrzeń ocen (przestrzeń jakości, przestrzeń kryterialna);  $\Phi_f$  – przestrzeń ocen dopuszczalnych

Pojęcie dominacji Pareto wprowadza dwuwartościową miarę jakości rozwiązań MOOP, a tym samym umożliwia podział zbioru rozwiązań dopuszczalnych zadania (wariantów dopuszczalnych) na dwa podzbiory – (1) podzbiór NDS, kompromisowych  $\Psi_f$ , które mogą być uznane za rozwiązanie MOOP, oraz (2) podzbiór rozwiązań zdominowanych  $\Phi_f - \Psi_f$ , które nie są użytecznym w praktyce rezultatem rozwiązywania MOOP. Dwuwartościowość tej miary nie poz-

wala na pełniejszą ocenę zbioru zdominowanych rozwiązań dopuszczalnych<sup>6</sup>, a w szczególności nie umożliwia oceny względnej odległości wariantów zdominowanych od frontu Pareto zbudowanego z ocen niezdominowanych przez jakąkolwiek inną ocenę dopuszczalną. Mimo to relacja dominacji Pareto jest najczęściej spotykaną relacją, służącą do zdefiniowania rozwiązania wielokryterialnego zadania optymalizacji. W dalszej części pracy przez relację dominacji rozumieć więc należy dominację w sensie Pareto, a użyte wyżej sformułowanie „zoptymalizuj wektorową funkcję celu  $\mathbf{f}$ ” rozumieć należy jako polecenie: W zbiorze rozwiązań dopuszczalnych odszukaj rozwiązania niezdominowane w odniesieniu do relacji dominacji Pareto. Przykładami innych relacji porządkujących  $S$ -wymiarową przestrzeń kryterialną jest relacja porządku leksykograficznego lub porządku liniowego, określona w stosunku do funkcji skalaryzującej (Cohon 1978, Hwang i Masud 1979, Hwang i Yoon 1981).

Rozwiązaniem MOOP jest każde dopuszczalne rozwiązanie  $\mathbf{f}_{\succ}$ , dla którego nie istnieje inne rozwiązanie dopuszczalne  $\mathbf{f}_j$ , które dominuje nad nim, to znaczy takie, w przypadku którego wartości wszystkich kryteriów są lepsze od odpowiednich wartości dla rozwiązania  $\mathbf{f}_{\succ}$ . Określenie „lepszy” rozumieć należy w sensie Pareto. W takim kontekście zadanie optymalizacji wielokryterialnej można przedstawić w formie krótkiego zdania: Należy wygenerować i znaleźć wszystkie niezdominowane rozwiązania  $\mathbf{f}_{\succ} \in \Psi_f$  postawionego zadania. Polecenie: Zoptymalizuj wektorową funkcję celu  $\mathbf{f}$  należy zatem rozumieć jako polecenie: W zbiorze ocen (rozwiązań) dopuszczalnych  $\Phi_f$  znajdź zbiór  $\Psi_f$  ocen (rozwiązań) niezdominowanych w sensie dominacji Pareto  $\mathbf{f}_{\succ}$  (rysunek 3.3).

Przypomnijmy, że sformułowana wyżej formalna definicja zadania optymalizacji zakłada, że poszukiwane jest tylko jedno rozwiązanie, które jest odwzorowane w przestrzeni ocen przez ocenę o minimalnej wartości, podczas gdy w przypadku zadania z wieloma kryteriami optymalizacji poszukuje się zazwyczaj całego zbioru optymalnego Pareto, a nie pojedynczego rozwiązania wybranego w arbitralny sposób. Prowadzi to w konsekwencji do innego zadania, nadal jednak nazywanego zadaniem optymalizacji, w którym przestrzeń poszukiwań zawiera również zbiór wektorów decyzji (rozwiązań, wariantów), przy czym przestrzeń ocen (kryteriów) zawiera zbiory wektorów ocen (wektorów kryterialnych). Mówiąc bardziej precyzyjnie, poszukiwanie skupia się na znalezieniu zbioru  $\Psi_f$  nieporównywalnych wzajemnie ocen (przypomnijmy, że oznacza to, iż w przypadku dwóch dowolnych ocen  $\mathbf{f}_1$  i  $\mathbf{f}_2$  żadna z nich nie dominuje słabo nad drugą,  $\mathbf{f}_1 \parallel \mathbf{f}_2$ :  $\mathbf{f}_1 \not\preceq \mathbf{f}_2$  i  $\mathbf{f}_2 \not\preceq \mathbf{f}_1$ ); nazywać je będziemy przybliżeniami zbioru Pareto (ang. *Pareto set approximations*) zdefiniowanymi poniżej (na podstawie Zitzler i in. 2002 c):

**Definicja 3.3. Zbiór przybliżający (AS).** Niech  $\Psi_f$  będzie zbiorem wektorów oceny w przestrzeni ocen:  $\Psi_f \subseteq V_f$ . Zbiór  $\Psi_f$  nazywany jest zbiorem przybliżającym, jeśli dowolny wektor oceny należący do zbioru  $\Psi_f$  nie jest zdominowany przez inny wektor oceny lub nie jest równy innemu wektorowi oceny w zbiorze  $\Psi_f$ . ■

Wprowadźmy także oznaczenie  $\Lambda_f$  dla zbiorów wszystkich przybliżeń  $\Psi_f$  frontu Pareto w przestrzeni ocen  $V_f$ . Odpowiednio zbiory wzajemnie nieporównywalnych wektorów ocen nazywać będziemy przybliżeniami frontu Pareto  $\Psi_f$ , a zbiór wszystkich przybliżeń

---

<sup>6</sup> bardziej szczegółowej analizy zbioru rozwiązań dopuszczalnych w odniesieniu do relacji dominacji. Relacja dominacji nie rozróżnia wielu szczegółów w zbiorze ocen rozwiązań, a uwzględnia jedynie to, czy rozwiązanie jest zdominowane lub czy jest niezdominowane.



frontu Pareto w przestrzeni ocen  $V_f$  oznaczać będziemy symbolem  $\Lambda_f$ , czyli że  $\Psi_f \subset \Lambda_f$ . W wielu zastosowaniach, między innymi w projektowaniu inżynierskim, znajomość zbioru  $\Psi_f$  przybliżającego zbiór ocen rozwiązań optymalnych Pareto dostarcza bardzo wartościowych informacji o rozwiązywanym problemie i ułatwia podejmowanie decyzji.

W zadaniach optymalizacji wielokryterialnej wiele rozwiązań minimalizujących wektorową funkcję celu  $\mathbf{f}(\Psi)$  można połączyć w jeden zbiór  $\Psi_f$ , w którym każde rozwiązanie  $\mathbf{f}_{\succ} \in \Psi_f$  reprezentuje inny kompromis pomiędzy kryteriami oceny (rysunek 3.3). Elementy „minimalne” nazywane są elementami optymalnymi Pareto, w związku z czym wektor decyzyjny  $\mathbf{x}_{\succ}$  jest optymalny Pareto, jeśli jest odwzorowywany na optymalny w sensie Pareto wektor ocen rozwiązań  $\mathbf{f}_{\succ}$ . Zbiór wszystkich optymalnych w sensie Pareto wektorów ocen rozwiązań  $\Psi_f$  nazywany jest frontem Pareto, a zbiór wszystkich rozwiązań optymalnych Pareto  $\mathbf{x}_{\succ}$  tworzy zbiór optymalny Pareto  $\Psi$ . Ponieważ – podobnie jak w przypadku zadania jednokryterialnego – kilka rozwiązań może być odwzorowanych do tego samego wektora ocen, front ocen optymalnych Pareto nie musi zawierać takiej samej liczby elementów co zbiór optymalny Pareto; wynika stąd, że zbiór rozwiązań (wariantów) optymalnych Pareto nie może być mniej liczny niż front ocen optymalnych Pareto.

Napisano już wyżej, że uogólniając zadanie optymalizacji jednokryterialnej ( $S = 1$ ) do postaci zadania z większą liczbą kryteriów optymalizacji ( $S \geq 2$ ), także ono może być traktowane jako zbiór czterech elementów  $(V_x, \mathfrak{R}^S, \mathbf{f}, rel)$ , gdzie  $V_x$  oznacza przestrzeń poszukiwania (przestrzeń rozwiązań),  $\mathfrak{R}^S$  oznacza  $S$ -wymiarową przestrzeń ocen mierzonych liczbami rzeczywistymi,  $\mathbf{f}: V_x \rightarrow \mathfrak{R}^S$  jest wektorową funkcją przyporządkowującą każdemu rozwiązaniu lub wektorowi decyzyjnemu  $\mathbf{x} \in V_x$  odpowiedni wektor kryteriów optymalizacji  $\mathbf{f}(\mathbf{x}) \in \mathfrak{R}^S$ , a  $rel$  reprezentuje dwuargumentową relację określoną na  $\mathfrak{R}^S$ , która określa częściowy porządek w przestrzeni ocen. Celem optymalizacji wielokryterialnej jest znalezienie rozwiązania optymalnego Pareto  $\mathbf{x}_{\succ} \in \Psi \subset \Phi \subset V_x$ , którego obrazem w przestrzeni ocen  $V_f$  jest ocena optymalna Pareto  $\mathbf{f}_{\succ} = \mathbf{f}(\mathbf{x}_{\succ}) \in \Psi_f \subset \Phi_f \subset V_f$ . Jeżeli relacją  $rel$ , ustalającą porządek w zbiorze ocen jest któraś z przedstawionych w tablicy A.1 relacji dominacji, to każde zadanie optymalizacji wielokryterialnej może być reprezentowane przez jeden z następujących zbiorów czterech elementów:  $(V_x, \mathfrak{R}^S, \mathbf{f}, \succcurlyeq)$  lub  $(V_x, \mathfrak{R}^S, \mathbf{f}, \succ)$  lub  $(V_x, \mathfrak{R}^S, \mathbf{f}, \succeq)$ .

### 3.3. Relacje preferencji zbiorów przybliżających

Jeszcze do niedawna podstawowym problemem badaczy i praktyków zajmujących się optymalizacją wielokryterialną było uzyskanie przynajmniej jednego zbioru zawierającego nawet niewielką liczbę atrakcyjnych rozwiązań niezdominowanych. Dokonany w ostatnich latach postęp w rozwoju metod optymalizacji wielokryterialnej, w szczególności ewolucyjnych algorytmów optymalizacji wielokryterialnej, oraz zwiększenie możliwości obliczeniowych powszechnie dostępnych komputerów osobistych spowodowało, że uzyskanie pojedynczych rozwiązań niezdominowanych przestało być już problemem najważniejszym. Uwaga badaczy zaczyna przesuwac się z poziomu pojedynczych ocen rozwiązań niezdominowanych, należących do zbioru przybliżającego  $\Psi_f$ , na poziom wyższy – zbiorów przybliżających  $\Psi_f$ , należących do zbioru przybliżeń  $\Lambda_f$  zawierającego zbiory przybliżające:  $\Psi_f \subset \Lambda_f$ . W takim wypadku nie wystarczają już ocena względna i wzajemne relacje preferencji rozwią-

zań niezdominowanych wewnątrz zbioru przybliżającego  $\Psi_f$ , konieczne jest ustalenie relacji preferencji zbiorów przybliżających  $\Psi_f$  wewnątrz zbioru przybliżeń  $\Lambda_f$ , a także opracowanie narzędzi względnej oceny zbiorów przybliżających  $\Psi_f$  wewnątrz zbioru przybliżeń  $\Lambda_f$ .

Relacje preferencji określone dla ocen dopuszczalnych  $\mathbf{f}_f$ , omówione w podrozdziale 3.1 i podane w tablicy A.1, można w naturalny sposób rozszerzyć na zbiory  $\Psi_f$  ocen rozwiązań niezdominowanych przybliżające front Pareto (patrz tablica A.2). W przypadku frontu Pareto i przybliżeń zbioru Pareto używać można tych samych symboli, które zostały wcześniej użyte w przypadku relacji preferencji wektorów ocen i wektorów decyzyjnych – z kontekstu wynika jasno, do których elementów odnosi się określona relacja. Ponadto w przypadku zbiorów przybliżających wprowadzić można dodatkową relację  $\triangleright$  zaklasyfikowaną pomiędzy słabą a zwykłą dominacją Pareto.

Uogólniając odpowiednie określenie wprowadzone w podrozdziale 3.1., w dalszej części pracy zakładamy, że  $(\Phi, \Phi_f, \mathbf{f}, \succ)$  jest rozważanym scenariuszem optymalizacji wielokryterialnej, gdzie  $\succ$  oznacza relację dominacji Pareto określoną na przybliżeniach  $\Psi_f$  frontu optymalnego Pareto  $\Psi_P$ . W takim sformułowaniu, które jest powszechnie używane w społeczności badaczy ewolucyjnych algorytmów optymalizacyjnych, front optymalny Pareto jest jedynym minimalnym elementem spełniającym  $\mathbf{f}(\Phi)$ , przy uwzględnieniu w pełni uporządkowanego zbioru  $(\Lambda_f, \succ)$ . W praktyce jednak uzyskanie zbioru wektorów konstrukcji kadłuba statku, reprezentujących pełen front optymalny Pareto  $\Psi_P$ , jest zazwyczaj trudne z kilku powodów: (a) liczba rozwiązań optymalnych Pareto jest zbyt duża, aby było to możliwe w akceptowalnym czasie i przy zaangażowaniu akceptowalnych nakładów obliczeniowych; (b) niekiedy nawet uzyskanie jednego rozwiązania optymalnego Pareto jest złożonym problemem obliczeniowym. Dlatego praktycznym zadaniem optymalizacji wielokryterialnej jest otrzymanie i zidentyfikowanie zadowalającego przybliżenia frontu Pareto, co oznacza możliwie „bliski” zbiór (przy danych możliwościach obliczeniowych), optimum w rozumieniu zdefiniowanej wyżej relacji słabej dominacji Pareto. Od tego momentu dalsze rozważania prowadzone będą według następującego scenariusza: rozważając względną jakość zbiorów rozwiązań niezdominowanych, stosować będziemy jedynie te metody, które odnoszą się do koncepcji dominacji Pareto.

Dokonajmy jeszcze następujących uproszczeń: (1) algorytm zaprojektowany do rozwiązania problemu optymalizacyjnego  $(\Phi, \Phi_f, \mathbf{f}, \succ)$  nazywać będziemy optymalizatorem wielokryterialnym (ang. *multiobjective optimizer*); (2) mimo że optymalizatory wielokryterialne generują zbiór wektorów konstrukcyjnych (punktów w przestrzeni konstrukcji, przestrzeni rozwiązań, przestrzeni wariantów, przestrzeni decyzji), w dalszej części opracowania rozważać będziemy tylko przybliżenia frontu Pareto określone w przestrzeni ocen<sup>7</sup>; (3) przez zbiór przybliżający będziemy rozumieć przybliżenie frontu Pareto.

W ogromnej większości prac, dotyczących ewolucyjnej optymalizacji wielokryterialnej uwaga badaczy skupiona jest na problemie, w jaki sposób w zbiorze wszystkich możliwych rozwiązań (lub w zbiorze wszystkich rozwiązań dopuszczalnych, jeśli sformułowano

---

<sup>7</sup> Powodem wprowadzenia takiego uproszczenia jest to, że ocena jakości rezultatów zazwyczaj przeprowadzana jest w przestrzeni ocen; problemu oceny rezultatów działania optymalizatora wielokryterialnego, z uwzględnieniem przestrzeni rozwiązań, nie będziemy poruszać.



ograniczenia dotyczące wartości zmiennych decyzyjnych), zidentyfikować rozwiązania optymalne Pareto lub, jeśli nie jest to możliwe, uzyskać dobre przybliżenia tych rozwiązań. Akceptując stwierdzenie to jako podstawę naszych rozważań, przyjmijmy, że rezultatem ewolucyjnej optymalizacji wielokryterialnej jest zbiór nieporównywalnych rozwiązań budujących zbiór przybliżający  $\Psi_f$  (zob. definicja 3.3). Zbiór wszystkich zbiorów przybliżających oznaczmy jako  $\Lambda_f$ .  $\Psi_f \subseteq \Lambda_f \subseteq \Phi_f \subseteq V_f$ . Motywacją dla takiego ustalenia jest fakt, że wszystkie wygenerowane przez algorytm optymalizacyjny rozwiązania, zdominowane przez jakiekolwiek inne rozwiązanie, nie są interesujące i mogą być pominięte. W dalszej części pracy przyjęto takie właśnie uproszczenie.


Zwróćmy uwagę, że definicja zbioru przybliżającego  $\Psi_f$  (definicja 3.3) nie odnosi się w jakikolwiek sposób do jakości rozwiązań niezdominowanych  $\mathbf{f}_{\succ}$  lub całych zbiorów przybliżających  $\Psi_f$ , poza tym oczywiście, że jakość rozwiązań niezdominowanych  $\mathbf{f}_{\succ}$  jest wyższa niż rozwiązań zdominowanych  $\mathbf{f}_{\prec}$ . Rzecz jasna, że w praktyce nie jesteśmy zainteresowani uzyskaniem jakiegokolwiek zbioru przybliżającego  $\Psi_f$ , ale chcemy, aby optymalizator wygenerował dobry zbiór przybliżający. Co znaczy „dobry” jest jednak nadal problemem dyskusyjnym; przedstawieniu prób jego rozwiązania poświęcono rozdział 5 pracy. W skrajnym przypadku celem ewolucyjnej optymalizacji wielokryterialnej jest zidentyfikowanie nie jakiegokolwiek frontu Pareto, zbioru ocen rozwiązań niezdominowanych, ale frontu optymalnego Pareto  $\Psi_P$ , który jest zbiorem wszystkich rozwiązań optymalnych Pareto. Zwykle cel ten (front optymalny Pareto  $\Psi_P$ ) jest jednak nieosiągalny – można traktować go jedynie jako rozwiązanie asymptotyczne, do którego zdążają generowane rozwiązania dopuszczalne, ale nigdy go nie osiągną. W praktyce przy ograniczonych zasobach obliczeniowych trzeba zadowolić się właśnie „dobrym” przybliżeniem  $\Psi_f$  tego zbioru. Poza tym nie jest możliwe dokładne opisanie, co jest dobrym przybliżeniem w przypadku sformułowania zbioru kryteriów, takich jak: bliskość frontu optymalnego Pareto, liczność zbioru rozwiązań niezdominowanych, zróżnicowanie ocen w zbiorze przybliżającym. Niemniej jednak oceniając otrzymane rezultaty, można próbować sformułować pewne wnioski, także ilościowe, dotyczące jakości zbioru przybliżającego w porównaniu z innym zbiorem przybliżającym (innymi zbiorami przybliżającymi).

Jako przykład rozważmy trzy hipotetyczne zbiory przybliżające  $\Psi_1$ ,  $\Psi_2$  i  $\Psi_3$  przedstawione na rysunku 3.4. Na tym samym rysunku pokazano także rozwiązania należące do frontu optymalnego Pareto  $\Psi_P$  przybliżonego tymi zbiorami przybliżającymi. Wyłącznie na podstawie relacji dominacji Pareto można stwierdzić, że dwa zbiory przybliżające  $\Psi_1$  i  $\Psi_2$  są lepsze od zbioru  $\Psi_3$ , ponieważ każde rozwiązanie w zbiorze przybliżającym  $\Psi_3$  jest zdominowane przynajmniej przez jedno rozwiązanie należące do pozostałych zbiorów przybliżających  $\Psi_1$  i  $\Psi_2$ . Ponadto zbiór przybliżający  $\Psi_1$  może być uznany za lepszy<sup>8</sup> od zbioru  $\Psi_2$ , ponieważ zawiera wszystkie rozwiązania należące także do  $\Psi_2$ , poza tym jedno rozwiązanie należące do  $\Psi_1$  nie należy do  $\Psi_2$ ; stwierdzenie to jest jednak słabsze od poprzedniego (nie jest tak zdecydowane jak poprzednie).

---

<sup>8</sup> Musimy pamiętać, że określenie „lepszy” ma już swoją formalną definicję, a zatem należy ostrożnie używać tego określenia w znaczeniu kolokwialnym. W rozdziale 7 określenie „lepszy” stanie się cechą zbiorów przybliżających mierzoną za pomocą odpowiednich wskaźników jakości.

Na podstawie rysunku 3.4 oraz relacji preferencji zbiorów przybliżających, podanych w tablicy A.2, można odpowiednio zilustrować cztery poziomy nadrzędności (ang. *superiority*) zbiorów przybliżających: (1) zbiór  $\Psi_A$  silnie dominuje nad zbiorem  $\Psi_B$  ( $\Psi_A \gg \Psi_B$ ), (2) zbiór  $\Psi_A$  dominuje nad zbiorem  $\Psi_B$  ( $\Psi_A \succ \Psi_B$ ), (3) zbiór  $\Psi_A$  jest lepszy od zbioru  $\Psi_B$  ( $\Psi_A \triangleright \Psi_B$ ) oraz (4) zbiór  $\Psi_A$  słabo dominuje nad zbiorem  $\Psi_B$  ( $\Psi_A \succeq \Psi_B$ ), gdzie:  $\Psi_A \gg \Psi_B \Rightarrow \Psi_A \succ \Psi_B \Rightarrow \Psi_A \triangleright \Psi_B \Rightarrow \Psi_A \succeq \Psi_B$ . Omówmy te przypadki bardziej szczegółowo.



Rys. 3.4. Ilustracja wyników optymalizacji wielokryterialnej w przypadku dwuwymiarowego zadania minimalizacji. Odpowiednie zbiory przybliżające oznaczone są symbolami  $\Psi_1$ ,  $\Psi_2$  i  $\Psi_3$ , front rozwiązań optymalnych Pareto  $\Psi_P$  zawiera trzy wektory oceny, pomiędzy zbiorami przybliżającymi  $\Psi_1$ ,  $\Psi_2$  i  $\Psi_3$  zachodzą następujące relacje dominacji:  $\Psi_1 \succ \Psi_3$ ,  $\Psi_2 \succ \Psi_3$ ,  $\Psi_1 \gg \Psi_3$ ,  $\Psi_1 \succeq \Psi_2$ ,  $\Psi_1 \succeq \Psi_3$ ,  $\Psi_2 \succeq \Psi_3$ ,  $\Psi_1 \triangleright \Psi_2$ ,  $\Psi_1 \triangleright \Psi_3$  i  $\Psi_2 \triangleright \Psi_3$

Źródło: opracowanie własne na podstawie: Zitzler i in. (2002 c).

W 4. i 3. wierszu tablicy A.2 słaba dominacja  $\Psi_A \succeq \Psi_B$  oznacza, że w zbiorze przybliżającym  $\Psi_B$  każda ocena rozwiązania jest słabo zdominowana przynajmniej przez jedną ocenę rozwiązania należącą do zbioru przybliżającego  $\Psi_A$ . Jednak nie wyklucza to równości obu zbiorów, ponieważ w przypadku wszystkich zbiorów przybliżających  $\Psi_A \subset \Lambda$  zachodzi relacja słabej dominacji:  $\Psi_A \succeq \Psi_A$ . W takim przypadku nie można wnioskować, że zbiór przybliżający  $\Psi_A$  jest lepszy od zbioru przybliżającego  $\Psi_B$ . Zamiast tego można użyć relacji „lepszy”  $\triangleright$ , ponieważ reprezentuje ona bardziej ogólną i słabszą relację wyższości. Wymaga ona, w przybliżeniu, aby pierwszy zbiór przybliżający był przynajmniej tak samo dobry jak inny zbiór przybliżający ( $\Psi_A \succeq \Psi_B$ ), podczas gdy ten ostatni nie jest tak samo dobry jak pierwszy ( $\Psi_B \not\succeq \Psi_A$ ). W tym przykładzie, przedstawionym na rysunku 3.4, zbiór  $\Psi_1$  jest lepszy od zbioru  $\Psi_2$  i  $\Psi_3$ , ( $\Psi_1 \triangleright \Psi_2$ ) i ( $\Psi_1 \triangleright \Psi_3$ ), a zbiór  $\Psi_2$  jest lepszy od zbioru  $\Psi_3$  ( $\Psi_2 \triangleright \Psi_3$ ). Takie rozumienie nadrzędności jest domyślnie używane w większości prac dotyczących ewolucyjnych algorytmów optymalizacji wielokryterialnej.

Następny poziom nadrzędności (relacja dominacji  $\succ$ ) – zob. 2. wiersz tablicy A.2, jest bezpośrednim rozszerzeniem relacji dominacji Pareto na zbiory przybliżające. Rozróżnia ona sytuację, w której dwa zbiory  $\Psi_A$  i  $\Psi_B$  są takie same i dlatego relacja ta jest dokładniejsza (silniejsza) niż zazwyczaj jest to potrzebne<sup>9</sup>. Jak to już napisano, zbiory przybliżające  $\Psi_1$  i  $\Psi_2$

<sup>9</sup> Według niektórych badaczy ważniejsza jest relacja słabej dominacji Pareto „ $\succeq$ ”, która dopuszcza równość zbiorów przybliżających.

dominują nad zbiorem  $\Psi_3$ , ( $\Psi_1 \succ \Psi_3$ ) i ( $\Psi_2 \succ \Psi_3$ ), ale zbiór  $\Psi_1$  nie dominuje nad zbiorem  $\Psi_2$ , ( $\Psi_1 \not\succ \Psi_2$ ).

W 1. wierszu tablicy A.2 silna dominacja  $\succ\succ$  jako najwyższy poziom nadrzędności oznacza, że zbiór przybliżający  $\Psi_i$  jest nadrzędny<sup>10</sup> wobec wszystkich pozostałych zbiorów przybliżających  $\Psi_{j \neq i}$  w takim znaczeniu, że dla dowolnej oceny rozwiązania w zbiorze  $\Psi_j$  istnieje w zbiorze  $\Psi_i$  ocena, która dominuje nad nim pod względem wszystkich kryteriów oceny. Na rysunku 3.4 zbiór przybliżający  $\Psi_1$  silnie dominuje nad zbiorem  $\Psi_3$ , ( $\Psi_1 \succ\succ \Psi_3$ ) – ponieważ dla każdej oceny rozwiązania w zbiorze  $\Psi_3$  istnieje w zbiorze  $\Psi_1$  przynajmniej jedna ocena, która dominuje nad nim pod względem wszystkich kryteriów oceny – ale zbiór  $\Psi_2$  nie dominuje silnie nad zbiorem  $\Psi_3$ , ( $\Psi_2 \not\succ\succ \Psi_3$ ), ponieważ należący do zbioru  $\Psi_3$  wektor ocen  $[9\ 4]^T$  nie jest silnie zdominowany przez jakikolwiek wektor należący do zbioru  $\Psi_2$ .

Można w tym miejscu zadać pytanie: Czy, biorąc pod uwagę przedstawione na rysunku 3.4 trzy hipotetyczne zbiory przybliżające  $\Psi_1$ ,  $\Psi_2$  i  $\Psi_3$  można wnioskować o tym, że któryś zbiór jest lepszy od innego? Mówiąc inaczej: Czy zbiory te różnią się jakością? Można również skupić uwagę na algorytmach optymalizacyjnych i zadać pytanie: Czy, biorąc pod uwagę przedstawione na rysunku 3.4 rezultaty zastosowania trzech hipotetycznych algorytmów, można wnioskować o tym, że któryś algorytm jest lepszy, skuteczniejszy od innego? Aby na to pytanie odpowiedzieć, należy rozszerzyć relację dominacji z pojedynczych ocen  $\mathbf{f}$  na zbiory przybliżające  $\Psi_f$  (na podstawie Zitzler i in. 2002 c):

**Definicja 3.4. Relacja dominacji na zbiorach przybliżających (ang. *dominance relations on approximation sets*).** Niech  $\Psi_A$  i  $\Psi_B \in \Lambda_f$  będą dwoma zbiorami przybliżającymi. Możemy zapisać, że  $\Psi_A \succ \Psi_B$  (zbiór  $\Psi_A$  dominuje nad zbiorem  $\Psi_B$ ), jeśli każdy element (ocena rozwiązania) w zbiorze przybliżającym  $\Psi_B$  jest zdominowany przynajmniej przez jeden element należący do zbioru  $\Psi_A$ ; pozostałe relacje dominacji ( $\succ\succ$ ,  $\succeq$ ,  $\prec$ ,  $\preceq$ ,  $\preceq$ ) definiowane są w odpowiedni sposób. Ponadto mówimy, że (1) zbiór przybliżający  $\Psi_A$  jest lepszy niż zbiór  $\Psi_B$  ( $\Psi_A \triangleright \Psi_B$  lub równoważnie  $\Psi_B \triangleleft \Psi_A$ ), jeśli  $\Psi_A \succeq \Psi_B$  i  $\Psi_A \neq \Psi_B$  oraz że (2) zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  są wzajemnie nieporównywalne ( $\Psi_A \parallel \Psi_B$ ), jeśli jednocześnie nie zachodzi  $\Psi_A \succeq \Psi_B$  i  $\Psi_B \succeq \Psi_A$ . ■

Zgodnie z tą definicją rozważmy pewien zbiór przybliżający  $\Psi_1$  lepszy od innego, np.  $\Psi_2$  ( $\Psi_1 \triangleright \Psi_2$ ) w przykładzie zilustrowanym na rysunku 3.4, jeśli w tym ostatnim ( $\Psi_2$ ) nie istnieje ocena rozwiązania słabo zdominowana przez jakąkolwiek ocenę ze zbioru pierwszego ( $\Psi_1$ ) i jeśli ten pierwszy zbiór zawiera przynajmniej jedną ocenę rozwiązania, która nie jest słabo zdominowana przez jakąkolwiek ocenę należącą do drugiego zbioru ( $\Psi_2$ ). W przykładzie zbiór  $\Psi_1$  jest lepszy od zbioru  $\Psi_2$  ( $\Psi_1 \triangleright \Psi_2$ ) i silnie dominuje nad zbiorem  $\Psi_3$  ( $\Psi_1 \succ\succ \Psi_3$ ); ponadto zbiór  $\Psi_2$  dominuje nad zbiorem  $\Psi_3$  ( $\Psi_2 \succ \Psi_3$ ).

### 3.4. Podsumowanie i wnioski

Powszechnie akceptowanymi rozwiązaniami wielokryterialnych zadań optymalizacji są zbiory przybliżające front rozwiązań optymalnych Pareto. Podstawą budowy zbiorów przybliżających jest relacja dominacji w sensie Pareto. Pozwala ona na wprowadzenie częściowego porządku w zbiorze ocen rozwiązań dopuszczalnych i wyselekcjonowanie spośród

<sup>10</sup> W tym miejscu można odczuwać bardzo silną pokusę używania określenia „lepszy”, jednak przyjmijmy, że należy je rozumieć w sposób przedstawiony w tablicy A.2.

nich ocen rozwiązań niezdominowanych budujących zbiory przybliżające. Liczność zbioru przybliżającego nie jest określona i w praktyce zawiera wiele ocen rozwiązań równoważnych, bez obiektywnych możliwości wskazania najlepszego rozwiązania lub najlepszych rozwiązań w zbiorze przybliżającym. Relacja dominacji ocen rozwiązań może być rozszerzona na zbiory przybliżające i może posłużyć do określenia relacji preferencji zbiorów przybliżających, a więc do wstępnej oceny jakości zbiorów przybliżających i/lub skuteczności optymalizatorów, które wykorzystano w celu uzyskania tych zbiorów.

Ilościowa dyskusja nad jakością zbiorów przybliżających oraz propozycje miar jakości zostaną zaprezentowane i omówione w rozdziale 5.

W następnym rozdziale przedstawiono i omówiono metody ewolucyjnej optymalizacji wielokryterialnej, to znaczy ewolucyjne metody poszukiwania zbiorów przybliżających front ocen rozwiązań optymalnych Pareto.

## 4. Poszukiwanie zbiorów przybliżających

### 4.1. Oczekiwany rezultat optymalizacji wielokryterialnej

Optymalizacja wielokryterialna stała się tematem licznych monografii i innych publikacji książkowych (np. *Multiobjective Optimization in Engineering and in the Sciences* 1988, Eschenauer i in. 1990, Statnikov i Matosov 1995, Miettinen 1998, Sen i Yang 1998, Tarnowski 2009, 2011, Köksalan i in. 2011). Nieliczne są prace dotyczące wielokryterialnej optymalizacji konstrukcji kadłuba statku (np. Das i in. 1993, Zanic i in. 1993, Ray i Sha 1994, Trincas i in. 1994, Sen i Yang 1995, Jianguo i Zuoshui 1996, Parsons i Singer 2000, Klanac i in. 2009, Caprace i in. 2010, Sekulski 2010, 2011 a, b, c). Bardziej szczegółowo przedstawiono to w podrozdziale 1.1.

Istotny wkład w teorię i praktykę optymalizacji wielokryterialnej wnieśli także polscy autorzy. Konarzewska-Gubała (1980) na przykład omawia teoretyczne podstawy optymalizacji wielokryterialnej z punktu widzenia zastosowań w ekonomii. Tarnowski (1984) przedstawił dyskusję nad procesem wyboru w różnych fazach projektowania technicznego oraz zaproponował ogólny model procesu wyboru, przy czym wybór może dotyczyć konstrukcji całego obiektu lub jego części, systemu projektującego lub samej procedury projektowania. Osiński i Wróbel (1995) omówili wybrane metody optymalizacji wielokryterialnej oraz przedyskutowali koncepcję dekompozycji dużych zadań optymalizacji wielokryterialnej. Paczkowski (1999) przedstawił problemy związane z formułowaniem zadań optymalizacji i MOOP obiektów budowlanych. Zaproponował oryginalną orto-diagonalną metodę optymalizacji i optymalizacji wielokryterialnej obiektów dyskretnych. Jaszkievicz (2001) przedyskutował aktualny stan badań nad ewolucyjnymi algorytmami optymalizacji wielokryterialnej oraz zaproponował własne metody optymalizacji wielokryterialnej oparte na symulowanym wyżarzaniu i algorytmie genetycznym. Osyczka (2002) przedstawił podstawy optymalizacji wielokryterialnej oraz zaawansowane metody ewolucyjnej optymalizacji wielokryterialnej (EMOA). Niczyj (2003) zastosował optymalizację wielokryterialną oraz teorię zbiorów rozmytych do oceny niezawodności oraz szacowania stanu technicznego konstrukcji prętowych w budownictwie. Tarnowski (2009, 2011) przedstawił bardzo szczegółową dyskusję nad metodami formułowania i rozwiązywania technicznych problemów optymalizacji wielokryterialnej.

Duże znaczenie problematyki optymalizacji wielokryterialnej, zarówno w aspekcie teoretycznym, jak i praktycznym, potwierdza fakt organizowania w kraju i za granicą cyklicznych konferencji naukowych. W kraju są to organizowane przez Wyższą Szkołę Inżynierską w Koszalinie (corocznie od 1982 roku) konferencje pt. „Polioptymalizacja w projektowaniu”, a następnie pt. „Polioptymalizacja i komputerowe wspomaganie projektowania” (Tarnowski 2007); w czerwcu 2012 roku odbędzie się 30. konferencja. Pierwsze cztery konferencje (w latach 1982–1985) zorganizowało Polskie Towarzystwo Mechaniki Teoretycznej i Stosowanej (PTMTiS), Oddział w Gliwicach. Spośród konferencji międzynarodowych

wymienić należy, zdaniem autora, konferencje „MultiCriteria Decision Making” (w czerwcu 2011 roku odbyła się 21. konferencja z tego cyklu) oraz szczególnie ważne dla przygotowanej pracy konferencje „Evolutionary Multi-Criterion Optimization”, organizowane w cyklu dwuletnim od 2001 roku (w kwietniu 2011 roku odbyła się 6. konferencja).

Opisane w monografiach i stosowane obecnie metody rozwiązywania zadań optymalizacji wielokryterialnej można podzielić na dwie podstawowe grupy – na (1) metody klasyczne i (2) metody ewolucyjne. Cohon (1978), autorzy publikacji *Multiobjective Optimization in Engineering and in the Sciences* (1988), Osiński i Wróbel (1995), Statnikov i Matosov (1995), Marler i Arora (2004), Parsons i Scott (2004) oraz Tarnowski (2009, 2011) omawiają metody klasyczne. W tej grupie wyróżnić można cztery podstawowe metody rozwiązywania takich zadań: (a) poszukiwanie rozwiązań niezdominowanych odbywa się bezpośrednio na podstawie definicji w wygenerowanym wcześniej skończonym zbiorze ocen dopuszczalnych; (b) zbioru ocen niezdominowanych poszukuje się w przestrzeni celów poprzez analizę ograniczeń aktywnych i znajdując krawędzie zbioru dopuszczalnego, na których położone są oceny rozwiązań niezdominowanych; (c) rozwiązywane są zadania optymalizacji pod względem wszystkich przyjmowanych kolejno pojedynczych kryteriów optymalizacji, podczas gdy pozostałe kryteria włączane są do zbioru ograniczeń; (d) z przyjętych kryteriów optymalizacji formułuje się zastępcze kryterium optymalizacji w postaci kombinacji liniowej kryteriów z odpowiednio dobranymi współczynnikami wagowymi, a następnie pod względem takiego kryterium rozwiązuje się zadanie optymalizacji. W przypadku (b) przeprowadza się zazwyczaj serię obliczeń dla różnych wartości współczynników wagowych i jako rozwiązanie zadania przyjmuje się najlepsze znalezione rozwiązanie. Metody wykorzystujące agregację wektorowej funkcji celu są powszechnie stosowane również w metodach ewolucyjnej optymalizacji wielokryterialnej, ponieważ umożliwiają korzystanie z dobrze zbadanych algorytmów optymalizacji jednokryterialnej. Zitzler (1999) zwrócił również uwagę na to, że pierwszy w pełni wielokryterialny algorytm optymalizacji ewolucyjnej opracował dopiero Horn (1997 a). Zasadnicze wady metod z tej grupy: (a) umożliwiają odszukiwanie w jednej symulacji pojedynczego punktu należącego do frontu ocen rozwiązań niezdominowanych; związana jest z tym konieczność przeprowadzania wielu cykli obliczeń dla jednego zadania optymalizacyjnego; (b) niektóre z nich są wrażliwe na kształt frontu ocen rozwiązań niezdominowanych; (c) wymagają na wstępie wiedzy eksperckiej o rozwiązywanym zagadnieniu potrzebnej do określenia współczynników wagowych cząstkowych kryteriów optymalizacji.

Klasyczne sposoby rozwiązywania zadań optymalizacji wielokryterialnej, bazujące przede wszystkim na agregacji wektorowej funkcji celu, są łatwe do stosowania, lecz w wielu przypadkach nieefektywne<sup>1</sup>. Bardzo skuteczne okazały się natomiast dynamicznie rozwijane w ostatnich latach ewolucyjne algorytmy optymalizacji wielokryterialnej (Deb 2001, Coello Coello 1999 a, b, 2006, 2011, Osyczka 2002, Sarker i in. 2002, Coello Coello i Lamont 2004, Ehrgott i Gandibleux 2004, *Evolutionary Multiobjective Optimization* 2005, Kicinger i in. 2005, Coello Coello i in. 2007, Deb 2011).

---

<sup>1</sup> Przede wszystkim są nieskuteczne w obszarach niewypukłego zbioru dopuszczalnego oraz umożliwiają znalezienie jednego rozwiązania w jednym przebiegu algorytmu.


Fonseca i Fleming (1995) przedstawili przegląd metod łączących wiele kryteriów oceny w jedną funkcję celu, dającą w wyniku jedną wartość, a także przegląd metod opartych na optymalności w sensie Pareto i dających zbiór wartości. Coello Coello (1998, 1999 a, b, 2001) dokonał obszernego przeglądu metod ewolucyjnej optymalizacji wielokryterialnej. Deb (1999) przedstawił interesujący przegląd klasycznych i ewolucyjnych algorytmów optymalizacji wielokryterialnej. Deb (2005, 2011) omówił najbardziej znane klasyczne i ewolucyjne algorytmy optymalizacji wielokryterialnej oraz przedyskutował ich wady i zalety. Veldhuizen (1999) porównał cztery algorytmy na przykładach siedmiu zadań testowych, a Knowles i Corne (2000) porównali 13 algorytmów na sześciu przykładach. Zitzler i in. (2000) przedstawili empiryczne porównanie ośmiu algorytmów ewolucyjnych służących do optymalizacji wielokryterialnej zastosowanych w sześciu zadaniach testowych. Badania te wykazały, że selekcja elitarna jest bardzo cenna przy implementowaniu wysokiej jakości algorytmów ewolucyjnych służących do optymalizacji wielokryterialnej. Ghosh i Dehuri (2004) omówili 14 wybranych ewolucyjnych algorytmów optymalizacji wielokryterialnej. Konak i in. (2006) przedstawili szczegółowo wiele procedur obliczeniowych wykorzystywanych w ewolucyjnych algorytmach optymalizacji wielokryterialnej. Zamarin i in. (2009) zaprezentowali metody optymalizacji wielokryterialnej wykorzystujące algorytmy genetyczne. Sekulski (2011 a) przedyskutował podstawy teoretyczne optymalizacji wielokryterialnej, metody optymalizacji oraz wybrane techniki obliczeniowe. W niedawno wydanych książkach (Coello Coello i in. 2007, Deb 2001 i Osyczka 2002) oraz we wspomnianych artykułach przeglądowych zamieszczono bardzo wartościową prezentację klasycznych i ewolucyjnych metod optymalizacji wielokryterialnej.

W przypadku algorytmów genetycznych stosowane mogą być specjalne ewolucyjne metody optymalizacji wielokryterialnej, np.: VEGA (Schaffer 1985), HPGA (Hajela i Lin 1992), FFGA (Fonseca i Fleming 1993), NPGA (Horn i in. 1994), NSGA (Srinivas i Deb 1994), RWGA (Murata i Ishibuchi 1995), MOBES (Binh i Korn 1997), SPEA (Zitzler i Thiele 1998 a), MOMGA (Veldhuizen 1999), PAES (Knowles i Corne 1999), NSGA-II (Deb i in. 2000), SPEA2 (Zitzler i in. 2001). Zasadnicze zalety tych metod to: (1) efektywne przeszukiwanie przestrzeni wariantów oraz (2) możliwość zobrazowania frontu ocen wariantów niedominowanych w jednej symulacji. Badania porównawcze ewolucyjnych algorytmów optymalizacji wielokryterialnej, które przeprowadzili Zitzler (1999), Zitzler i Thiele (1998 b, 1999), wskazują, że najbardziej efektywny jest algorytm SPEA (Zitzler i Thiele 1998 a). W każdym jednak konkretnym przypadku niezbędne jest przeprowadzenie na początku obliczeń testowych w celu ustalenia rzeczywistej skuteczności wybranego algorytmu.

Ostatnio osiągnięto bardzo obiecujące wyniki zastosowania algorytmów genetycznych do rozwiązywania zadań optymalizacji wielokryterialnej. Opublikowano również wyniki prac dotyczących konstrukcji okrętów (Okada i Neki 1992, Hutchinson i in. 1998, Klanac i Jelovica 2007 a, Klanac i in. 2009, Sekulski 2010). Jang i Shin (1997) do wielokryterialnej optymalizacji konstrukcji statków zastosowali również strategię ewolucyjną.

W podrozdziale 3.2 przyjęto i szczegółowo uzasadniono to, że wynikiem zastosowania MOEA jest zbiór  $\Psi_f$  ocen rozwiązań niezdominowanych, stanowiący przybliżenie zbioru ocen rozwiązań optymalnych Pareto  $\Psi_P$  – rysunek 4.1 (a), a nie sam zbiór ocen rozwiązań optymalnych Pareto  $\Psi_P$  i że w związku z tym należy sformułować praktyczne zadanie optymalizacji wie-

lokryterialnej oraz ocenić osiągnięte rezultaty. Definicję zbioru przybliżającego oraz relacje dominacji zbiorów przybliżających przedstawiono w podrozdziałach 3.2 i 3.3, natomiast dyskusję nad pojęciem jakości zbiorów przybliżających opartej na relacji dominacji – w rozdziale 5.



Rys. 4.1. Ilustracja (a) optymalizacji wielokryterialnej polegającej na odszukaniu ocen (rozwiązań) na froncie ocen rozwiązań optymalnych Pareto, w praktyce stanowiących dobre (akceptowalne) przybliżenie frontu ocen rozwiązań optymalnych Pareto (przybliżenie Pareto); (b) dwóch podstawowych celów optymalizacji wielokryterialnej: 1 – skierowanie poszukiwań w kierunku frontu Pareto, 2 – utrzymanie zróżnicowania odszukanych rozwiązań niezdominowanych

Skuteczne rozwiązanie tak sformułowanego zadania komplikuje dodatkowo fakt, że odszukanie przybliżenia frontu optymalnego Pareto także jest zadaniem wielokryterialnym, ponieważ dąży się, na przykład, jednocześnie do (1) maksymalizacji liczby generowanych i znajdowanych rozwiązań niezdominowanych, (2) minimalizacji odległości generowanych rozwiązań od frontu Pareto  $\Psi_P$  oraz do (3) maksymalizacji zróżnicowania rozwiązań w osiągniętym przybliżeniu  $\Psi_f$  frontu optymalnego Pareto  $\Psi_P$ , którego położenie i kształt nie są znane. W ocenie rozwiązań próbnych nie można zatem odnieść się bezpośrednio do tego frontu, można jedynie oczekiwać, że odszukiwane oceny rozwiązań niezdominowanych są jego dobrym przybliżeniem; nie można jednak potwierdzić tego żadnymi miarami ilościowymi<sup>2</sup>. Zatem, tak jak w każdym zadaniu optymalizacji wielokryterialnej, także w tym przypadku nie jest możliwe dokładne stwierdzenie, jak dobre jest znalezione rozwiązanie, wówczas gdy określenie „dobre” jest wieloaspektowe i obejmuje: (1) bliskość frontu Pareto, którego położenie i kształt nie są znane; (2) zróżnicowanie ocen rozwiązań w zbiorze przybliżającym front Pareto; (3) szerokość zbioru przybliżającego; (4) głębokość zbioru itd. Niemniej jednak dobrze ilustruje dwa podstawowe cele częściowe formułowania i rozwiązywania MOEA: (1) skierowanie poszukiwań w kierunku frontu optymalnego Pareto i (2) utrzymanie zróżnicowania odszukanych ocen rozwiązań niezdominowanych – rysunek 4.1 (b).

## 4.2. Klasyczne algorytmy optymalizacji wielokryterialnej

Nie opracowano dotychczas teorii pozwalającej na ścisłe pod względem matematycznym rozwiązanie wielokryterialnego zadania optymalizacji sformułowanego w pierwot-

<sup>2</sup> W rozdziale 5 problem ilościowych miar jakości zbiorów przybliżających  $\Psi_f$  zostanie szczegółowo przedyskutowany.



nej postaci – zob. zależność (3.4). W praktyce dąży się do zastąpienia zadania wielokryterialnego zadaniem jednokryterialnym lub ciągiem zadań jednokryterialnych, a następnie do rozwiązania takich zadań za pomocą jednego ze sprawdzonych algorytmów optymalizacji jednokryterialnej. Klasyczne metody rozwiązywania wielokryterialnych zadań optymalizacji są więc zazwyczaj dobrymi metodami formułowania zastępczego skalarne kryterium optymalizacji  $f(\mathbf{x})$ . Do najczęściej wykorzystywanych metod formułowania zastępczego skalarne kryterium optymalizacji należą niżej opisane metody (Osiński i Wróbel 1995, Rao 1996, Miettinen 1998, Marler i Arora 2004, Parsons i Scott 2004, Stadnicki 2006).

**Metoda agregacji kryteriów optymalizacji.** Zakładając, że nie wszystkie kryteria składowe  $f_s(\mathbf{x})$  są w przybliżeniu jednakowo ważne<sup>3</sup>, zadanie wielokryterialne zastępuje się zadaniem jednokryterialnym w postaci:

$$f(\mathbf{x}) = \sum_{s=1}^S w_s f_s(\mathbf{x}) \rightarrow \min! (\max!), w_s \geq 0, s = 1, 2, \dots, S, \sum_{s=1}^S w_s = 1 \quad (4.1)$$

Współczynniki  $w_s$  mają sens wag przypisywanych poszczególnym kryteriom; metodą tą nie można odtworzyć zbioru przybliżającego w obszarach, w których zbiór ocen rozwiązań dopuszczalnych jest niewypukły. Problemy z praktycznym zastosowaniem metody wynikają również z faktu, że wartości współczynników wagowych  $w_s$  wybierane są arbitralnie; zazwyczaj określa je zespół ekspertów opierających się na własnych preferencjach, co powoduje, że wartości współczynników wagowych  $w_s$  nie są przyjmowane w pełni obiektywnie. Agregacja kryteriów optymalizacji może być dokonywana także wieloma innymi sposobami, np. w postaci iloczynowej, w postaci nieliniowej, z uwzględnieniem rozrzutu wartości kryteriów  $f_s(\mathbf{x})$  – patrz np. Tarnowski (1997). Każde uruchomienie poszukiwania po zmianie wartości współczynników wagowych  $w_s$  doprowadza do znalezienia innego rozwiązania należącego do zbioru przybliżającego  $\Psi_f$ .

**Metoda programowania celowego.** Zakładając, że można podać idealne wartości poszczególnych składowych kryteriów optymalizacji, co oznacza, że w przestrzeni ocen określony jest punkt idealny – cel, który należy osiągnąć, punktem należącem do zbioru ocen rozwiązań dopuszczalnych można przypisać liczby  $\rho$ , które w sensie przyjętej metryki będą wyrażać ich odległość od punktu idealnego  $\tilde{\mathbf{f}}(\mathbf{x})$ ; w takim przypadku zadanie optymalizacji wielokryterialnej (3.4) można zastąpić zadaniem jednokryterialnym, w którym minimalizowana będzie odległość pomiędzy punktami  $\tilde{\mathbf{f}}(\mathbf{x})$  i  $\mathbf{f}(\mathbf{x})$ :

$$\rho(f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_s(\mathbf{x}), \dots, f_S(\mathbf{x})) \rightarrow \min! \quad (4.2)$$

Rozwiązując wielokryterialne zadanie optymalizacji metodą programowania celowego, można znaleźć oceny rozwiązań należące do zbioru przybliżającego  $\Psi_f$  w niewypukłych obszarach zbioru ocen dopuszczalnych  $\Phi_f$  przy odpowiednim wyborze punktu idealnego. Jeśli określenie punktu idealnego nie jest możliwe, to można rozwiązać ciąg zadań jednokryterialnych pod względem wybieranych niezależnie kolejno pojedynczych kryteriów optymalizacji  $f_s(\mathbf{x})$ , a otrzymane rozwiązania przyjąć za współrzędne punktu idealnego  $\tilde{\mathbf{f}}(\mathbf{x})$ .

**Metoda leksykograficznego porządkowania kryteriów.** Punktem wyjścia metody jest uporządkowanie kryteriów składowych  $f_s(\mathbf{x})$  w kolejności wynikającej z ich subiektyw-

---

<sup>3</sup> W przypadku, gdy któreś z kryteriów jest znacznie mniej ważne od pozostałych, właśnie one mogą być pominięte, a optymalizacja może być prowadzona pod względem najważniejszych kryteriów.

nej ważności. Następnie rozwiązuje się ciąg jednokryterialnych zadań optymalizacji pod względem przyjmowanych kolejno kryteriów oceny. Znajdowane kolejno rozwiązania zadań jednokryterialnych włączane są do kolejnych zadań w formie ograniczeń równościowych. Rozwiązując ciąg zadań jednokryterialnych kolejno pod względem wszystkich kryteriów oceny, za rozwiązanie wielokryterialnego zadania optymalizacji przyjmuje się rozwiązanie o współrzędnych równych optymalnym rozwiązaniom kolejnych zadań jednokryterialnych. Metoda jest łatwa, wymaga jednak arbitralnego określenia ważności poszczególnych kryteriów, co powoduje, że jest subiektywna. Każde uruchomienie poszukiwań, przy różnej kolejności kryteriów, prowadzi do znalezienia innego rozwiązania ze zbioru przybliżającego  $\Psi_f$ .

**Metoda ograniczania kryteriów.** Na początku wybiera się jedno kryterium optymalizacji, uznane za najważniejsze, oraz określa się górne i dolne granice zmienności pozostałych kryteriów. Następnie przeprowadza się optymalizację jednokryterialną ze względu na wybrane kryterium, pozostałe kryteria włączając do zbioru ograniczeń brzegowych.

Omówione wybrane klasyczne algorytmy optymalizacji wielokryterialnej mają wszystkie wady i zalety klasycznych metod rozwiązywania zadań jednokryterialnych, a ponadto: (1) wymagają przyjęcia arbitralnych założeń podczas konstruowania skalarne zastępczego kryterium optymalizacji, (2) w jednym przebiegu algorytmu znajdują tylko jedno rozwiązanie ze zbioru przybliżającego, (3) poza szczególnymi przypadkami nie można z ich pomocą odwzorować wklęsłych fragmentów krawędzi zbioru ocen rozwiązań dopuszczalnych.

### 4.3. Ewolucyjne algorytmy optymalizacji wielokryterialnej

Jeśli chodzi o ewolucyjne algorytmy optymalizacji, w przeciwieństwie do optymalizacji jednokryterialnej, w której funkcja celu i funkcja przystosowania często są identyczne<sup>4</sup>, w zadaniach optymalizacji wielokryterialnej zarówno ocena przystosowania, jak i selekcja muszą uwzględniać kilka kryteriów ujętych w pojedynczej funkcji przystosowania  $F$ . Z tego punktu widzenia metody te można podzielić na metody wykorzystujące do obliczeń funkcji przystosowania (Zitzler i in. 2002 a): (1) skalaryzację wektorowej funkcji celu z ustalonymi wartościami współczynników wagowych – rysunek 4.2 (a); (2) skalaryzację wektorowej funkcji celu z losowymi wartościami współczynników wagowych – rysunek 4.2 (b); (3) podział zbioru wariantów na grupy i zastosowanie w każdej z nich pojedynczych kryteriów optymalizacji; osobnym problemem jest wybór tych kryteriów – rysunek 4.2 (c); (4) selekcję wariantów pod względem wartości atrybutów dominacji, określających położenie ocenianego wariantu dopuszczalnego w odniesieniu do innych wariantów dopuszczalnych – rysunek 4.2 (d).


Dwie pierwsze propozycje – rysunki 4.2 (a) i 4.2 (b) wywodzą się z klasycznych metod stosowanych w celu odtworzenia powierzchni kompromisu; polegają na zsumowaniu kryteriów i sformułowaniu skalarnej funkcji celu. W takim przypadku problem optymalizacji wielokryterialnej jest sprowadzany do problemu z jednym zastępczym kryterium  $F$ , które nazywane jest zazwyczaj funkcją celu:

$$F = \sum_{s=1}^S w_s f_s \quad (4.3)$$

---

<sup>4</sup> Tak jest w przypadku zadań bez ograniczeń. W przypadku zadania z ograniczeniami formułuje się zazwyczaj rozszerzoną funkcję przystosowania, włączając do niej, oprócz kryterium optymalizacji, także składniki będące funkcjami kar za naruszenie przyjętych ograniczeń.

Współczynniki wagowe kryteriów optymalizacji mogą mieć ustalone wartości – rysunek 4.2 (a), odzwierciedlając preferencje formułowane przez ekspertów przygotowujących model optymalizacyjny, lub zmieniają się w określony sposób, przyjmując np. wartości losowe podczas procesu optymalizacji – rysunek 4.2 (b), umożliwiając znalezienie zbioru ocen rozwiązań niezdominowanych zamiast pojedynczej oceny rozwiązania kompromisowego. Niektóre ewolucyjne algorytmy optymalizacji wielokryterialnej wykorzystują ważoną sumę kryteriów optymalizacji, w której współczynniki wagowe reprezentują parametry zmieniające się w trakcie ewolucji (Hajela i Lin 1992, Ishibuchi i Murata 1996).



Rys. 4.2. Ilustracja wybranych strategii umożliwiających uwzględnienie kryteriów optymalizacji w algorytmach optymalizacji wielokryterialnej: (a) selekcja pod względem skalarnej funkcji celu z ustalonymi wagami, (b) selekcja pod względem skalarnej funkcji celu z losowymi wagami, (c) podział zbioru wariantów na podzbiory, w których selekcja odbywa się pod względem pojedynczych kryteriów, (d) selekcja pod względem atrybutów dominacji Pareto

Metody selekcji według pojedynczych kryteriów – rysunek 4.2 (c) – zawierają mechanizmy przełączające między kryteriami podczas fazy wyboru. W każdym przypadku, w którym algorytm przystępuje do reprodukcji, potencjalnie inne kryterium decyduje, który członek populacji będzie skopiowany do zbioru wariantów przeznaczonych do krzyżowania.


Schaffer (1985) na przykład zaproponował algorytm, w którym populacja jest z góry podzielona na jednakowe części, a następnie dla osobników w każdej z grup stosowane jest inne pojedyncze kryterium wyboru. Natomiast Kursawe (1991) zaproponował losowy wybór każdego z pojedynczych kryteriów optymalizacji, które będzie kryterium decydującym w następnej fazie wyboru – prawdopodobieństwa mogą być określone przez użytkownika lub wybierane losowo w trakcie ewolucji.

Metody wykorzystujące w procesie selekcji atrybuty dominacji – rysunek 4.2 (d) – określają prawdopodobieństwo selekcji w zależności od położenia ocenianego wariantu względem innych wariantów w zbiorze dopuszczalnym. W tym przypadku więc wartości kryteriów optymalizacji dla poszczególnych wariantów obliczane są tylko po to, aby zbudować zbiór dopuszczalny  $\Phi_f$  w przestrzeni ocen  $V_f$  oraz ocenić położenie wariantu w tym zbiorze; jednak nie są bezpośrednio wykorzystywane w procesie selekcji. Zastosowane w pracy atrybuty dominacji zostaną określone i przedyskutowane w następnym podrozdziale.


W celu polepszenia zbieżności algorytmów ewolucyjnych dokonuje się także prób sprzężenia tych algorytmów z lokalnymi algorytmami optymalizacyjnymi. Na przykład Ghiasi i in. (2011) dokonali z powodzeniem sprzężenia algorytmu genetycznego NSGA-II z lokalnym algorytmem Nelder-Meada.

#### 4.4. Struktura wewnętrzna zbioru dopuszczalnego – szeregowanie i licznik dominacji

Przypomnijmy za podrozdziałem 3.2, że przyporządkowanie ocenom wariantów dopuszczalnych dwuargumentowego atrybutu dominacji (1 lub 0) pozwala podzielić zbiór ocen wariantów dopuszczalnych  $\Phi_f$  na dwa podzbiory: (1) ocen wariantów zdominowanych  $\mathbf{f}_{\succ} \in \Phi_{\succ}$  oraz (2) ocen wariantów niezdominowanych  $\mathbf{f}_{\succ} \in \Phi_{\succ}$  (rysunek 3.3). Informacja ta jest dość ogólna i nie odnosi się do wewnętrznej struktury zbioru ocen dopuszczalnych – rysunek 4.4 (a), a w szczególności nie dostarcza wiedzy np. (1) o liczbie ocen zdominowanych przez każdą z ocen dopuszczalnych, (2) o liczbie ocen zdominowanych przez daną ocenę niezdominowaną, (3) o tym, jak odległa jest dana zdominowana ocena dopuszczalna od frontu Pareto itd. (rysunek 4.3). Próba wypełnienia tej luki jest proponowane pojęcie szeregowania (ang. *rank*). Goldberg (1989) jako pierwszy zaproponował sposób wykorzystania informacji o wewnętrznej strukturze zbioru ocen dopuszczalnych w procesie selekcji. Zaproponował szeregowanie ocen rozwiązań dopuszczalnych w zależności od głębokości kolejnych frontów ocen rozwiązań niezdominowanych – rysunek 4.4 (b). Atrybut dominacji, którym w tym przypadku jest głębokość dominowania, przyjmuje wartości dyskretne 1, 2, 3 itd. Bardziej szczegółowe, niż propozycja Goldberga, zbadanie struktury zbioru ocen dopuszczalnych umożliwi wykorzystanie jako atrybutów dominacji pojęć: (1) szeregowania (klasyfikowania, rangi – ang. *rank*) ocen wariantów dopuszczalnych – rysunek 4.4 (c) oraz (2) licznika dominacji ocen (ang. *count*) wariantów dopuszczalnych – rysunek 4.4 (d). Wartości obu atrybutów zmieniają się w sposób ciągły w zbiorze ocen rozwiązań dopuszczalnych w sposób zależny od przyjętych strategii ich wyznaczania.



Rys. 4.3. Ilustracja zależności liczby ocen zdominowanych przez daną ocenę od nasycenia zbioru ocen rozwiązań dopuszczalnych  $\Phi_f$ : na rysunku (a) nasycenie zbioru dopuszczalnego  $\Phi_f$  jest mniejsze niż w przypadku przedstawionym na rysunku (b)



Rys. 4.4. Ilustracja atrybutów dominacji. Klasyfikowanie ocen dopuszczalnych: (a) ze względu na relację dominacji Pareto, (b) ze względu na głębokość dominacji, (c) według wskaźnika szeregowania ocen (ang. *rank*) – proponowana przez autora strategia określania liczby ocen dominujących nad daną oceną oraz (d) według licznika dominacji ocen (ang. *count*) – proponowana przez autora strategia określania liczby ocen zdominowanych przez daną ocenę


Szeregowanie oceny wariantu dopuszczalnego jest proporcjonalne do liczby oceny wariantów dopuszczalnych dominujących nad daną oceną – rysunek 4.4 (c). Jego wartość jest zatem najmniejsza (a w szczególnym przypadku równa zero) w przypadku ocen wariantów niezdominowanych, czyli należących do zbioru  $\Psi_f$  przybliżającego front Pareto  $\Psi_P$ . Dla ocen wariantów leżących poza przybliżeniem frontu Pareto, w głębi zbioru dopuszczalnego  $\Phi_f$ , wartości szeregowania są rosnącą miarą odległości ocen wariantów od tego frontu. Inne schematy szeregowania zaproponowali np. Fonseca i Fleming (1993), Zitzler i Thiele (1999). Licznik dominacji ocen określony dla danej oceny jest proporcjonalny do liczby ocen dopuszczalnych zdominowanych przez tę ocenę – rysunek 4.4 (d). Wartość licznika dominacji jest zatem największa w przypadku ocen niezdominowanych, czyli należących do zbioru  $\Psi_f$  przybliżającego front Pareto  $\Psi_P$ . Dla ocen leżących poza przybliżeniem frontu Pareto, w głębi zbioru dopuszczalnego  $\Phi_f$ , wartości licznika dominacji są malejącą miarą odległości tych ocen od frontu. Właściwe wykorzystanie obu atrybutów umożliwia opracowanie bardzo subtelnych użytecznych narzędzi wspomagających pożądaną zbieżność algorytmu obliczeniowego.

Zwróćmy uwagę, że w algorytmach ewolucyjnych wartości funkcji celu każdego wariantu ustalane są po obliczeniu jego charakterystyk (kryteriów oceny i nałożonych ograniczeń), a odległości pomiędzy wariantami, o ustalonych wartościach funkcji celu w przestrzeni celów, są stałe i mogą zostać potraktowane jako miara wzajemnego podobieństwa rozwiązań. W przypadku szeregowania (klasy rozwiązań) jest inaczej. Nie jest ono bezwzględną miarą położenia wariantu w przestrzeni ocen; jest raczej względną miarą położenia wariantu w tej przestrzeni określaną względem pozostałych rozwiązań (dopuszczalnych) w zbiorze. Ponieważ zbiór dopuszczalny  $\Phi_f$  nieustannie zmienia się w trakcie ewolucji, także szeregowanie wariantów wewnątrz niego ulega zmianie, ponieważ w każdym kolejnym pokoleniu określane jest ono względem innego zbioru wariantów dopuszczalnych, mimo że wartości funkcji celu pozostają takie same.


Zauważmy, że w populacji inicjującej, rozpoczynającej symulację, ocena wygenerowanego rozwiązania niezdominowanego otrzyma wg propozycji Goldberga (1989) klasę 1. Wraz z postępowaniem symulacji i zbliżaniem się ocen rozwiązań dopuszczalnych do frontu optymalnego Pareto ocena ta będzie wyprzedzana przez inne, a określony dla niej wskaźnik szeregowania będzie coraz mniejszy. Ponadto różnica w szeregowaniu między dwiema ocenami nie jest ustalona i nie może być względną miarą wartości dwóch porównywanych rozwiązań. Oczywiście w każdym przypadku rozwiązanie niezdominowane jest lepsze od rozwiązań, które są zdominowane. Ale nie można po prostu stwierdzić na przykład, że jeśli tylko ocena  $\mathbf{f}_B$  rozwiązania B ma rangę o jeden niższą niż ocena  $\mathbf{f}_A$  rozwiązania A, a ocena  $\mathbf{f}_C$  rozwiązania C ma klasę o trzy mniejszą niż ocena  $\mathbf{f}_A$ , to rozwiązanie B jest lepsze od rozwiązania C (ze względu na kryteria optymalizacji).

Rozważmy przykład zilustrowany na rysunku 4.5. Przyjmijmy początkowy zbiór – rysunek 4.5 (a) – złożony tylko z ocen  $\mathbf{f}_A$ ,  $\mathbf{f}_B$  i  $\mathbf{f}_C$  rozwiązań A, B i C, w którym oceny  $\mathbf{f}_B$  i  $\mathbf{f}_C$  są zdominowane przez  $\mathbf{f}_A$ , ale nie dominują nad sobą wzajemnie. Ocena  $\mathbf{f}_A$  otrzymuje klasę 1., a oceny  $\mathbf{f}_B$  i  $\mathbf{f}_C$  otrzymują klasę 2. Załóżmy, że w kolejnym pokoleniu do zbioru dodano dwie nowe oceny –  $\mathbf{f}_D$  i  $\mathbf{f}_E$  – rozwiązań dopuszczalnych D i E, tak jak na rysunku 4.5 (b). Ocena  $\mathbf{f}_D$  jest zdominowana przez  $\mathbf{f}_A$  i jednocześnie dominuje nad ocenami  $\mathbf{f}_C$  i  $\mathbf{f}_E$ . Ocena  $\mathbf{f}_E$  jest zdominowana przez oceny  $\mathbf{f}_A$  i  $\mathbf{f}_D$  i jednocześnie dominuje nad oceną  $\mathbf{f}_C$ . Ocena  $\mathbf{f}_C$  rozwiązania C otrzymuje

teraz nową klasę 4. (poprzednio miała klasę 2.), podczas gdy ocena  $f_B$  rozwiązania B zachowała nadal klasę 2., mimo że rozwiązania C i B nie zmieniły swojego położenia w przestrzeni ocen.



Rys. 4.5. Ilustracja koncepcji zmiany szeregowania rozwiązań bez zmiany położenia rozwiązań w przestrzeni ocen w przypadku kryteriów typu min!; liczby na rysunkach oznaczają: (a) wartości rang ocen wariantów populacji początkowej, (b) wartości rang po rozszerzeniu zbioru ocen wariantów dopuszczalnych



Rys. 4.6. Ilustracja podstawowych koncepcji umożliwiających uwzględnienie dominacji wariantów w algorytmach optymalizacji wielokryterialnej: (a) głębokości dominowania, (b) wskaźnika szeregowania (rangi, ang. rank) i licznika dominowania (ang. count); koła oznaczają oceny rozwiązań niezdominowanych, okręgi – oceny rozwiązań zdominowanych

Omówiony przykład pokazuje, że ani szeregowanie, ani licznik dominacji rozwiązania nie są obiektywnymi miarami jego wartości. Mimo to można je stosować jako narzędzia różnicowania ocen rozwiązań optymalizacji wielokryterialnej.

W literaturze przedmiotu znaleźć można opisy różnych szczegółowych propozycji rozwiązań wykorzystujących te koncepcje (np. Fonseca i Fleming 1993, Srinivas i Deb 1994, Zitzler i Thiele 1999, Deb i in. 2000, Zitzler i in. 2002 b). Każda taka propozycja ma swoje indywidualne właściwości, jednak wstępne doświadczenie autora oraz innych bada-

czy, np. Leylanda (2002), wskazują, że wpływ poszczególnych strategii szeregowania na zbieżność optymalizacji może być nieznaczny. W szczególności przy zastosowaniu nowoczesnych strategii elitarnych rozwiązania szybko dążą do rozwiązań niezdominowanych.

Wykorzystanie atrybutów dominacji w ewolucyjnych algorytmach optymalizacji wielokryterialnej zostało przetestowane przez innych autorów na prostych zadaniach optymalizacji wielokryterialnej. Ponieważ dotychczas nie zbadano przydatności tych algorytmów do rozwiązywania zadań optymalizacyjnych w projektowaniu konstrukcji statków morskich, zastosowanie konkretnej metody (rysunek 4.6) powinno być poprzedzone systematycznymi badaniami jej efektywności.

#### **4.5. Podsumowanie i wnioski**

Można przyjąć, że celem optymalizacji wielokryterialnej jest poszukiwanie zbioru przybliżającego zawierającego oceny rozwiązań niezdominowanych przybliżające front ocen optymalnych Pareto. Klasyczne metody optymalizacji nie umożliwiają zazwyczaj odtworzenia zbioru przybliżającego w przypadkach, gdy front optymalny Pareto nie jest wypukły. Intensywnie rozwijane w ostatnich latach ewolucyjne algorytmy optymalizacji okazały się bardzo skuteczne w rozwiązywaniu wielu zadań optymalizacji wielokryterialnej. Podstawową ich zaletą jest to, że bez liczenia pochodnych funkcji celu i pochodnych ograniczeń umożliwiają podczas jednego uruchomienia programu odszukanie zbioru przybliżającego z zadowalającą dokładnością odwzorowującego front ocen rozwiązań optymalnych Pareto. Od możliwości narzędzia obliczeniowego i oczekiwań użytkownika zależy uzyskanie zadowalającej liczby rozwiązań w zbiorze przybliżającym, odległości zbioru przybliżającego od frontu Pareto oraz zróżnicowania ocen rozwiązań w osiągniętym przybliżeniu frontu optymalnego Pareto. W algorytmach optymalizacyjnych powszechnie stosuje się dwie grupy metod. W pierwszej z nich selekcja generowanych rozwiązań kierowana jest przez funkcję przy stosowania agregującą w różny sposób kryteria oceny. W drugiej selekcja odbywa się względem ustalonych atrybutów dominacji, określających położenie ocen generowanych rozwiązań względem ocen innych rozwiązań dopuszczalnych. Odpowiedni dobór mechanizmów symulowanej ewolucji pozwala wygenerować wiele różnych zbiorów przybliżających, które następnie należy poddać krytycznej ocenie pozwalającej rozstrzygnąć, który z nich jest lepszy. Problemowi oceny jakości zbiorów przybliżających poświęcono następny rozdział opracowania.



## 5. Ocena jakości zbiorów przybliżających

### 5.1. Wprowadzenie

Osiągnięcie zbioru  $\Psi_P$  ocen rozwiązań optymalnych Pareto, z wykorzystaniem klasycznych metod optymalizacji wielokryterialnej, może być bardzo czasochłonne, a w wielu przypadkach nawet niemożliwe, ponieważ nie opracowano dotychczas bezpośrednich ścisłych metod oceny jakości tych rozwiązań. W takich przypadkach algorytmy ewolucyjne mogą być atrakcyjnym rozwiązaniem alternatywnym – zazwyczaj nie gwarantują zidentyfikowania optymalnych kompromisów należących do zbioru  $\Psi_P$ , ale mogą pomóc w zidentyfikowaniu zadowalającego przybliżenia, to znaczy zbioru przybliżającego  $\Psi_f$  zawierającego oceny rozwiązań, które nie są zbyt odległe od frontu  $\Psi_P$  ocen optymalnych Pareto. Zaproponowano już wiele wielokryterialnych algorytmów ewolucyjnych (najbardziej znane wymieniono w podrozdziale 4.1), potrzebne są zatem narzędzia do oceny, jak dobre są uzyskiwane rozwiązania sformułowanych problemów. A to prowadzi do pytania: Jak porównywać jakość zbiorów przybliżających  $\Psi_f$ ?

W przypadku ewolucyjnych algorytmów optymalizacji wielokryterialnej (statystycznych z natury), porównywanie jakości zbiorów przybliżających jest problemem bardzo trudnym i wzbudzającym wiele kontrowersji. Do jakościowego porównywania powszechnie wykorzystuje się oceny wizualne, natomiast w przypadku metod ilościowych dopiero poszukuje się odpowiednich standardów (Knowles i in. 2006). Nie opublikowano jeszcze akceptowanych powszechnie procedur pozwalających porównywać jakość wyników uzyskiwanych przy wykorzystaniu różnych algorytmów zwykle w wyniku wielokrotnego uruchomienia lub tego samego algorytmu uruchamianego wielokrotnie, uwzględniających ilościowo ich statystyczny charakter (Sarker i Coello Coello 2002, Knowles i in. 2006). Problem ten jest szczególnie trudny również dlatego, że w tym przypadku – inaczej niż ma to miejsce w optymalizacji jednokryterialnej – porównywać trzeba nie pojedyncze oceny rozwiązań, ale wektory reprezentujące zbiory  $\Psi_f$  ocen niezdominowanych rozwiązań, przy założeniu, że są one przybliżeniem nieznanego w praktyce zbioru  $\Psi_P$  ocen rozwiązań optymalnych Pareto. W konsekwencji większość badań porównawczych opartych jest na różnych koncepcjach, w związku z czym uzyskane rezultaty badań są trudne do porównań (Knowles i in. 2006).

W przypadku optymalizacji jednokryterialnej wybór miernika jakości uzyskanego rozwiązania jest oczywisty i prosty – jest nim kryterium optymalizacji. Wielkość ta jest jednoznacznie zdefiniowana, obliczana dla każdego rozwiązania próbnego, a mniejsza lub większa, w zależności od zadania, wartość kryterium optymalizacji odpowiada lepszemu rozwiązaniu. W przypadku optymalizacji wielokryterialnej nie jest jednak jasne, co oznacza określenie „lepszy” – rozwiązania, których oceny leżą bliżej frontu Pareto czy rozwiązania, których oceny obejmują szerszy zakres właściwości rozwiązań itd. A pamiętać przy tym trzeba, że front  $\Psi_P$  ocen rozwiązań optymalnych Pareto nie jest znany. Z tych powodów trudno jest zdefiniować odpowiednią miarę jakości dla przybliżeń  $\Psi_f$  nieznanego frontu  $\Psi_P$

ocen rozwiązań optymalnych Pareto. W rezultacie do porównywania i oceny rezultatów ewolucyjnych algorytmów optymalizacji wielokryterialnej do niedawna bardzo często wykorzystywano jedynie jakościową ocenę graficznej prezentacji uzyskanych ocen rozwiązań niezdominowanych (Veldhuizen 1999).

W ostatnich latach w dziedzinie tej dokonano jednak pewnego postępu – opublikowano prace dotyczące problemu ilościowego porównywania różnych przybliżeń  $\Psi_f$  powierzchni kompromisu  $\Psi_P$ . Najbardziej popularne są jednoargumentowe miary jakości, to znaczy miary przypisujące każdemu, pojedynczemu, zbiorowi przybliżającemu  $\Psi_f$  jedną wartość, która odzwierciedla określony aspekt jakości (np. Veldhuizen i Lamont 2000 b, Deb i Jain 2002). Chcąc zwiększyć siłę wnioskowania, formułuje się różne miary jakości i zwykle wykorzystuje się je łącznie, starając się w ten sposób uwzględnić w ocenie różne interesujące aspekty pojęcia „jakość”. Inne metody oparte są na dwuargumentowych miarach jakości, które przyporządkowują liczby do par zbiorów (Hansen i Jaskiewicz 1998, Zitzler i Thiele 1998 b). Trzecią grupę, zupełnie inną pod względem koncepcyjnym, stanowią metody MFM (Grunert da Fonseca i in. 2001), za pomocą których szacuje się prawdopodobieństwo osiągnięcia dowolnie wybranych celów  $f(\mathbf{x})$  w przestrzeni ocen na podstawie znajomości wielu zbiorów przybliżających  $\Psi_f$ . Pomimo tej różnorodności metod nadal pozostaje niejasne to, jakie są wzajemne relacje poszczególnych miar jakości oraz jakie są ich wady i zalety (Zitzler i in. 2002 c). W konsekwencji nie ma uzgodnionych opinii, która miara lub miary jakości powinny być użyte w konkretnych przypadkach (Zitzler i in. 2002 d).

W szczególności Zitzler i in. (2002 d) wykazali, że: (1) nie istnieje ogólna jednoargumentowa miara, która w dowolnym przypadku może wskazać, czy przybliżenie  $\Psi_A$  frontu optymalnego Pareto jest lepsze niż przybliżenie  $\Psi_B$ ; (2) stwierdzenie to jest słuszne nawet w przypadku, gdy dysponuje się skończoną kombinacją jednoargumentowych miar jakości; (3) nie sformułowano dotychczas miary jakości, której można użyć do wykazania, że przybliżenie  $\Psi_A$  jest lepsze niż przybliżenie  $\Psi_B$ ; można wnioskować jedynie, że przybliżenie  $\Psi_A$  nie jest gorsze od przybliżenia  $\Psi_B$ , co oznacza, że przybliżenie  $\Psi_A$  jest lepsze niż przybliżenie  $\Psi_B$  lub że przybliżeń  $\Psi_A$  i  $\Psi_B$  nie można porównywać; (4) istnieją jednoargumentowe miary, które w szczególnych przypadkach mogą wskazać, że przybliżenie  $\Psi_A$  jest lepsze niż przybliżenie  $\Psi_B$ ; (5) poprawnie sformułowane dwuargumentowe miary jakości mogą wskazać, czy przybliżenie  $\Psi_A$  jest lepsze niż przybliżenie  $\Psi_B$ .

Określenie wiarogodnej metody oceny jakości zbiorów przybliżających  $\Psi_f$  jest bardzo ważne, jeśli chce się zastosować ją do walidacji algorytmu. Jednakże, gdy problem dotyczy optymalizacji wielokryterialnej, istnieje kilka powodów trudności związanych z oceną uzyskanych wyników: (1) algorytmy ewolucyjne generują wiele rozwiązań – zamiast jednego zazwyczaj pożądane jest uzyskanie jak największej liczby rozwiązań, których oceny należą do zbioru  $\Psi_f$  przybliżającego front  $\Psi_P$  ocen rozwiązań optymalnych Pareto; (2) algorytmy ewolucyjne są algorytmami losowymi, w związku z czym na potrzeby oceny skuteczności trzeba zazwyczaj uruchomić wiele symulacji, a otrzymane rezultaty poddać analizie statystycznej; (3) może zaistnieć potrzeba zmierzenia różnych aspektów jakości zbiorów przybliżających  $\Psi_f$ . To wszystko pokazuje, jak trudne jest opracowanie miar skuteczności algorytmów optymalizacji wielokryterialnej.

Uzasadnione wydaje się oczekiwanie, że sformułowanie dobrej miary jakości powinno uwzględniać (Zitzler i in. 2000): (1) minimalizację odległości wygenerowanego przybliżenia  $\Psi_f$  do rzeczywistego frontu  $\Psi_P$  ocen rozwiązań optymalnych Pareto (oczywiście, jeśli jest on znany); (2) maksymalizację zróżnicowania ocen rozwiązań w zbiorze przybliżającym  $\Psi_f$ , przy jednoczesnym ich rozmieszczeniu na empirycznej powierzchni kompromisu tak gładko i jednorodnie, jak to jest możliwe; (3) maksymalizację liczby ocen rozwiązań w zbiorze przybliżającym  $\Psi_f$ .

Zitzler i in. (2002 c, d, 2003), Fonseca i in. (2005), Knowles i in. (2006), Brockhoff (2009) przedstawili najbardziej aktualny i wyczerpujący, zdaniem autora, przegląd problemów związanych z oceną jakości zbiorów przybliżających  $\Psi_f$ , wygenerowanych przez wielokryterialne losowe algorytmy optymalizacyjne. Zaproponowali matematyczne podstawy badania jakości zbiorów przybliżających  $\Psi_f$ . Wychodząc z założenia, że rezultatem działania ewolucyjnego algorytmu optymalizacji wielokryterialnej jest zbiór nieporównywalnych rozwiązań, nazwany przez ww. autorów zbiorem przybliżającym  $\Psi_f$  (patrz podrozdział 3.2), wprowadzili wiele relacji dominacji zbiorów przybliżających (patrz podrozdział 3.3). Relacje te można potraktować jako formalną reprezentację tego, co zgodnie z intuicją zrozumimy, stwierdzając, że jeden zbiór przybliżający  $\Psi_A$  jest lepszy od innego zbioru  $\Psi_B$ . Termin „wskaźnik jakości  $QI$ ” został przez wspomnianych autorów wykorzystany do uchwycenia znaczenia miary jakości zbiorów przybliżających  $\Psi_f$ .

Sarker i Coello Coello (2002) dokonali przeglądu propozycji uznanych przez nich za najważniejsze i pozwalające zmierzyć trzy wymienione wyżej i poddawane ocenie aspekty pojęcia „jakość”. Zauważyli przy tym, że nie istnieje metoda pozwalająca zmierzyć te trzy aspekty za pomocą jednej wielkości. Niestety, próby opracowania jednej miary pozwalającej uchwycić te aspekty są bezowocne, ponieważ dotyczą bardzo różnych właściwości algorytmów. Interesujące jest spostrzeżenie, że próby opracowania dobrej miary służącej do oceny ww. obszarów lub większej liczby obszarów są także zadaniem optymalizacji wielokryterialnej. Z tego powodu bardziej właściwe wydaje się używanie różnych miar do szacowania różnych aspektów jakości zbiorów przybliżających  $\Psi_f$ .


## 5.2. Wskaźniki jakości zbiorów przybliżających

Zgodnie z dyskusją przedstawioną w rozdziale 3 optymalizacja może być traktowana jako poszukiwanie optymalnych rozwiązań w uporządkowanym zbiorze. Częściowe uporządkowanie  $rel$  na potrzeby dowolnego zadania optymalizacji  $(\Phi, \Phi_f, f, rel)$  określa strukturę preferencji w przestrzeni poszukiwań – rozwiązanie  $x_1$  jest bardziej preferowane niż rozwiązanie  $x_2$ , jeśli  $f(x_1) rel f(x_2)$ , ale nie jest preferowane, jeśli  $f(x_2) rel f(x_1)$ . Tak określona struktura preferencji jest założeniem, przy którym realizuje się proces optymalizacji. Zatem najbardziej naturalną drogą porównywania dwóch zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$  jest wykorzystanie struktury preferencji będących jej podstawą.

W kontekście słabej dominacji Pareto możemy wyróżnić cztery możliwe sytuacje (patrz tablica A.2): (1) zbiór przybliżający  $\Psi_A$  jest lepszy od zbioru  $\Psi_B$ , (2) zbiór przybliżający  $\Psi_B$  jest lepszy od zbioru  $\Psi_A$ , (3) zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  są nieporównywalne wza-


jemnie lub (4) zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  są obojętne. Są to stwierdzenia możliwe do sformułowania, w przypadku których wystarczy zbadać relację dominacji, przy czym nie są potrzebne jakiekolwiek dodatkowe informacje o preferencji zbiorów przybliżających  $\Psi_f$ .

Często jednak badacze zainteresowani są bardziej precyzyjnym sformułowaniem jakości rozwiązań w postaci ilościowej na ciągłej skali wartości. Na przykład w przypadkach (1) i (2) można być zainteresowanym informacją, jak bardzo jeden zbiór przybliżający  $\Psi_A$  jest lepszy od drugiego  $\Psi_B$ , a w przypadku (3) można dodatkowo zapytać o to, czy jest możliwe to, że zbiór  $\Psi_A$  jest lepszy od zbioru  $\Psi_B$  w określonym aspekcie nieuwzględnionym w sformułowanej strukturze preferencji. Jeśli zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  przenikają się wzajemnie, to na podstawie relacji dominacji nie można rozstrzygnąć o względnej wyższej jakości któregoś z nich – relacja dominacji nie jest wystarczającym kryterium rozstrzygającym o wyższej jakości zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$ .



Rys. 5.1. Przykłady ilustrujące omówione w pracy ograniczenia wniosków formułowanych tylko przy założeniu słabej dominacji Pareto: (a), (b) zbiory przybliżające nie przenikają się, (c), (d) zbiory przybliżające przenikają się;  $f_1 \rightarrow \min!$ ,  $f_2 \rightarrow \min!$

Na rysunku 5.1 przedstawiono przykłady ilustrujące ograniczenia wniosków formułowanych tylko przy założeniu słabej dominacji Pareto: (a) i (b) – zbiór przybliżający  $\Psi_A$  dominuje nad zbiorem  $\Psi_B$ , ale w przypadku (a) oba zbiory przybliżające leżą bliżej siebie niż w przypadku (b); (c) zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  są nieporównywalne, lecz można przyjąć, że w większości przypadków zbiór  $\Psi_A$  będzie bardziej preferowany przez decydenta niż zbiór  $\Psi_B$  (ponieważ większa liczba ocen rozwiązań należących do zbioru  $\Psi_A$  będzie dominowała nad ocenami rozwiązań należącymi do zbioru  $\Psi_B$ ); (d) zbiory przybliżające  $\Psi_A$  i  $\Psi_B$  są nieporównywalne, jednak można spodziewać się, że zbiór  $\Psi_B$  będzie bardziej preferowany przez decydenta niż zbiór  $\Psi_A$  (ponieważ większa liczba ocen rozwiązań należących do zbioru  $\Psi_B$  będzie dominowała nad ocenami rozwiązań należącymi do zbioru  $\Psi_A$ ). Omówione i zilustrowane ograniczenia wnioskowania o jakości zbiorów przybliżających, na podstawie relacji dominacji Pareto, uzasadniają cel sformułowania wskaźników jakości zbiorów przybliżających, jakim jest ocena jakości także nieporównywalnych w sensie dominacji Pareto zbiorów przybliżających oraz przypisanie miar określeniom „lepszy” i „gorszy” pod względem określonych kryteriów (rysunek 5.2).




Rys. 5.2. Ilustracja potrzeby sformułowania wskaźników jakości zbiorów przybliżających: (a) przypadek, gdy zbiory przybliżające nie przenikają się, (b) przypadek, gdy zbiory się przenikają;  $f_1 \rightarrow \min!$ ,  $f_2 \rightarrow \min!$

W związku z tym zaproponować trzeba ilościowe miary jakości zbiorów przybliżających  $\Psi_f$ . Zitzler i in. (2002 c, d) oraz Knowles i in. (2006) proponują używanie terminu „wskaźnik jakości” (ang. Quality Indicator, QI) zdefiniowanego poniżej – na podstawie Zitzler i in. (2002 d).

**Definicja 5.1. Wskaźnik jakości (ang. Quality Indicator, QI).** Jest to funkcja  $QI: A_f \rightarrow \mathbb{R}$ , która każdemu zbiorowi przybliżającemu  $\Psi_f \subset A_f$  przyporządkowuje liczbę rzeczywistą  $QI(\Psi_f) \in \mathbb{R}$ , która jest miarą określonego aspektu jakości. ■

Niech na przykład  $\Psi_A$  będzie dowolnym zbiorem przybliżającym. Rozważmy część  $V_f$  przestrzeni ocen rozwiązań  $V_f = \Re^n$  zdominowaną przez zbiór  $\Psi_A$ . Oznacza to, że każdy wektor jakości w części  $V_f$  jest słabo zdominowany przynajmniej przez jeden wektor należący do zbioru  $\Psi_A$ . Wskaźnik hiperobjętości  $QI_H$  (Zitzler i Thiele 1999) jest miarą hiperobjętości części  $V_f$  (rysunek 5.3). Większa wartość wskaźnika  $QI_H$  oznacza lepszy zbiór przybliżający. Zwróćmy uwagę, że wskaźnik ten wymaga podania punktu referencyjnego, względem którego obliczana będzie wartość hiperobjętości. W przypadku przedstawionym na rysunku 5.3 (a) zbiór przybliżający  $\Psi_A$  otrzymuje wartość wskaźnika  $QI_H(\Psi_A) = 62,5\%$ . W przypadku przedstawionym na rysunku 5.3 (b) zbiór przybliżający  $\Psi_A$  otrzymuje wartość wskaźnika  $QI_H(\Psi_A) = 65,6\%$ . W obu przedstawionych przypadkach ten sam wektor jakości, o współrzędnych  $[240 \ 7700]^T$ , przyjęto jako punkt referencyjny do obliczenia wartości wskaźnika  $QI_H$ . Ponieważ zbiór przybliżający, przedstawiony na rysunku 5.3 (b), charakteryzuje się większą wartością wskaźnika  $QI_H$ , może być oceniony jako lepszy od zbioru przedstawionego na rysunku 5.3 (a).



Rys. 5.3. Ilustracja pojęcia wskaźnika hiperobjętości: (a) dla zbioru przybliżającego  $\Psi_A$  wartość wskaźnika  $QI_H(\Psi_A) = 62,5\%$ , (b) dla zbioru przybliżającego  $\Psi_A$  wartość wskaźnika  $QI_H(\Psi_A) = 65,6\%$ ;  $f_1 \rightarrow \min!$ ,  $f_2 \rightarrow \min!$

Rozważając ponownie rysunek 5.1, zauważyć można, że wskaźnik hiperobjętości  $QI_H$  ujawnia różnice jakości, które nie mogą być dostrzeżone jedynie przy uwzględnieniu relacji dominacji podanych w tablicy A.2. Przy założeniu, że punktem referencyjnym jest wektor oceny o współrzędnych  $[240 \ 7700]^T$  dla zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$ , przedstawionych na rysunku 5.1 (a), odpowiednie wartości wskaźnika są następujące:  $QI_H(\Psi_A) = 63,68\%$ ,  $QI_H(\Psi_B) = 49,77\%$ ; na rysunku 5.1 (b):  $QI_H(\Psi_A) = 72,28\%$ ,  $QI_H(\Psi_B) = 46,16\%$ ; na rysunku 5.1 (c):  $QI_H(\Psi_A) = 58,29\%$ ,  $QI_H(\Psi_B) = 50,41\%$ ; na rysunku 5.1 (d):  $QI_H(\Psi_A) = 58,29\%$ ,  $QI_H(\Psi_B) = 62,13\%$ . Wnioski o dostrzeżonych różnicach w jakości zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$ , formułowane na podstawie wskaźnika hiperobjętości  $QI_H$ , nie mogą być rozszerzane na dowolny przypadek innego wskaźnika jakości, ponieważ każdy wskaźnik jakości reprezentuje określone założenia o preferencjach decydenta, a zatem badania jakości zbiorów przybliżających za pomocą innych wskaźników jakości mogą prowadzić do innych wniosków. Niemniej jednak, jeśli  $QI_H(\Psi_A) > QI_H(\Psi_B)$ , to są podstawy do tego, aby stwierdzić, że

zbiór przybliżający  $\Psi_A$  jest lepszy od zbioru  $\Psi_B$  pod względem wskaźnika hiperobjętości  $QI_H$ . Wniosek ten można sformułować także w ten sposób, że w rozpatrywanym przypadku są podstawy do stwierdzenia, że zbiór przybliżający  $\Psi_A$  jest wyższej jakości od zbioru  $\Psi_B$ , jeśli wskaźnik hiperobjętości  $QI_H$  reprezentuje nieuwjęte w algorytmie optymalizacji preferencje decydenta dotyczące jakości zbiorów przybliżających. Jednak może być inaczej w przypadku przyjęcia innego wskaźnika jakości  $QI'$ , którego wartości w przypadku zbioru przybliżającego  $\Psi_B$  będą lepsze (większe lub mniejsze) niż w przypadku zbioru  $\Psi_A$ . W konsekwencji każde porównywanie zbiorów przybliżających ograniczone jest przez przyjęte wskaźniki jakości reprezentujące preferencje decydenta. Na przykład, jeśli do badań porównawczych wybrany został wskaźnik hiperobjętości  $QI_H$ , każde stwierdzenie typu „zbiór przybliżający  $\Psi_A$  przewyższa pod względem jakości zbiór przybliżający  $\Psi_B$ ” musi być konieczne uściśnione poprzez uzupełnienie „przy założeniu, że wskaźnik hiperobjętości  $QI_H$  odzwierciedla preferencje decydenta dotyczące jakości zbiorów przybliżających  $\Psi_f$ ”.

Na przykład, jeśli przyjmiemy wskaźnik jakości  $QI_N$  równy liczbie ocen w zbiorze przybliżającym, co oznacza, że  $QI_N$  jest równy liczbie ocen w zbiorze przybliżającym, taki że większa wartość wskaźnika jest bardziej preferowana, to dla zbiorów przedstawionych na rysunku 5.1 (a) otrzymuje się  $QI_N(\Psi_A) = 11$  i  $QI_N(\Psi_B) = 15$ , czyli  $QI_N(\Psi_B) > QI_N(\Psi_A)$ . A zatem są podstawy, aby stwierdzić, że zbiór  $\Psi_B$  przybliżający front optymalny Pareto jest lepszy od zbioru  $\Psi_A$ , jeśli liczba ocen w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta. Za pomocą symboli<sup>1</sup> wniosek ten można zapisać w następującej postaci:

$$QI_N(\Psi_B) > QI_N(\Psi_A) \Rightarrow \uparrow QI_N \Rightarrow \Psi_B \blacktriangleright \Psi_A$$

Czyli: ponieważ liczba ocen  $QI_N(\Psi_B)$  w zbiorze  $\Psi_B$  przybliżającym zbiór ocen rozwiązań optymalnych Pareto  $\Psi_P$  jest większa od liczby ocen  $QI_N(\Psi_A)$  w zbiorze  $\Psi_A$  i ponieważ liczba ocen w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta w taki sposób, że większe wartości  $QI_N$  są bardziej preferowane, są podstawy do tego, aby stwierdzić, że zbiór  $\Psi_B$  przybliżający front ocen rozwiązań optymalnych Pareto  $\Psi_P$  jest lepszy od zbioru  $\Psi_A$ .

Akceptując fakt, że wskaźniki jakości wyrażają preferencje decydenta, można przyjąć, że każda funkcja w postaci  $QI: \Psi_f \rightarrow \mathfrak{R}$  może być wybrana jako wskaźnik jakości zbioru przybliżającego  $\Psi_f$ . Ta dowolność jest jednak ograniczona, jeśli oczekuje się zachowania zgodności z naturalną strukturą preferencji rozważanego zadania optymalizacji. W takim przypadku bowiem całkowity porządek (ang. *total order*) w zbiorze  $\Lambda_f$  zawierającym zbiory przybliżające  $\Psi_f$ , wprowadzony poprzez wybór wskaźnika jakości  $QI$ , nie powinien być sprzeczny z częściowym porządkiem<sup>2</sup> (ang. *partial order*) w zbiorze  $\Lambda_f$  wprowadzonym poprzez słabą relację dominacji Pareto. Oznacza to, że jeśli zbiór przybliżający  $\Psi_A$  jest bardziej preferowany (wyżej oceniany) niż zbiór  $\Psi_B$ , pod względem słabej dominacji Pareto, to także

<sup>1</sup> Symbol  $\blacktriangleright$  oznacza ‘lepszy’, symbol  $\uparrow$  oznacza, że decydent preferuje większe wartości wskaźnika, zaś symbol  $\downarrow$  oznacza, że decydent preferuje mniejsze wartości wskaźnika jakości.

<sup>2</sup> Częściowy porządek w zbiorze  $X$  to relacja, która pozwala porównywać ze sobą pewne elementy tego zbioru. Mówimy, że relacja  $rel$  w zbiorze  $X$  jest relacją częściowego porządku, jeśli jest zwrotna, przechodnia i antysymetryczna. Przez zbiór częściowo uporządkowany rozumiemy zbiór  $X$  wraz z relacją porządkującą, czyli parę  $(X, rel)$ . Warunek zwrotności ujęty w definicji oznacza, że częściowymi porządkami są relacje nierówności słabych, na przykład  $\leq$  dla liczb,  $\subseteq$  dla zbiorów. Jeśli dodatkowo elementy w zbiorze  $X$  są porównywane względem relacji  $rel$ , to zbiór ten jest całkowicie uporządkowany, a o relacji  $rel$  mówimy, że wprowadza całkowity porządek w zbiorze  $X$ .

wartość wskaźnika jakości  $QI$  dla zbioru  $\Psi_A$  powinna być przynajmniej tak samo korzystna jak wartość wskaźnika dla zbioru  $\Psi_B$ . W związku z tym można stwierdzić, że takie wskaźniki jakości są zgodne w sensie Pareto (ang. *Pareto compliant*) – na podstawie Knowles i in. (2006):

**Definicja 5.2. Wskaźnik jakości zgodny w sensie Pareto (PCQI).** Wskaźnik jakości  $QI: \Lambda_f \rightarrow \mathfrak{R}$  jest zgodny w sensie Pareto, jeżeli dla dowolnych zbiorów przybliżających  $\Psi_A, \Psi_B \subset \Lambda_f$ :  $\Psi_A \succeq \Psi_B \Rightarrow QI(\Psi_A) \geq QI(\Psi_B)$ , zakładając, że większe wartości wskaźnika odpowiadają wyższej jakości zbiorów przybliżających, w przeciwnym razie  $\Psi_A \succeq \Psi_B \Rightarrow QI(\Psi_A) \leq QI(\Psi_B)$ . W kontekście teorii porządku (teorii mnogości) wskaźnik jakości zbiorów przybliżających  $QI$  jest zgodny w sensie Pareto, jeśli jest funkcją zachowującą porządek przy przejściu od  $(\Lambda_f, \succeq)$  do  $(\mathfrak{R}, \geq)$  oraz od  $(\Lambda_f, \preceq)$  do  $(\mathfrak{R}, \leq)$ . ■

Należy zwrócić uwagę, że wiele zaproponowanych w literaturze przedmiotu wskaźników jakości  $QI$ , omówionych w dalszej części tego podrozdziału, nie jest zgodnych w sensie Pareto. Niektóre popularne wskaźniki sformułowano tylko dla ograniczonych aspektów jakości zbiorów przybliżających  $\Psi_f$ , takich jak odległość od frontu optymalnego Pareto  $\Psi_P$  lub zróżnicowanie w przestrzeni ocen. Takie wskaźniki jakości, niekiedy nazywane także funkcjonalnie niezależnymi (ang. *functionally independent*), nazywa się niezgodnymi w sensie Pareto (PNCQI) – na podstawie Knowles i in. (2006):

**Definicja 5.3. Wskaźnik jakości niezgodny w sensie Pareto (PNCQI).** Każdy wskaźnik jakości zbiorów przybliżających  $QI$  taki, że jeśli zostanie zastosowany w przypadku dowolnych zbiorów przybliżających  $\Psi_A, \Psi_B \subset \Lambda_f$ , może wykazać preferowanie zbioru  $\Psi_A$  przed zbiorem  $\Psi_B$ , podczas gdy zbiór  $\Psi_B$  preferowany przed zbiorem  $\Psi_A$  ze względu na relację słabej dominacji Pareto ( $\Psi_A \succeq \Psi_B \wedge \neg \Psi_B \succeq \Psi_A$  lub  $\Psi_A \succ \Psi_B$ ) jest niezgodny w sensie Pareto. ■

Badania empiryczne wykazują, że w praktycznych zadaniach wskaźniki jakości, które nie są zgodne w sensie Pareto, naruszają częściowy porządek określony przez relację słabej dominacji Pareto bardzo często, a nie tylko w pewnych szczególnych, patologicznych, okolicznościach. Nie oznacza to, że niezgodne w sensie Pareto wskaźniki nie są użyteczne w przypadku ewolucyjnych optymalizatorów wielokryterialnych, które przecież z założenia wykorzystują najczęściej słabą relację dominacji Pareto; na przykład mogą być użyte do dokładniejszego rozpoznania struktury preferencji wykazanej za pomocą wskaźników zgodnych w sensie Pareto dla zbiorów przybliżających mających identyczne wartości tychże wskaźników. Ponadto mogą istnieć inne algorytmy optymalizacji ( $\Phi, \Phi_f, \mathbf{f}, rel$ ) nieoparte na słabej dominacji Pareto, dla których wskaźniki takie mogą być odpowiednie, ponieważ stosowanie ich nie musi być sprzeczne z częściowym porządkiem określonym przez relację  $rel$ .

Można jeszcze zauważyć, że powyższa dyskusja ograniczona jest jedynie do jednoargumentowych wskaźników jakości  $QI(\Psi_A)$ , mimo że dowolny wskaźnik może być stosowany dla dowolnej liczby zbiorów przybliżających, będących jego argumentami. Oprócz takich, jednoargumentowych, wskaźników zaproponowano także wskaźniki dwuargumentowe  $QI(\Psi_A, \Psi_B)$ , przyporządkowujące liczby rzeczywiste parom zbiorów przybliżających. Przegląd takich wskaźników przedstawili m. in. Zitzler i in. (2003). Na przykład jednoargumentowy wskaźnik hiperobjętości może być rozszerzony do dwuargumentowego wskaźnika jakości  $QI_H(\Psi_A, \Psi_B)$  rozumianego jako hiperobjętość tej części przestrzeni ocen, która jest zdominowana przez zbiór przybliżający  $\Psi_A$ , lecz nie jest zdominowana przez zbiór  $\Psi_B$ .

Ponieważ w praktycznych zastosowaniach wskaźniki jakości  $QI$  zbiorów przybliżających  $\Psi_f$  są wielkościami o wartościach szacowanych na podstawie przeprowadzonych symu-



lacji komputerowych, można stosować omówione poniżej empiryczne wskaźniki jakości. Większość z nich zakłada, że dla rozwiązywanego zadania jest znany lub możliwy do określenia (np. przy wykorzystaniu przeglądowych algorytmów optymalizacji) front ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Wówczas można zbadać jakość zbiorów przybliżających  $\Psi_f$ , wykorzystując którąś z wybranych miar jakości zbiorów przybliżających:

- *error rate* (Veldhuizen 1999, Coello Coello i Lamont 2004), która określa, jaki procent ocen rozwiązań należących do zbioru przybliżającego  $\Psi_f$  nie należy do frontu optymalnego Pareto  $\Psi_P$ ;

- *generational distance* (Veldhuizen i Lamont 1998, Coello Coello i Lamont 2004), która jest miarą odległości ocen należących do zbioru przybliżającego  $\Psi_f$  względem frontu Pareto  $\Psi_P$ ;

- *spread* (Dias i Vasconcelos 2002, Zitzler 1999), która mierzy rozkład prawdopodobieństwa ocen rozwiązań należących do zbioru przybliżającego  $\Psi_f$  w zbiorze ocen rozwiązań niezdominowanych;

- *maximum spread MS* (Deb 2001), która mierzy, jak dobrze front optymalny Pareto  $\Psi_P$  jest odwzorowany przez zbiór przybliżający  $\Psi_f$ .

Oczywiście w praktycznych zadaniach znajomość frontu ocen rozwiązań optymalnych Pareto  $\Psi_P$  nie jest możliwa. Zakładając jednak, że badany zbiór przybliżający  $\Psi_f$  dąży do frontu ocen rozwiązań optymalnych Pareto  $\Psi_P^3$ , można sformułować empiryczne miary jakości niewymagające znajomości zbioru  $\Psi_P$ :

- Zitzler i Thiele (1999) zaproponowali miarę, nazywaną *size of the space covered* (ang. *metric S*, SSC), która szacuje, jaka część przestrzeni ocen  $V_f$  jest zdominowana przez oceny należące do ocenianego zbioru przybliżającego  $\Psi_f$ . Laumanns i in. (1999) rozszerzyli tę miarę na zagadnienia o większej liczbie kryteriów;

- Zitzler i Thiele (1998 b) zaproponowali inną miarę (ang. *metric C*) do porównywania zbiorów przybliżających; w tym wypadku dwa zbiory rozwiązań niezdominowanych porównywane są poprzez obliczenie, jaka część jednego z nich „pokrywa” drugi zbiór albo inaczej dominuje nad nim;

- Fonseca i Fleming (1996) zaproponowali statystyczną metodę porównywania algorytmów, nazwaną metodą powierzchni osiągalnych (ang. *attainment surfaces*), pozwalającą oszacować prawdopodobieństwo wygenerowania odpowiedniej oceny w serii symulacji komputerowych.

Z praktycznego punktu widzenia przedstawione wskaźniki jakości można podzielić na dwie grupy: (1) na służące do badania jakości pojedynczych zbiorów przybliżających  $\Psi_f$ , które wymagają znajomości dyskretnego zbioru ocen rozwiązań optymalnych Pareto  $\Psi_P$ ; (2) na służące do porównywania zbiorów przybliżających  $\Psi_f$  wygenerowanych przez różne algorytmy lub zbiorów przybliżających  $\Psi_f$  wygenerowanych przez te same algorytmy uruchamiane przy różnych wartościach parametrów sterujących; nie wymagają znajomości zbioru ocen rozwiązań optymalnych Pareto  $\Psi_P$ .

Przystępując do wygenerowania zbiorów przybliżających  $\Psi_f$ , należy pamiętać o tym, że w przypadku obliczeń ewolucyjnych, gdy porównuje się jakość zbiorów przybliżających,

---

<sup>3</sup> Jeśli założenie to nie byłoby słuszne, to w zasadzie optymalizacja wielokryterialna nie byłaby możliwa do przeprowadzenia, przynajmniej nie wszystkimi narzędziami.

zbiory uzyskuje się przy tych samych: (1) reprezentacjach zmiennych decyzyjnych (np. binarnych), (2) operatorach przekształcających zbiór rozwiązań należących do poprzedniego pokolenia w zbiór rozwiązań z pokolenia następnego (to znaczy krzyżowania i mutacji), (3) wartościach parametrów sterujących ewolucją pokoleń (liczba pokoleń, prawdopodobieństwo krzyżowania, prawdopodobieństwo mutacji itd.). W przeciwnym razie wnioski, sformułowane na podstawie badania jakości zbiorów przybliżających  $\Psi_f$ , nie są wiarygodne.

Zitzler i in. (2002 c) zbadali jednoargumentowe wskaźniki jakości z matematycznego punktu widzenia, w szczególności to, jakie wnioski można formułować na ich podstawie. Jedyne założeniem, jakie przyjęli na wstępie, było założenie, że decydecja preferuje rozwiązanie niezdominowane. Na tej podstawie: (1) dowiedli, że w ogóle nie jest możliwe sformułowanie skończonego zbioru jednoargumentowych wskaźników jakości, np. odległości i zróżnicowania, które wyczerpująco opisują jakość zbioru przybliżającego; (2) wykazali, że istniejące wskaźniki w najlepszym wypadku pozwalają wnioskować, że określony zbiór przybliżający nie jest gorszy od innego; (3) sformułowali dwa wskaźniki jakości, które mogą wykazać dominację wśród zbiorów przybliżających, oraz wykazali, dlaczego użycie takich wskaźników jest ograniczone; (4) sklasyfikowali i przedyskutowali istniejące jednoargumentowe wskaźniki jakości.

W każdym przypadku, gdy dokonuje się porównywania zbiorów przybliżających, trzeba pamiętać, że porównuje się pojedyncze symulacje zrealizowane przez poszczególne algorytmy.

### 5.3. Wektorowe wskaźniki jakości zbiorów przybliżających

Podsumowując rozważania z poprzedniego podrozdziału, można stwierdzić, że wskaźniki jakości odwzorowują zbiory przybliżające w zbiór liczb rzeczywistych. Podstawą jest ilościowe wyrażenie różnicy jakości pomiędzy zbiorami przybliżającymi przez zastosowanie wspólnych wskaźników (w sensie matematycznym) wyrażonych w liczbach rzeczywistych. To spostrzeżenie umożliwiło formalne zdefiniowanie wskaźnika jakości  $QI$  (patrz definicja 5.1).

Wymienione w podrozdziale 5.2 empiryczne wskaźniki jakości są przykładami jednoargumentowych i dwuargumentowych wskaźników jakości; jednak, w zasadzie, wskaźnik jakości może uwzględniać dowolną liczbę argumentów, którymi są zbiory przybliżające  $\Psi_f$ . Można także formułować inne metody porównywania, np. takie, które wykorzystują procedury testów statystycznych i mogą być stosowane w wielu przebiegach algorytmu (Fonseca i Fleming 1996, Knowles i Corne 2000, Grunert da Fonseca i in. 2001). Ponadto często do oceny zbiorów przybliżających stosuje się nie pojedyncze wskaźniki jakości, ale raczej kombinację różnych wskaźników, mierzących różne, interesujące decydenta, cechy zbiorów przybliżających. Na przykład Veldhuizen i Lamont (2000 b) zastosowali trzy wskaźniki jakości: średnią odległość rozwiązań w zbiorze przybliżającym  $\Psi_A$  od frontu ocen rozwiązań optymalnych Pareto  $QI_{GD}(\Psi_A)$ , wariancję odległości pomiędzy sąsiednimi ocenami rozwiązań w zbiorze przybliżającym  $\Psi_A$   $QI_S(\Psi_A)$  oraz liczbę zbioru przybliżającego  $\Psi_A$ ,  $I_{ONVG}(\Psi_A)$ . W takich przypadkach autor proponuje, aby mówić, że sformułowane są wektorowe wskaźniki jakości  $QI$ , które traktowane są jako funkcja wektorowa i każdemu zbiorowi przybliżającemu  $\Psi_f \subset \Lambda_f$  przyporządkowują wektor trzech liczb rzeczywistych:  $\Lambda_f \rightarrow \mathbb{R}^Q$ ,

gdzie  $Q$  jest liczbą skalnych wskaźników jakości. Można więc sformułować odpowiednią definicję:

**Definicja 5.4. Wektorowy wskaźnik jakości (QI).**  $Q$ -wymiarowy wektorowy wskaźnik jakości **QI** jest funkcją wektorową **QI**:  $\Lambda_f \rightarrow \mathbb{R}^Q$ , która każdemu zbiorowi przybliżającemu  $\Psi_f \subset \Lambda_f$  przyporządkowuje wektor  $Q$  liczb rzeczywistych  $\mathbf{QI} = [QI_1(\Psi_f) \ QI_2(\Psi_f) \ \dots \ QI_q(\Psi_f) \ \dots \ QI_Q(\Psi_f)]^T = [QI_1 \ QI_2 \ \dots \ QI_q \ \dots \ QI_Q]^T \in \mathbb{R}^Q$ , czyli inaczej **QI**:  $\Psi_f \rightarrow [QI_1 \ QI_2 \ \dots \ QI_q \ \dots \ QI_Q]^T \in \mathbb{R}^Q$ . Składowe  $QI_q$  wektorowego wskaźnika jakości **QI** nazywane są skalarnymi wskaźnikami jakości spełniającymi definicję 5.1. ■

Po przyjęciu powyższej definicji można mówić o skalarnych wskaźnikach jakości  $QI_q(\Psi_f)$  – definicja 5.1 – oraz o wektorowych wskaźnikach jakości **QI**( $\Psi_f$ ) – definicja 5.4. Zgodnie z tą ostatnią definicją na przykład Veldhuizen i Lamont (2000 b) zastosowali trójwymiarowy wektorowy wskaźnik jakości  $\mathbf{QI}(\Psi_A) = [QI_1(\Psi_A) \ QI_2(\Psi_A) \ QI_3(\Psi_A)]^T = [QI_{GD}(\Psi_A) \ QI_S(\Psi_A) \ QI_{ONVG}(\Psi_A)]^T$ , którego współrzędnymi są trzy skalarne wskaźniki jakości: średnia odległość ocen rozwiązań w zbiorze przybliżającym  $\Psi_A$  od frontu ocen rozwiązań optymalnych Pareto  $\Psi_P$ ,  $QI_{GD}(\Psi_A)$ , wariancja odległości pomiędzy sąsiednimi ocenami rozwiązań w zbiorze przybliżającym  $\Psi_A$ ,  $QI_S(\Psi_A)$  oraz licznosc zbioru przybliżającego  $\Psi_A$ ,  $QI_{ONVG}(\Psi_A)$ .

## 5.4. Strategie oceny jakości zbiorów przybliżających

Jak to już wspomniano, można przyjąć, że decydent lub projektant zazwyczaj jest zainteresowany uzyskaniem w rezultacie wielokryterialnej analizy optymalizacyjnej nie jednego idealnego rozwiązania, ale większej liczby rozwiązań alternatywnych równomiernie rozłożonych w odniesieniu do powierzchni kompromisu, ponieważ zapewnia mu to większą swobodę podejmowania decyzji, w tym także z uwzględnieniem wiedzy niezapisanej w algorytmie optymalizacyjnym. Używając wielokrotnie narzędzia obliczeniowego, przy zmienionych wartościach parametrów sterujących, uzyska się zapewne różne zbiory przybliżające  $\Psi_f$ . Nie zaproponowano jednak dotychczas wskaźników jakości pozwalających na jednoznaczne wskazanie, który ze zbiorów przybliżających  $\Psi_f \subset \Lambda_f$  jest lepszy (Sarker i Coello Coello 2002). Niemniej jednak zastosowanie kilku wskaźników jednocześnie oraz inne proste rozważania mogą pomóc w porównaniu dwóch lub kilku zbiorów przybliżających.

Uogólniając, przegląd dostępnej literatury wskazuje, że można obecnie stosować cztery podstawowe strategie oceny jakości zbiorów przybliżających  $\Psi_f \in \Lambda_f$ , uzyskanych w wyniku uruchomienia ewolucyjnych algorytmów optymalizacji wielokryterialnej: (1) metodę oceny wizualnej (VAM), (2) metodę relacji dominacji (DRM), (3) metodę wskaźników jakości (QIM), (4) metodę funkcji osiągnięcia (AFM).

Jeśli jest to możliwe, ocenę zbiorów przybliżających  $\Psi_f$  należy rozpocząć od graficznego przedstawienia frontu ocen rozwiązań optymalnych Pareto  $\Psi_P$  (jeśli jest znany) i zbiorów przybliżających  $\Psi_f$ . Następnie można poddać je ocenie pod kątem: (1) możliwego odwzorowania frontu Pareto  $\Psi_P$ , (2) jednorodności rozkładu rozwiązań wzdłuż krzywej kompromisu, (3) braku skupień i obszarów o małej gęstości rozwiązań, itd. W wielu przypadkach ocena wizualna pozwala na wyciągnięcie wartościowych wniosków, jeśli zbiory przybliżające  $\Psi_f$  wyraźnie różnią się jakością odwzorowania frontu ocen optymalnych Pareto  $\Psi_P$ . Niestety, podejście takie z oczywistych względów jest możliwe tylko wtedy, gdy liczba kryte-

riów oceny wynosi trzy lub mniej. W przypadkach, gdy jakość zbiorów przybliżających  $\Psi_f$  jest zbliżona i trudna do względnej oceny, na podstawie oceny wizualnej, pomocne mogą być metody statystyczne. Liczba ocen rozwiązań próbnych, średnia odległość pomiędzy sąsiednimi ocenami (oraz – jeśli jest to możliwe – ich rozkład) oraz średnia odległość ocen rozwiązań próbnych (oraz ich rozkład) od początku układu współrzędnych w przestrzeni ocen (lub jakiegoś innego punktu referencyjnego) mogą ułatwić porównanie jakości zbiorów przybliżających  $\Psi_f$ . Metoda jest metodą jakościową, nie pozwala na liczbową, chociażby binarną, interpretację określeń „lepszy”, „gorszy”.

Szeregowanie rozwiązań  $\Psi_f \subset A_f$  pod względem relacji dominacji oznacza ogólnie niezależną od preferencji decyden<sup>4</sup> ocenę ich jakości opartą na porównywaniu parami zbiorów przybliżających, podobnie jak w przypadku relacji dominacji Pareto zastosowanej do oceny funkcji przystosowania w ewolucyjnej optymalizacji wielokryterialnej. Mówiąc dokładniej, wszystkie porównywane zbiory przybliżające są archiwizowane, porównywane parami ze sobą i porządkowane według liczby zbiorów zdominowanych przez wybierane kolejno zbiory przybliżające. W rezultacie każdemu zbiorowi przybliżającemu  $\Psi_f \subset A_f$  można przyporządkować rangę (wskaźnik szeregowania) w taki sposób, że jej wartość będzie maksymalizowana. Z kolei, aby sformułować względne stwierdzenie o przewadze któregoś ze zbiorów przybliżających  $\Psi_f$ , trzeba statystycznie opracować różne próbki rang. Zaletą takiego podejścia jest to, że jest ono oparte tylko na relacji dominacji Pareto pomiędzy zbiorami, a procedura szeregowania nie wymaga sformułowania dodatkowych preferencji decyden<sup>4</sup>. Metoda ta jednak dostarcza najmniej informacji spośród trzech, przedstawionych w dalszej części, strategii ilościowych, ponieważ różnice jakości możliwe do uchwycenia uwzględniają jedynie relację dominacji i nie wykorzystują informacji o innych preferencjach decyden<sup>4</sup>ów. Nie pozwalają na wykrycie różnicy w poziomach określenia „lepszy”, ponieważ są tylko relacją binarną pozwalającą nadać liczbową, binarną, wartość określeniom „lepszy” – „dominujący” i „gorszy” – „zdominowany”.

Wskaźniki jakości umożliwiają wyrażenie i zmierzenie różnicy jakości pomiędzy zbiorami przybliżającymi, przy założeniu wykorzystania dodatkowych informacji o preferencjach decyden<sup>4</sup>a. Używając jednoargumentowego wskaźnika jakości  $QI(\Psi_f)$ , to znaczy funkcji odwzorowującej każdy zbiór przybliżający  $\Psi_f \subset A_f$  w zbiór liczb rzeczywistych jako pojedynczych atrybutów jakości, zbiorom przybliżającym  $\Psi_f$  przyporządkowuje się próbkę wartości wskaźnika. Testując odpowiednie hipotezy statystyczne, można sprawdzić, czy jeden zbiór przybliżający jest lepszy od innego pod względem preferencji reprezentowanej przez rozważany wskaźnik. Bardzo ważne, ale jednocześnie trudne do spełnienia, jest wymaganie, aby formułować i stosować wskaźniki jakości, które są zgodne z dominacją Pareto, co oznacza, że gdy jeden zbiór przybliżający jest preferowany bardziej niż inny zbiór przybliżający pod względem wskaźnika jakości, musi również nad nim dominować w sensie Pareto. Tylko niektóre wskaźniki proponowane w literaturze są zgodne w sensie Pareto. Problem polega przede wszystkim na tym, że w praktyce zbiorów przybliżających, również tych dyskutowanych w pracy, nie można porównywać ze sobą w sensie dominacji Pareto, ponieważ ich powierzchnie osiągalne się przenikają. Nie można więc rozstrzygać o wzajemnej dominacji zbiorów przybliżających.

---

<sup>4</sup> Oczywiście poza tymi, które są reprezentowane przez kryteria optymalizacji.

Metoda wskaźników jakości jest bardzo interesującym podejściem, ponieważ można ją wykorzystać także w przypadku dużej liczby kryteriów oceny jakości (oczywiście poszczególne wskaźniki różnią się niezbędnymi nakładami obliczeniowymi) oraz dlatego, że dostarcza ilościowych informacji o różnicach w jakości zbiorów przybliżających  $\Psi_f$ . Pamiętać jednak należy, że formułowane wnioski zawsze powinny być interpretowane w kontekście rozważanej preferencji decydenta. Ponadto transformacja zbiorów przybliżających  $\Psi_f$  do liczb rzeczywistych nieuchronnie prowadzi do utraty części informacji, dlatego nadal nie wszystkie istniejące różnice jakości mogą być wykryte przez zastosowane wskaźniki.

MOEA są algorytmami losowymi, co oznacza, że różne zbiory przybliżające uzyskiwane są z różną częstością (różnym prawdopodobieństwem). Jak zatem można to zmierzyć? Propozycją odpowiedzi na to pytanie jest AFM (Fonseca i Fleming 1996), która pozwala dla każdego wektora w przestrzeni celów  $\mathbf{f}(\mathbf{x})$  określić prawdopodobieństwo, że zostanie on osiągnięty, co oznacza, że zostanie słabo zdominowany przez zbiór przybliżający wygenerowany w jednym przebiegu optymalizatora. Empiryczna funkcja osiągnięcia EAF reprezentuje estymację nieznaną zazwyczaj funkcji osiągalnej i podsumowuje informacje o wielu zbiorach przybliżających poprzez obliczenie dla każdego wektora celu  $\mathbf{f}(\mathbf{x})$  względnej częstości, z jaką został uzyskany. W przeciwieństwie do trzech omówionych strategii zostaje utracona podczas transformacji tylko niewielka ilość informacji; odpowiednie statystyczne porównanie dwóch empirycznych funkcji osiągalnych może ujawnić wiele informacji dotyczących miejsc, w których porównywane zbiory przybliżające są zróżnicowane. W tym sensie strategia funkcji osiągalnej jest bardziej wrażliwa (czuła) na różnice w jakości niż pozostałe trzy strategie oceny. Jednak podstawowymi wadami metody są: (1) duże wymagania obliczeniowe, (2) ograniczenie praktycznego stosowania do dwóch lub trzech kryteriów optymalizacji (Knowles i in. 2006).

## **5.5. Ocena skuteczności ewolucyjnych algorytmów optymalizacji wielokryterialnej**

Przedyskutowana szczegółowo w poprzednich podrozdziałach ocena jakości zbiorów przybliżających  $\Psi_f$  może być w naturalny sposób przeniesiona na ocenę skuteczności algorytmów i narzędzi obliczeniowych, które wykorzystywane są do generowania tych zbiorów. Podobnie jak w przypadku oceny jakości zbiorów przybliżających nie opublikowano jeszcze zaakceptowanych powszechnie procedur pozwalających porównywać jakość wyników uzyskanych za pomocą różnych algorytmów, zwykle w wielu przebiegach optymalizatora, lub tego samego algorytmu w wielu przebiegach, uwzględniających ilościowo statystyczny charakter (Sarker i Coello Coello 2002, Knowles i in. 2006).

Pojęcie skuteczności algorytmu optymalizacyjnego jako metody obliczeniowej, realizowanej w postaci programu komputerowego, uwzględnić powinno dwa aspekty: (1) jakość osiągniętego rezultatu oraz (2) wielkość niezbędnych do tego nakładów obliczeniowych. Jeśli chodzi o drugi aspekt, powszechnie przyjmuje się, że liczba obliczeń funkcji celu i całkowity czas obliczeń są stałe – w tym sensie nie ma różnicy pomiędzy sposobem oceny algo-

rytmów optymalizacji jedno- i wielokryterialnej<sup>5</sup>. W przypadku jakości rozwiązań jest inaczej. Ponieważ w problemach optymalizacji wielokryterialnej rozwiązaniem są zbiory przybliżające  $\Psi_f$ , ocena ich jakości jest kluczowym problemem przed oceną skuteczności algorytmów optymalizacyjnych. Metody oceny i wskaźniki jakości zbiorów przybliżających, omówione w poprzednich podrozdziałach, mogą być stosowane bezpośrednio do oceny skuteczności algorytmów optymalizacyjnych. Oczywiście przy uwzględnieniu wszystkich krytycznych uwag dotyczących tych metod.

Ponieważ problemy oceny jakości zbiorów przybliżających  $\Psi_f$  oraz skuteczności ewolucyjnych algorytmów optymalizacyjnych są ze sobą bardzo ściśle związane, w obu przypadkach stosować można podobne metody wnioskowania. Można nawet utożsamiać oba problemy oceny i zamiennie stosować pojęcia „badania jakości zbiorów przybliżających” oraz „badania skuteczności algorytmów optymalizacyjnych”. Oznacza to, że jeśli nie pojawi się wyraźne zastrzeżenie, że jest inaczej, zazwyczaj stwierdzenie, że zbiór przybliżający  $\Psi_A$ , wygenerowany przez optymalizator  $A$ , jest lepszy od zbioru  $\Psi_B$ , wygenerowanego przez optymalizator  $B$ , można traktować jako równoważne stwierdzeniu, że optymalizator  $A$  jest skuteczniejszy od optymalizatora  $B$ .

Określenie wiarygodnej metody oceny jest bardzo ważne, jeżeli chcemy ją zastosować do walidacji algorytmu optymalizacyjnego. W podrozdziale 5.1 przedyskutowano już, dlaczego w przypadku optymalizacji wielokryterialnej ocena uzyskanych wyników, a tym samym ocena skuteczności algorytmów, jest trudna. Ponadto w przypadku algorytmu optymalizacyjnego można, na przykład, oczekiwać odpornego algorytmu dążącego do frontu Pareto praktycznie w każdym przypadku, bardziej niż dążącego do frontu Pareto tylko okazjonalnie (w przypadku określonych typów zadań), nawet jeśli algorytm ten pozwala uzyskać lepsze wyniki. Można być także zainteresowanym oceną zachowania się algorytmu ewolucyjnego w trakcie symulacji, próbując określić jego zdolność do utrzymania zróżnicowania i stopniowego podążania do zbioru ocen rozwiązań bliskiego frontowi Pareto. Następnym problemem w dyskusji jest ustalenie, jakie wielkości będą poddane pomiarowi, ocenie i analizie. Te krótkie rozważania pokazują, jak trudnym zadaniem jest opracowanie miar skuteczności algorytmów optymalizacji wielokryterialnej.

Można przyjąć – podobnie jak w przypadku oceny jakości zbiorów przybliżających – że także w przypadku oceny skuteczności algorytmów sformułowanie dobrej miary skuteczności powinno uwzględniać (Zitzler i in. 2000): (1) minimalizację odległości wygenerowanego przez algorytm przybliżenia frontu ocen rozwiązań optymalnych Pareto od rzeczywistego frontu Pareto, (2) maksymalizację zróżnicowania odszukanych ocen rozwiązań niezdominowanych, (3) maksymalizację liczby ocen rozwiązań w zbiorze przybliżającym.

Sarker i Coello Coello (2002) dokonali przeglądu propozycji uznanych przez nich za najważniejsze i umożliwiające zmierzenie trzech wymienionych i poddanych ocenie aspektów pojęcia „skuteczność”. Zauważają przy tym, że nie istnieje metoda pozwalająca zmierzyć te trzy aspekty za pomocą jednej wielkości i że podejmowane dotychczas próby opraco-

---

<sup>5</sup> Oczywiście przy takich założeniach pomija się część wysiłku obliczeniowego przeznaczonego na kontrolę relacji dominacji oraz archiwizowanie rozwiązań niezdominowanych, czyli na budowę zbioru przybliżającego  $\Psi_f$ .

wania pojedynczej miary były bezowocne, ponieważ dotyczyły bardzo różnych właściwości algorytmów.

Zitzler i in. (2002 c, d, 2003), Fonseca i in. (2005), Knowles i in. (2006), oraz Brockhoff (2009) w kontekście badania jakości zbiorów przybliżających przedstawili przegląd problemów, które mogą być odniesione także do oceny skuteczności wielokryterialnych losowych algorytmów optymalizacyjnych.

Przy założeniu, że należy ocenić skuteczność dwóch ewolucyjnych algorytmów optymalizacji wielokryterialnej, odpowiedź na pytanie o to, czy któryś z nich przewyższa inne, pozwala uwzględnić wiele różnych szczegółowych aspektów tego pojęcia, takich jak: jakość rozwiązań, wymagany czas obliczeń, wartości parametrów sterujących. Podobnie jak inni badacze autor skupił się na jakości uzyskanych rozwiązań i na tym, jak porównywać ze sobą skuteczność różnych algorytmów optymalizacyjnych. Założył również, że rozważa się tylko jedno zadanie optymalizacji i algorytmy, które są porównywane deterministyczne, co oznacza, że każdy optymalizator generuje dokładnie jeden zbiór przybliżający.

Napisano już wyżej, że najbardziej naturalnym sposobem porównywania dwóch zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$ , wygenerowanych przez dwa różne optymalizatory wielokryterialne, jest wykorzystanie struktury preferencji będącej jej podstawą. Szczegółową dyskusję tego problemu oraz możliwe do sformułowania wnioski przedstawiono w podrozdziale 5.2. Dyskusja ta może być bezpośrednio przeniesiona na problem oceny skuteczności algorytmów optymalizacyjnych, jeśli relacja dominacji ma posłużyć do rozstrzygnięcia o wyższości któregoś z nich. Jak wiadomo, w wielu przypadkach relacja dominacji nie jest do tego wystarczająca.

Rozważając zaproponowane i omówione w podrozdziałach 5.2 i 5.3 wskaźniki jakości dla zbiorów przybliżających, można także formułować bardziej ogólne wnioski dotyczące nie tylko zbiorów przybliżających, ale również skuteczności algorytmów, które zastosowano do wygenerowania tych zbiorów. Na przykład przedstawiona w podrozdziale 5.2 analiza zbiorów przybliżających  $\Psi_f$ , pokazanych na rysunku 5.1 (a), pozwala uogólnić sformułowany wniosek i odnieść go do algorytmów optymalizacji – są podstawy do stwierdzenia, że algorytm optymalizacji wielokryterialnej, który zastosowano do wygenerowania zbioru przybliżającego  $\Psi_A$ , jest skuteczniejszy od algorytmu, który wygenerował zbiór  $\Psi_B$ , jeśli wskaźnik hiperobjętości  $QI_H$  reprezentuje nieujęte w algorytmie optymalizacji preferencje decydenta dotyczące skuteczności algorytmów. Oczywiście pamiętać trzeba o tym, że każde porównywanie optymalizatorów wielokryterialnych ograniczone jest nie tylko wyborem problemu do obliczeń i parametrów sterujących symulacjami komputerowymi, ale także przyjętymi wskaźnikami jakości reprezentującymi preferencje decydenta. Na przykład, jeśli do badań porównawczych wybrano wskaźnik hiperobjętości  $QI_H$ , każde stwierdzenie typu „optymalizator  $A$  przewyższa optymalizator  $B$  pod względem jakości wygenerowanego zbioru przybliżającego”, to musi być konieczne uściśnione poprzez uzupełnienie „przy założeniu, że wskaźnik hiperobjętości  $QI_H$  odzwierciedla preferencje decydenta”.

Powracając do przykładu omówionego w podrozdziale 5.2: jeśli wskaźnik jakości  $QI_N$  równy liczbie ocen w zbiorze przybliżającym  $\Psi_f$  jest taki, że większa wartość wskaźnika jest bardziej preferowana, to w przypadku zbiorów przybliżających przedstawionych na rysunku 5.1 (a),  $QI_M(\Psi_A) = 11$ ,  $QI_M(\Psi_B) = 14$ , mamy podstawy, aby stwierdzić, że algorytm, któ-

ry wygenerował zbiór  $\Psi_B$  przybliżający zbiór ocen rozwiązań optymalnych Pareto, jest skuteczniejszy od algorytmu, który wygenerował zbiór  $\Psi_A$ , jeśli liczba ocen rozwiązań w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta. Można zapisać to w postaci:

$$QI_N(\Psi_B) > QI_N(\Psi_A) \Rightarrow \uparrow QI_N \Rightarrow \Psi_B \blacktriangleright \Psi_A$$

czyli: ponieważ liczba ocen w zbiorze  $\Psi_B$  przybliżającym zbiór ocen rozwiązań optymalnych Pareto  $QI_N(\Psi_B)$  jest większa od liczby ocen  $QI_N(\Psi_A)$  w zbiorze  $\Psi_A$  i ponieważ liczba ocen w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta, dotyczące skuteczności algorytmu optymalizacyjnego, w taki sposób, że większe wartości wskaźnika  $QI_N$  są bardziej preferowane, mamy podstawy do stwierdzenia, że algorytm optymalizacji wielokryterialnej, który wygenerował zbiór przybliżający  $\Psi_B$ , jest skuteczniejszy od algorytmu, który wygenerował zbiór  $\Psi_A$ .

Przedstawione i omówione w podrozdziale 5.2 empiryczne wskaźniki jakości zbiorów przybliżających mogą być zastosowane także do oceny skuteczności algorytmów optymalizacyjnych. Również w tym wypadku mogą one służyć do oceny (1) skuteczności pojedynczych algorytmów optymalizacyjnych lub (2) do porównywania skuteczności różnych algorytmów lub skuteczności tych samych algorytmów uruchamianych przy różnych wartościach parametrów sterujących. Wskaźniki te zostaną przez autora wykorzystane w rozdziale 9 także do względnej oceny skuteczności algorytmów optymalizacyjnych.

W celu zachowania wiarygodności formułowanych ocen, podobnie jak w przypadku oceny jakości zbiorów przybliżających, również w przypadku oceny skuteczności algorytmów optymalizacyjnych zakłada się, że algorytmy optymalizacyjne były uruchamiane przy tych samych (1) reprezentacjach zmiennych decyzyjnych, (2) operatorach przekształcających zbiór rozwiązań poprzedniego pokolenia w zbiór rozwiązań pokolenia następnego oraz (3) wartościach parametrów sterujących ewolucją pokoleń.

Do oceny skuteczności algorytmów optymalizacyjnych można również zastosować strategię oceny jakości zbiorów przybliżających przedstawione w podrozdziale 5.4. Wówczas wnioski o skuteczności algorytmów optymalizacyjnych będą formułowane na podstawie oceny jakości zbiorów przybliżających wygenerowanych przez te algorytmy.

## 5.6. Podsumowanie i wnioski

W każdym przypadku rezultat ewolucyjnej optymalizacji wielokryterialnej, czyli zbiory przybliżające, (1) wygenerowane przez ten sam algorytm lub przez to samo narzędzie obliczeniowe, lecz uruchamiane przy różnych wartościach parametrów sterujących<sup>6</sup>, lub (2) wygenerowane przez różne algorytmy lub narzędzia obliczeniowe poddawane porównaniom, powinny być poddane szczegółowej i krytycznej ocenie. Celem przeprowadzonej analizy porównawczej jest ujawnienie różnic w jakości zbiorów przybliżających (lub skutecz-

---

<sup>6</sup> W przypadku algorytmu genetycznego będą to przede wszystkim wielkość populacji i liczba pokoleń. Mogą to być także: prawdopodobieństwo mutacji, prawdopodobieństwo krzyżowania i inne, również zakresy zmienności zmiennych decyzyjnych – większa zmienność pozwala na zwiększenie efektu eksploracji przestrzeni rozwiązań, przy jednoczesnym osłabieniu zbieżności algorytmu.



ności algorytmów optymalizacji wielokryterialnej).<sup>7</sup> Do przeprowadzenia tej oceny zastosować można metody: (1) oceny wizualnej, (2) badania relacji dominacji, (3) badania wskaźników jakości i (4) metody statystyczne. Oprócz oceny wizualnej najprostszą metodą porównywania jest sprawdzenie, czy wybrany rezultat jest lepszy od innego pod względem relacji dominacji Pareto. Jednak ani ocena wizualna, ani sprawdzenie relacji dominacji Pareto nie mogą być podstawą do udzielenia odpowiedzi na bardziej szczegółowe pytania. W takich przypadkach pomocne mogą być ilościowe, deterministyczne lub statystyczne, miary jakości rozwiązań.

Ilościowe miary jakości odwzorowują zbiory przybliżające w zbiór liczb rzeczywistych. Podstawową ideą jest ilościowe wyrażenie różnicy jakości pomiędzy zbiorami przybliżającymi poprzez zastosowanie wspólnych miar (w sensie matematycznym) wyrażonych w liczbach rzeczywistych. Zazwyczaj wykorzystuje się jednoargumentowe, rzadziej dwuarargumentowe, wskaźniki jakości; jednak w zasadzie wskaźnik jakości może uwzględniać dowolną liczbę argumentów (zbiorów przybliżających). Można także formułować inne metody porównywania, np. takie, które wykorzystują procedury testów statystycznych i mogą być stosowane w wielu przebiegach algorytmu.

Jednoargumentowe wskaźniki jakości (skuteczności) są najczęściej opisywane w literaturze. Powodem ich atrakcyjności jest możliwość szacowania miar jakości zbiorów przybliżających (skuteczności algorytmów) niezależnie od innych rozważanych zbiorów przybliżających (algorytmów optymalizacyjnych, optymalizatorów). Mają one ograniczenia, o których napisano w tym rozdziale, i różnice w sile diagnostycznej istniejących wskaźników.

Do oceny zbiorów przybliżających (i skuteczności algorytmów) stosować można nie tylko pojedyncze wskaźniki jakości, ale także kombinację różnych wskaźników mierzących różne, interesujące decydenta, cechy zbiorów przybliżających lub algorytmów optymalizacyjnych. W takich przypadkach można mówić o sformułowaniu wektorowych wskaźników jakości **QI**, które jako funkcja wektorowa każdemu zbiorowi przybliżającemu przyporządkowują wektor liczb rzeczywistych. W ten sposób zadanie wygenerowania wysokiej jakości zbioru przybliżającego, jako rezultatu wielokryterialnego zadania optymalizacji, jest także zadaniem wielokryterialnym ze względu na wektorowe wskaźniki jakości **QI**.<sup>8</sup>

Liczba, zaproponowanych i spotykanych w literaturze, wskaźników jakości (skuteczności) może sugerować, że cel, jakim jest opracowanie wskaźników jakości pozwalających ocenić, czy dany zbiór przybliżający jest lepszy od drugiego (lub czy dany optymalizator jest skuteczniejszy od drugiego), jest osiągalny, chociaż z ogromną trudnością. Udowodniono jednak, że celu tego nie można osiągnąć, ponieważ liczba miar jakości (skuteczności), które określają, jak dobry jest zbiór przybliżający (optymalizator), jest nieskończona (Zitzler i in. 2002 d, 2003).

Opracowane przez autora narzędzie obliczeniowe (służące do ewolucyjnej optymalizacji wielokryterialnej KKSMM, umożliwiające wygenerowanie zbiorów niezdominowanych wariantów konstrukcji, których oceny utworzą zbiory przybliżające front ocen optymalnych Pareto) zostanie przedstawione w następnym rozdziale pracy.

---

<sup>7</sup> Można również podczas obliczeń testowych poszukiwać najlepszych wartości parametrów sterujących przebiegiem symulacji komputerowych, realizujących ten sam algorytm.

<sup>8</sup> Przypomina to rosyjską babuszkę – optymalizacja wielokryterialna wektorowych wskaźników jakości **QI(x)** stanowi głębszy poziom wielokryterialnej optymalizacji KKSMM pod względem wektorowej funkcji celu **f(x)**.



## 6. Narzędzie obliczeniowe do ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku

### 6.1. Podstawowe techniki obliczeniowe

#### 6.1.1. Funkcje użyteczności

Najbardziej istotnym elementem narzędzia obliczeniowego, wykorzystującego algorytm genetyczny do rozwiązywania ewolucyjnych zadań optymalizacji wielokryterialnej, jest odpowiednie sformułowanie funkcji przystosowania kierującej procesem optymalizacji. W pierwszym kroku, nawiązując do klasycznej metody optymalizacji, formułuje się jedną funkcję celu, która jest sumą iloczynów kryteriów optymalizacji z odpowiednimi współczynnikami wagowymi:

$$F(\mathbf{x}) = \sum_{s=1}^S w_s f_s(\mathbf{x}) \quad (6.1)$$

Wartości współczynników wagowych  $w_s$  kryteriów oceny dobierane są w sposób odpowiedni do wybranej przez użytkownika strategii agregacji kryteriów optymalizacji (patrz podrozdział 4.3). W takim przypadku wielokryterialne zadanie optymalizacji sprowadzane jest do odpowiedniego zadania optymalizacji jednokryterialnej. Przypomnijmy, że w przypadku algorytmów ewolucyjnych zabieg taki jest konieczny, ponieważ optymalizacją kieruje jednowartościowa wielkość<sup>1</sup>, w odniesieniu do której określa się prawdopodobieństwo selekcji.

Sformułowanie skalarnej funkcji celu w postaci zależności (6.1) jest powszechnie przyjętą praktyką, wymaga jednak rozwiązania trzech zasadniczych problemów, które są z tym związane:

1. Jakiego typu będzie funkcja celu  $F(\mathbf{x})$ , tzn.  $F(\mathbf{x}) \rightarrow \min!$  czy  $F(\mathbf{x}) \rightarrow \max!$ , w przypadku, gdy kryteria optymalizacji (kryteria oceny)  $f_s(\mathbf{x})$  będą różnych typów, np.  $f_1(\mathbf{x}) \rightarrow \min!$  oraz  $f_2(\mathbf{x}) \rightarrow \max!?$

2. Jak sumować wartości kryteriów optymalizacji  $f_s(\mathbf{x})$  w przypadku, gdy są one mierzone w różnych jednostkach, np.  $[f_1(\mathbf{x})] = \text{kN}$  i  $[f_2(\mathbf{x})] = \text{m}^2$ ?

3. Jak uniknąć dominacji (nie mamy tu na myśli dominacji w sensie Pareto, lecz zwykłą dominację w sensie arytmetycznym) tych kryteriów oceny, których wartości są znacznie większe od innych wartości, np.  $f_1(\mathbf{x}) = 2345,76 \gg f_2(\mathbf{x}) = 0,00342$ ?

Problemy tych można uniknąć, zastępując w zależności (6.1) kryteria oceny  $f_s(\mathbf{x})$  przez odpowiednio sformułowane funkcje użyteczności tych kryteriów:  $f_s(\mathbf{x}) \rightarrow u_s(f_s(\mathbf{x}))$ . Określenie „odpowiednio sformułowane” oznacza to, że funkcje użyteczności  $u_s(f_s(\mathbf{x}))$  powinny spełniać następujące warunki:

---

<sup>1</sup> Najczęściej jest to funkcja przystosowania, ale może to być także inna wielkość, w odniesieniu do której określane będzie prawdopodobieństwo selekcji, np. ranga rozwiązań.

(a) powinny być maksymalizowane dla pożądaných wartości kryteriów oceny, niezależnie od ich typu, tzn.  $u_s(f_s(\mathbf{x}) \rightarrow \max!) \rightarrow \max!$  oraz  $u_s(f_s(\mathbf{x}) \rightarrow \min!) \rightarrow \max!$ ;

(b) wartości funkcji powinny być bezwymiarowe i unormowane do jedności, tzn.  $u_s(f_s(\mathbf{x})) \rightarrow [0, 1]$ .

Matematyczne funkcje użyteczności, które spełniają powyższe warunki i zostały przyjęte przez autora do zastosowania w zbudowanym narzędziu obliczeniowym, wyrażono w postaci:

$$u_s(\mathbf{x}) = \left( \frac{f_s(\mathbf{x})}{f_{s,max}} \right)^{r_s} \rightarrow \max! \Leftrightarrow f_s(\mathbf{x}) \rightarrow \max! \quad (6.2)$$

$$u_s(\mathbf{x}) = \left( \frac{f_{s,max} - f_s(\mathbf{x})}{f_{s,max}} \right)^{r_s} \rightarrow \max! \Leftrightarrow f_s(\mathbf{x}) \rightarrow \min! \quad (6.3)$$

Wartości parametrów funkcji użyteczności ( $f_{s,max}$  i  $r_s$ ) wyznacza się podczas obliczeń testowych, osiągając pożądaną zbieżność algorytmu.


Po przyjęciu funkcji użyteczności w postaci zależności (6.2) lub (6.3) skalarna funkcja celu może być zapisana w postaci:

$$F(\mathbf{x}) = \sum_{s=1}^S w_s u_s(\mathbf{x}) \quad (6.4)$$

Wprowadzenie funkcji użyteczności  $u_s$  w postaci zależności (6.2) lub (6.3) w miejsce kryteriów oceny pozwala uwzględnić w analizie optymalizacyjnej zarówno subiektywną atrakcyjność przyjętych kryteriów oceny  $f_s$ , jak i dążenie do żądanej zbieżności algorytmu. Ponieważ wartość funkcji użyteczności  $u_s$  jest miarą atrakcyjności odpowiedniego kryterium oceny  $f_s$ , w tym samym znaczeniu używane jest również pojęcie funkcji preferencji. W celu poprawnego rozwiązania zadania optymalizacji i akceptowanej zbieżności algorytmu ważne jest, oprócz przyjęcia odpowiedniej postaci matematycznej, także przyjęcie wartości parametrów funkcji użyteczności  $u_s$  dla założonych kryteriów oceny  $f_s$ .

Na rysunkach 6.1 (a) i 6.1 (b) pokazano, na przykładzie kryterium typu  $f_s \rightarrow \min!$ , wpływ parametrów  $f_{s,max}$  i  $r_s$  funkcji użyteczności  $u_s$  na przebieg zmienności funkcji. Przy ustalonej wartości współczynnika potęgowego  $r_s = 5$  zwiększanie wartości parametru  $f_{s,max}$  powoduje zmniejszanie wrażliwości funkcji użyteczności  $u_s$  na zmiany wartości kryterium  $f_s$ , przy większych wartościach funkcji użyteczności. Przy ustalonej największej wartości kryterium  $f_{s,max} = 2800$  zmniejszanie wartości współczynnika potęgowego  $r_s$  powoduje zmniejszanie wrażliwości funkcji użyteczności na zmiany wartości kryterium, również przy większych wartościach funkcji użyteczności.

Na rysunkach 6.1 (c) i 6.1 (d) pokazano, na przykładzie kryterium typu  $f_s \rightarrow \max!$ , wpływ parametrów  $f_{s,max}$  i  $r_s$  funkcji użyteczności  $u_s$  na przebieg zmienności funkcji. Przy ustalonej wartości współczynnika potęgowego  $r_s = 1,5$  zwiększanie wartości parametru  $f_{s,max}$  powoduje zmniejszanie wrażliwości funkcji użyteczności na zmiany wartości kryterium, przy mniejszych wartościach funkcji. Przy ustalonej największej wartości kryterium  $f_{s,max} = 2000$  zmniejszanie wartości współczynnika potęgowego  $r_s$  powoduje zmniejszanie wrażliwości funkcji użyteczności na zmiany wartości kryterium, przy większych wartościach funkcji.



Rys. 6.1. Wpływ największej wartości kryterium oceny  $f_{s,max}$  na wartość funkcji użyteczności w przypadku kryterium typu min! (a), wpływ wartości współczynnika potęgowego  $r_s$  na wartość funkcji użyteczności w przypadku kryterium typu min! (b), wpływ największej wartości kryterium oceny  $f_{s,max}$  na wartość funkcji użyteczności w przypadku kryterium typu max! (c), wpływ wartości współczynnika potęgowego  $r_s$  na wartość funkcji użyteczności w przypadku kryterium typu max! (d)

### 6.1.2. Funkcje kary za naruszenie ograniczeń

Do sterowania dopuszczalnością wariantów próbnych generowanych przez algorytm przyjęto metodę zewnętrznej funkcji kary:

$$F(\mathbf{x}) = \sum_{s=1}^S w_s u_s(\mathbf{x}) + \sum_{p=1}^P w_p P(\mathbf{x})_p^{r_p} \quad (6.5)$$

Składowe funkcji kary  $P(\mathbf{x})_p$  dla wszystkich ograniczeń zdefiniowano w postaci funkcji wykładniczej, która ma bardzo atrakcyjną interpretację inżynierską. Na przykład funkcja kary za naruszenie ograniczenia grubości płyty poszycia pokładu samochodowego, z punktu widzenia wytrzymałości lokalnej ( $p = 13$ ), ma postać:

$$P_{13} = \begin{cases} e^{|t - t_{rule}|}, & \text{dla } t < t_{rule} \\ e^{(t_{rule} - t)^2}, & \text{dla } t \geq t_{rule} \end{cases} \quad (6.6)$$

gdzie:  $P_{13}$  – odpowiednia składowa funkcji kary,  $t$  – bieżąca wartość grubości płyty poszycia,  $t_{rule}$  – najmniejsza wymagana przepisami grubość płyty poszycia, określona na podstawie warunku wytrzymałości lokalnej.

Przyjęte formy składowych funkcji kar zapewniają unormowanie składowych funkcji kary do jedności oraz wprowadzają do poszukiwań miękką selekcję, z punktu widzenia czynnika opisywanego odpowiednim składnikiem kary  $P_p$ , w miejsce selekcji twardej:

$$P_{13} = \begin{cases} 0 & \text{dla } t < t_{rule} \\ 1 & \text{dla } t \geq t_{rule} \end{cases} \quad (6.7)$$

Selekcja twarda jest najprostszym rozwiązaniem procesu selekcji – rysunek 6.2 (a). W takim przypadku warianty niespełniające odpowiednich wymagań są szybko eliminowane z puli genowej, nawet przy bardzo korzystnych wartościach innych cech. Natomiast osobniki, które spełniają ograniczenia, są reprodukowane z prawdopodobieństwem niezależnym od stopnia przewyższania tych ograniczeń. Zróżnicowanie populacji jest w tym wypadku bardzo ograniczone, a sam proces poszukiwania prowadzi do ulepszania przypadkowo znalezionej ekstremum. Zazwyczaj nie jest to ekstremum globalne. Taki proces selekcji powoduje, że ewolucja jest silnie lokalna i że w jej trakcie istnieje niewielkie prawdopodobieństwo przekroczenia „barier” lub „wąwozów” w przestrzeni rozwiązań. Zdaniem autora korzystniejszym rozwiązaniem, z punktu widzenia efektywności algorytmu, jest wykorzystanie pojęcia miękkiej selekcji.

Na rysunku 6.2 (a) pokazano kształt składowej funkcji kary  $P_p$  w przypadku selekcji twardej i miękkiej na przykładzie grubości płyt poszycia. Warianty o rosnących, w stosunku do wymaganych przepisami, wartościach grubości płyt  $t - t_{rule} > 0$  (obszar II) mają odpowiednio mniejszą szansę na reprodukcję. Jednocześnie bardzo maleje szansa na reprodukcję wariantów o mniejszej, niż przepisowa, grubości płyt poszycia  $t - t_{rule} < 0$  (obszar I). Taka realizacja selekcji powoduje, że w reprodukcji uczestniczyć mogą również osobniki bardzo nieefektywne z punktu widzenia określonych kryteriów, ale o korzystnych cechach z punktu widzenia innych kryteriów. Cechy niekorzystne mogą zostać usunięte lub zamienione w operacjach mutacji i krzyżowania, a zmieniony wariant może wykazać cechy bardzo korzystne w przyszłych pokoleniach. Taka realizacja selekcji zwiększa możliwości przeszukiwania całej przestrzeni rozwiązań i umożliwia przekraczanie „barier” i „wąwozów” w wielomodalnej przestrzeni rozwiązań.


Na rysunku 6.2 (a) pokazano, że wartości grubości płyty  $t$ , mniejsze od wartości wymaganych przepisami  $t_{rule}$ , są zabronione, ponieważ nie spełniają odpowiedniego ograniczenia. Zatem wartości takie nie są preferowane (promowane, nagradzane) przez dobór naturalny. Osobniki z odpowiednim materiałem genetycznym będą „karane” małymi wartościami funkcji kary. Dobór naturalny będzie najbardziej promował osobniki o grubości płyty  $t$  nieco większej od wymaganej przepisami  $t_{rule}$ . Większe wartości grubości poszycia  $t$  będą preferowane w mniejszym stopniu, ponieważ nie ma potrzeby nadmiernego zwiększenia grubości płyt poszycia z punktu widzenia tego ograniczenia. Takie osobniki będą „karane” za zbyt duże dopuszczalne wartości grubości płyt  $t$ ; „karą” jest mała wartość odpowiedniej składowej funkcji kary<sup>2</sup>.

Zmiana wartości wykładników potęgowych  $r_p$  umożliwia modyfikowanie kształtu krzywych odpowiednich funkcji kary. Wartości wykładników potęgowych ustala się na podstawie doświadczenia zebranego podczas obliczeń testowych. Odpowiedni dobór wartości

---

<sup>2</sup> Ponieważ tak zdefiniowana funkcja kary premiuje lub nagradza dobre warianty, naturalne wydaje się mówienie o funkcji nagrody lub preferencji. Można wówczas mówić o premiowaniu, nagradzaniu lub preferowaniu dobrych wariantów. Pozostawiono jednak rozpowszechnioną w literaturze nazwę: funkcja kary.

indeksów potęgowych  $r_p$  powoduje, że operator reprodukcji jest narzędziem bardziej subtelnym i elastycznym. Zmiana wartości indeksów potęgowych pozwala na rozmycie lub zagęszczenie selekcji miękkiej – rysunek 6.2 (b). Odpowiednie rozmycie lub zagęszczanie selekcji jest bardzo silnym narzędziem kierującym symulowaną ewolucją.



Rys. 6.2. Ilustracja pojęć twardej i miękkiej selekcji (a), ilustracja koncepcji rozmycia i koncentracji miękkiej selekcji (b)

Dobór wartości współczynników wagowych  $w_p$  odbywa się także na podstawie doświadczenia użytkownika i podczas obliczeń próbnych. Istotność tego doboru osłabia jednak losowość składowych funkcji kary  $P(\mathbf{x})_p$ , co prowadzi w konsekwencji do losowych wartości iloczynów  $w_p P(\mathbf{x})_p$ .

Dobór konkretnej postaci składowej funkcji kary  $P(\mathbf{x})_p$ , współczynników wagowych  $w_p$  oraz wykładników potęgowych  $r_p$  dokonywany jest arbitralnie. Są to jednak bardzo ważne czynności, realizowane podczas budowy genetycznego modelu zadania optymalizacji konstrukcji; trudno przecenić ich znaczenie. Ponieważ funkcja przystosowania jest analogiem środowiska oddziałującego na populację, kieruje ewolucją osobników podczas symulacji. Błędne lub nie dość dokładne zbudowanie funkcji przystosowania pociąga za sobą ewoluowanie osobników w sposób daleki od oczekiwań. Znalezione rozwiązania mogą być odległe od optymalnych. Może nawet nie dojść do zbieżności algorytmu. Dostrajanie wartości in-

deksów potęgowych musi być bardzo staranne. Ten etap budowy modelu genetycznego wymaga od użytkownika dużego doświadczenia i wyczucia. Bardzo często potrzebne jest przeprowadzenie wielu symulacji próbnych, które mogą ułatwić dobór wartości wspomnianych parametrów.

Przyjęte formy składowych funkcji kar zapewniają wymagane unormowanie ich składowych funkcji kary do jedności oraz wprowadzają do poszukiwań miękką selekcję pod względem czynnika opisanego odpowiednim składnikiem kary. Doboru wartości parametrów poszczególnych składowych funkcji kary  $P(\mathbf{x})_p$  dokonuje się na podstawie obliczeń testowych, z uwzględnieniem pożądanej zbieżności algorytmu.

### 6.1.3. Wskaźnik dopuszczalności wariantu konstrukcji

Na przykładzie grubości płyty poszycia międzypokładu rozważymy problem, czy wariant o grubości płyty  $t = 12,00$  mm można uznać za dopuszczalny w przypadku, gdy wymagana przepisami grubość płyty  $t_{rule} = 12,03$  mm. Projektant może uznać, że wariant taki jest dopuszczalny i zaakceptuje go. Można się zastanowić, co zrobi projektant wówczas, gdy wymagana grubość płyty  $t_{rule} = 12,13$  mm. W tym wypadku może uznać, że płyta o grubości  $t = 12,00$  mm jest niedopuszczalna i że trzeba wybrać płytę o większej grubości. Na tym przykładzie widać, że projektanci nie stosują ostrego rozróżnienia pomiędzy wariantami dopuszczalnymi i niedopuszczalnymi. W pracy tej zwrócono na to uwagę w kontekście budowy narzędzia do automatycznego klasyfikowania generowanych wariantów na dopuszczalne lub niedopuszczalne. Rozwiązując problem dopuszczalności, wykorzystano pojęcia zaczerpnięte ze znanej teorii zbiorów rozmytych (Gutenbaum 1992, Yager i Filev 1995, Driankow i in. 1996, Jendo i Niczyj 1999, Piegat 1999, Łachwa 2001), uznając, że zbiór wariantów dopuszczalnych jest zbiorem rozmytym o stowarzyszonej z nim funkcji przynależności. Przyjęto funkcję przynależności w postaci (rysunek 6.3):

$$\mu(v_d) = \begin{cases} \mu = 0 & \text{dla } v_d < 2\Delta v_d \\ \mu = \frac{1}{2} \left[ 1 + \sin \left( \frac{\pi}{2\Delta v_d} (v_d - v_{d0}) + \frac{\pi}{2} \right) \right] & \text{dla } (v_{d0} - 2\Delta v_d) \leq v_d \leq v_{d0} \\ \mu = 1 & \text{dla } v_d > v_{d0} \end{cases} \quad (6.8)$$


gdzie:  $v_d$  – bieżąca wartość fizycznej cechy konstrukcji,  $v_{d0}$  – wymagana wartość tej cechy,  $v_d$ ,  $\Delta v_d$  – wartość cechy  $v_d$ , dla której wartość funkcji przynależności  $\mu$  równa się 0,5. Wartość parametru funkcji przynależności  $\Delta v_d$  określono arbitralnie dla każdego ograniczenia (wyłączając ograniczenia kostkowe).

Nie decydując się jeszcze na konsekwentne zastosowanie wnioskowania rozmytego, przyjęto, że wartość funkcji przynależności wariantu jest sumą wartości funkcji przynależności dla wszystkich ograniczeń.

Zaproponowane pojęcie dopuszczalności wariantu konstrukcji wprowadza rozmyte granice zbioru dopuszczalnego, a zatem wpływa na jego liczebność. Jest to istotne, ponieważ zbiór rozwiązań niezdominowanych przybliżających front ocen rozwiązań optymalnych Pareto jest przecież podzbiorem zbioru ocen rozwiązań dopuszczalnych. Zmiękczenie, rozmycie pojęcia dopuszczalności pozwala również na intensywniejszą eksplorację przestrzeni poszukiwań.



Po przeprowadzeniu obliczeń testowych przyjęto najmniejszą wartość wskaźnika dopuszczalności wariantów poddawanych ocenie  $\mu_{min} = 0,975$ .



Rys. 6.3. Funkcja przynależności  $\mu$  do zbioru rozmytego „wariant dopuszczalny” dla grubości płyt poszycia, przy założeniu wymaganej grubości płyty  $t_{rule} = 12,00$  mm,  $\Delta v_d = \Delta t = 1,00$  mm

#### 6.1.4. Operatory genetyczne

Opracowany na potrzeby pracy algorytm genetyczny tworzy warianty nowego pokolenia, realizując podstawowe operatory selekcji, mutacji i krzyżowania oraz, dodatkowo, operator aktualizacji i strategię pretendenta.

Goldberg (1989), Syswerda (1989), Bäck (1991, 1994, 1995, 1996), Goldberg i Deb (1991), De Jong (1995), Harik (1995), Neri i Saitta (1995), Michalewicz (1996) opisują operatory selekcji, które dokonują wyboru par chromosomów pod kątem wartości funkcji przystosowania. Osobniki cechujące się większą wartością funkcji przystosowania mają większą szansę uczestniczenia w symulowanym rozrodzie i przekazywania swoich genów kolejnym pokoleniom. Po analizie opisanych operatorów selekcji w pracy zastosowano operator selekcji proporcjonalnej, bazujący na koncepcji koła ruletki.

Goldberg (1989), Bäck (1996), Michalewicz (1996), Haupt i Haupt (1998), Gwiazda (2007 b) opisują różne warianty operatora mutacji, który wprowadza losowe zmiany chromosomu. W ten sposób umożliwia wniesienie nowej informacji do puli genetycznej populacji i zwiększa zróżnicowanie puli rodzicielskiej. Mutacja umożliwia eksplorację przestrzeni poszukiwań. W pracy zastosowano mutację bitową zmieniającą z ustalonym prawdopodobieństwem  $p_m$  wartości bitów w łańcuchach bitowych reprezentujących ewoluujące warianty rozwiązań.

Operator krzyżowania dokonuje wymiany odcinków chromosomów osobników rodzicielskich. Krzyżowanie umożliwia eksploatację lokalnego obszaru w przestrzeni poszukiwań. Po przeanalizowaniu operatorów, które opisują np. Goldberg (1989), Syswerda (1989), Goldberg i Deb (1991), Spears i De Jong (1991), Bäck (1996), Michalewicz (1996), Gwiazda (2007 a) zastosowano operator jednopunktowego krzyżowania. Przeprowadzone obliczenia testowe wykazały, że w przypadku długich chromosomów, przyjętych w pracy, operator jednopunktowego krzyżowania jest mało efektywny. Dla zwiększenia efektywności krzyżowania opracowano własny  $n_c$ -punktowy losowy operator krzyżowania. W tym wypadku parametrami operatora krzyżowania są najmniejsza  $n\_x\_site\_min$  i największa  $n\_x\_site\_max$

liczba punktów krzyżowania oraz prawdopodobieństwo krzyżowania  $p_c$ . Operator ustala automatycznie, niezależnie dla każdej krzyżowanej pary osobników, z prawdopodobieństwem  $p_c$ , liczbę punktów krzyżowania  $n\_x\_site$ , która jest zmienną losową o rozkładzie jednostajnym w zadanym przedziale  $[n\_x\_site\_min, n\_x\_site\_max]$ . Wykonane obliczenia testowe potwierdziły szybszą zbieżność algorytmu niż algorytmu realizującego jednopunktowe krzyżowanie. Jednocześnie ustalono, że zwiększenie największej liczby punktów krzyżowania  $n\_x\_site\_max$  powyżej siedmiu nie powoduje lepszej zbieżności algorytmu. Przyjęto więc najmniejszą  $n\_x\_site\_min = 1$  i największą  $n\_x\_site\_max = 7$  liczbę punktów krzyżowania.

Zwiększenie efektywności algorytmu osiągnięto, wprowadzając dodatkowo operator aktualizowania (ang. *updating*) oraz realizując koncepcję pretendentów (ang. *elitist strategy*).

Operator aktualizowania zaproponowali Stoffa i Sen (1991). Operator ten z ustalonym prawdopodobieństwem aktualizowania  $p_u$  wprowadza losowo wybranego osobnika z populacji rodzicielskiej do populacji potomnej w miejsce osobnika potomnego o słabszym przystosowaniu.

Losowy charakter operatorów selekcji, mutacji i krzyżowania może spowodować, że najlepiej przystosowane warianty z populacji rodzicielskiej nie zostaną wyselekcjonowane do krzyżowania, a nawet jeśli zostaną wyselekcjonowane, to mogą generować potomków o mniejszej wartości funkcji przystosowania. W ten sposób może zostać utracony bardzo korzystny zestaw genów. Strategia pretendenta łagodzi to potencjalne źródło utraty materiału genetycznego dzięki skopiowaniu ustalonej liczby najlepiej przystosowanych osobników rodzicielskich (bez zmian) do pokolenia potomnego. W większości przypadków strategia pretendenta zwiększa prędkość zdominowania populacji przez osobniki lepiej przystosowane, przyspieszając tym samym zbieżność algorytmu. Algorytm wybiera ustaloną  $n_p$  liczbę osobników rodzicielskich, o największych wartościach funkcji przystosowania, oraz równą liczbę osobników potomnych, o najmniejszych wartościach funkcji przystosowania. Wybrane osobniki potomne zostają zastąpione przez wybrane osobniki rodzicielskie.


### 6.1.5. Archiwizowanie rozwiązań niezdominowanych

W przypadku zadania optymalizacji wielokryterialnej rozważyć należy sposób gromadzenia i prezentowania informacji o odszukanych rozwiązaniach niezdominowanych. Powszechnie przyjęta jest prezentacja graficzna wszystkich (dopuszczalnych) rozwiązań w postaci punktów w przestrzeni ocen. Tylko niektóre z nich będą wariantami niezdominowanymi.

W opracowanym narzędziu obliczeniowym rozwiązania niezdominowane, wygenerowane w każdym kolejnym pokoleniu, zapisywane są w osobnym zbiorze, stale uzupełnianym i aktualizowanym w trakcie symulacji. Rozwiązania zgromadzone w zbiorze rozwiązań niezdominowanych można uwzględnić w procesie selekcji: (1) członkostwo w zbiorze nie ma wpływu na selekcję osobników (strategia egalitarna), (2) osobniki ze zbioru (rozwiązania niezdominowane) mają zagwarantowany udział w selekcji (strategia elitarna). Ze względu na prostotę w pracy zrealizowano strategię egalitarną.

Aktualizacja zewnętrznego zbioru rozwiązań niezdominowanych przebiega w dwóch krokach: (1) do dotychczasowego zbioru dopisywane są rozwiązania niezdominowane odszukane w bieżącym pokoleniu; utworzony zostaje zbiór tymczasowy, w którym część roz-

wiązań może być zdominowana; (2) ze zbioru tymczasowego usuwane są rozwiązania zdominowane i utworzony zostaje w ten sposób zbiór rozwiązań niezdominowanych kolejnego pokolenia (pokolenia potomnego). Podczas aktualizacji możliwe są następujące sytuacje (rysunek 6.4): (1) nowe rozwiązanie włączone do zbioru tymczasowego dominuje nad niektórymi rozwiązaniami, niezdominowanymi w dotychczasowym zbiorze, które są z niego usuwane, a nowe rozwiązanie jest do niego włączane, co oznacza, że jest włączane do archiwum; (2) nowe rozwiązanie włączone do zbioru tymczasowego jest zdominowane przez niektóre rozwiązania ze zbioru; zostaje więc z niego usunięte, co oznacza, że nie jest włączane do archiwum; (3) nowe rozwiązanie nie jest zdominowane przez którekolwiek z dotychczasowych rozwiązań i jest włączane do archiwum rozwiązań niezdominowanych.




Rys. 6.4. Ilustracja opracowanej procedury archiwizacji rozwiązań niezdominowanych

### 6.1.6. Odległość od rozwiązania asymptotycznego

W przypadku operowania wieloma kryteriami optymalizacji nie jest możliwe wskazanie jednego wariantu obiektywnie najlepszego, ponieważ taki nie istnieje<sup>3</sup>. W praktyce jednak użytkownicy oczekują automatycznego lub quazi-automatycznego wskazania jednego lub kilku wariantów, które mógłby przyjąć jako rozwiązanie zadania. Dodatkowo użytkownicy przyzwyczajeni są do śledzenia, w trakcie procesu optymalizacji, ewolucji jednej wielkości, co umożliwia im ocenę poprawności przebiegu obliczeń, zbieżności rozwiązań oraz jakości odszukiwanych wariantów, ułatwiających sterowanie procesem optymalizacji. W przypadkach jednokryterialnych naturalne jest śledzenie wartości funkcji przystosowania i kryterium optymalizacji. W przypadku optymalizacji wielokryterialnej jednoczesna ocena ewolucji kryteriów jest trudna do przeprowadzenia i interpretacji. Aby ułatwić to, autor wykorzystał znane z literatury (Cohon 1978, *Multiobjective Optimization in Engineering and in the Sciences* 1988, Deb 2001, Coello Coello i in. 2007, Tarnowski 2009) pojęcie rozwiązania idealnego (IS) – rysunek 6.5 (a).

<sup>3</sup> Oczywiście poza szczególnym, mało interesującym, przypadkiem, gdy zbiór rozwiązań niezdominowanych  $\Phi_{\succ}$  zawiera jedno rozwiązanie.



Rys. 6.5. Ilustracja pojęcia dopuszczalnego rozwiązania niezdominowanego najbliższego ocenie idealnej  $\mathbf{f}^*$  (a) oraz ilustracja koncepcji oceny (rozwiązania) asymptotycznej  $\mathbf{f}^0$  (b) w przypadku dwóch kryteriów typu min!


W powszechnym rozumieniu rozwiązanie idealne odpowiada najmniejszym, odszukanym w procesie optymalizacji, wartościom wszystkich kryteriów traktowanych osobno, a nie łącznie. Co znaczy, że jeśli  $f_1^*, f_2^*, \dots, f_s^*, \dots, f_s^*$  są odpowiednio najmniejszymi wartościami każdego kryterium optymalizacji, to idealne rozwiązanie (w przestrzeni ocen) określone jest jako wektor  $\mathbf{f}^* = [f_1^* \ f_2^* \ \dots \ f_s^* \ \dots \ f_s^*]^T$ . Ponieważ wektor  $\mathbf{f}^*$  minimalizuje jednocześnie wszystkie kryteria optymalizacji, w praktyce nie reprezentuje rozwiązania dopuszczalnego. W takim przypadku można jednak w każdym pokoleniu, inaczej mówiąc: w każdym zbiorze dopuszczalnym wygenerowanym w kolejnym  $m$  pokoleniu, wskazać rozwiązanie, którego ocena jest najbliższa ocenie idealnej:

$$f_m^{\approx}(\mathbf{x}) = [f_{1;m}^{\approx}(\mathbf{x}) \ \dots \ f_{s;m}^{\approx}(\mathbf{x}) \ \dots \ f_{s;m}^{\approx}(\mathbf{x})]^T \quad (6.9)$$

Określenie „najbliższe” należy rozumieć w sensie metryki Euklidesa, gdzie  $\mathbf{f}_m^{\approx}(\mathbf{x})$  jest najbliższym rozwiązaniem odszukanym w  $m$  pokoleniu.

Tak sformułowane pojęcie dopuszczalnego wariantu niezdominowanego najbliższego oceny idealnej  $\mathbf{f}_m^{\approx}(\mathbf{x})$  jest wystarczające do wskazania jednego rozwiązania, które przy braku innych przesłanek może być uznane za „najlepsze” rozwiązanie zadania optymalizacji wielokryterialnej. Nie jest jednak odpowiednie do śledzenia ewolucji rozwiązań niezdominowanych w kierunku teoretycznie najmniejszych wartości kryteriów optymalizacji  $f_s \rightarrow 0!$ , ponieważ przesuwanie zbioru ocen rozwiązań niezdominowanych w pożądanym kierunku może następować także przy niezmiennych się odległościach tych ocen od oceny rozwiązania idealnego (rysunek 6.6). W celu śledzenia ewolucji zbioru przybliżającego należy zatem przyjąć układ odniesienia, w którym ewolucja ta będzie widoczna nawet przy niezmiennych się odległościach od oceny idealnej. Autor wprowadził więc pojęcie oceny rozwiązania asymptotycznego  $\mathbf{f}^0$ , reprezentującego ocenę odpowiadającą asymptotycznym wartościom kryteriów optymalizacji:  $f_1 \rightarrow 0!, \dots, f_s \rightarrow 0!, \dots, f_s \rightarrow 0!, (f_1 \rightarrow 0! \ f_2 \rightarrow 0!)$  – rysunek 6.6:

**Definicja 6.1. Ocena asymptotyczna (ocena wariantu asymptotycznego, ocena rozwiązania asymptotycznego).** Jest to ocena, w kierunku której zmierzają generowane w trakcie symulowanej ewolucji oceny rozwiązań niezdominowanych, lecz oceny tej nigdy nie osiągną; ocena odpowiadająca asymptotycznym wartościom kryteriów optymalizacji; niezmiennik procesu optymalizacji. ■



Rys. 6.6. Ilustracja przemieszczania się rozwiązań najbliższych rozwiązaniu idealnemu  $f^*$  w kierunku rozwiązania asymptotycznego  $f^0$  w trakcie ewolucji w przypadku kryteriów typu min!

Przy takim zdefiniowaniu oceny rozwiązania asymptotycznego można (1) określić odległość oceny każdego rozwiązania niezdominowanego od tego rozwiązania i wybrać rozwiązanie dla niego najbliższe oraz dodatkowo (2) śledzić w trakcie symulacji ewolucję odległości ocen rozwiązań niezdominowanych formujących zbiór przybliżający od oceny tego rozwiązania. Po zdefiniowaniu oceny asymptotycznej  $f^0$  przyjęto, że rozwiązanie najbliższe  $\tilde{f}(x)$  oznacza rozwiązanie najbliższe rozwiązaniu asymptotycznego  $f^0$ , a nie rozwiązaniu idealnego  $f^*$ . Zatem za szczególne rozwiązanie niezdominowane uznano rozwiązanie najbliższe oceny asymptotycznej  $\tilde{f}_m(x)$ ; odległość oceny tego rozwiązania od oceny rozwiązania asymptotycznego będzie śledzona w trakcie symulacji. Odległość ta będzie także utożsamiana z odległością zbioru przybliżającego  $\Psi_f$  od oceny rozwiązania asymptotycznego.

### 6.1.7. Szeregowanie i licznik dominacji

W podrozdziale 3.2. stwierdzono, że relacja dominacji Pareto pozwala jedynie z grubsza zróżnicować rozwiązania dopuszczalne pod względem dominacji w sensie Pareto

(rysunek 3.2). Nie dostarcza zwłaszcza informacji o liczbie rozwiązań zdominowanych przez poszczególne rozwiązania, a zatem informacji o wewnętrznej strukturze zbioru rozwiązań dopuszczalnych  $\Phi_f$ . Oznacza to, że nie rozróżnia wariantów położonych w obszarach o różnym nasyceniu rozwiązaniami dopuszczalnymi (rysunek 4.3).


W celu zwiększenia możliwości diagnostycznych autor zaproponował schemat postępowania, w którym rozwiązania klasyfikowane są pod względem liczby rozwiązań (które są przez nie zdominowane) odniesionej do liczby rozwiązań dopuszczalnych.

**Definicja 6.2. Wskaźnik szeregowania (szeregowanie, ranga, ang. rank).** Jest to określona dla każdego wariantu dopuszczalnego wielkość o wartości równej ilorazowi liczby rozwiązań zdominowanych przez ten wariant i liczby wszystkich wariantów dopuszczalnych:

$$R_{fi}(i) = \frac{\sum_{j=1, j \neq i}^{N_{fi}} dm(i, j)}{N_{fi}} \quad (6.10)$$

gdzie:  $dm(i, j) = 1$ , gdy  $i$  dominuje nad  $j$ , oraz  $dm(i, j) = 0$  w pozostałych przypadkach,  $i, j$  – wskaźniki sprawdzanych rozwiązań dopuszczalnych. ■

Koncepcję wskaźnika szeregowania zilustrowano na rysunkach 6.7 (a) i 6.8. Zaletami zaproponowanej strategii są: (1) łatwość obliczeń, (2) unormowanie wartości wskaźnika szeregowania do przedziału  $[0, 1]$  oraz (3) wzrost wartości wskaźnika szeregowania w przypadku wariantów zbliżających się do zbioru przybliżającego  $\Psi_f$  (leżących na brzegu zbioru dopuszczalnego). Ponadto dzięki właściwościom (2) i (3) wartość wskaźnika szeregowania, obliczana w zaproponowany sposób, może być bezpośrednio włączona do funkcji przystosowania. W takim przypadku selekcja promować będzie rozwiązania dopuszczalne leżące blisko zbioru przybliżającego, natomiast rozwiązania oddalające się stopniowo od tego zbioru promowane będą coraz słabiej, co jest numeryczną realizacją nacisku selekcyjnego na warianty leżące blisko zbioru przybliżającego  $\Psi_f$  zwiększającego właściwości eksploatacyjne algorytmu. Wadą zaproponowanej strategii jest złożoność obliczeniowa  $N_{fi}^2$ .



Rys. 6.7. Ilustracja zaproponowanych strategii wyznaczania: (a) wskaźnika szeregowania rozwiązań zależnego bezpośrednio od liczby rozwiązań zdominowanych przez wybrane rozwiązanie, (b) licznika dominacji zależnego bezpośrednio od liczby rozwiązań dominujących nad wybranym rozwiązaniem


W podobny sposób można klasyfikować rozwiązania dopuszczalne pod względem liczby rozwiązań, które dominują nad nimi, odniesionej do liczby rozwiązań dopuszczalnych.

**Definicja 6.3. Licznik dominacji (ang. *count*).** Jest to określona dla każdego wariantu dopuszczalnego wielkość o wartości równej ilorazowi liczby rozwiązań dominujących nad tym wariantem i liczby wszystkich wariantów dopuszczalnych:

$$C_{fi}(i) = \frac{\sum_{j=1, j \neq i}^{N_{fi}} dm(j, i)}{N_{fi}} \quad (6.11)$$

gdzie:  $dm(j, i) = 1$ , gdy  $j$  dominuje nad  $i$  oraz  $dm(j, i) = 0$  w pozostałych przypadkach,  $i, j$  – wskaźniki sprawdzanych rozwiązań dopuszczalnych. ■

Koncepcję licznika dominacji zilustrowano na rysunkach 6.7 (b) i 6.8. Tak określony licznik dominacji charakteryzuje się wymienionymi wyżej właściwościami (1) i (2), oraz (3) wzrostem wartości licznika dominacji w przypadku wariantów oddalających się od zbioru przybliżającego  $\Psi_f$  (leżących w zbiorze dopuszczalnym). Dzięki właściwościom (2) i (3) wartość licznika dominacji, obliczana w zaproponowany sposób, może być bezpośrednio włączona do funkcji przystosowania; w procesie selekcji promowane będą wówczas rozwiązania dopuszczalne leżące w obszarach odległych od zbioru przybliżającego  $\Psi_f$ , natomiast rozwiązania zbliżające się do tego zbioru promowane będą coraz słabiej, co jest numeryczną realizacją nacisku selekcyjnego na warianty odległe od zbioru przybliżającego  $\Psi_f$ , zwiększającego właściwości eksploracyjne algorytmu. Podobnie jak w poprzednim przypadku wadą zaproponowanej strategii jest złożoność obliczeniowa  $N_{fi}^2$ .



Rys. 6.8. Ilustracja różnic we wnioskowaniu za pomocą wskaźnika szeregowania (a) oraz licznika dominacji (b) rozwiązań dopuszczalnych; kwadraty oznaczają oceny rozwiązań niezdominowanych należące do zbioru przybliżającego  $\Psi_f$ ; okręgi i koła oznaczają oceny zdominowanych rozwiązań dopuszczalnych

### 6.1.8. Kombinowana funkcja przystosowania

Jak to wspomniano, zaproponowane przez autora strategie szeregowania wariantów dopuszczalnych, licznika dominacji oraz odległości od rozwiązania asymptotycznego umożliwiają

ich bezpośrednie włączenie do sformułowanej wyżej (zobacz podrozdział 6.1.2), zależności (6.5), opisującej rozszerzoną funkcję celu zadania maksymalizacji z ograniczeniami:

$$f(\mathbf{x}) = F(\mathbf{x}) + w_{rank}R_{fi}(\mathbf{x}) + w_{count}C_{fi}(\mathbf{x}) + w_{distance}d_{fi}(\mathbf{x})$$

(6.12)

*kombinowana funkcja celu = funkcja celu z ograniczeniami +  
+ szeregowanie + licznik dominacji + odległość od rozwiązania asymptotycznego*

gdzie:  $F(\mathbf{x})$  – funkcja celu w zadaniu z ograniczeniami (6.5). Nadanie wartości zero odpowiedniemu współczynnikowi wagowemu  $w_{rank}$ ,  $w_{count}$  lub  $w_{distance}$  pozwala użytkownikowi na wyłączenie odpowiedniej składowej kombinowanej funkcji celu.

Uwzględniając (1) ujęte w zależności (6.5) składowe funkcji kary za naruszenie ograniczeń, (2) wymaganie, aby opracowane narzędzie obliczeniowe promowało rozwiązania leżące blisko rozwiązania asymptotycznego<sup>4</sup> oraz (3) odpowiednie właściwości matematyczne składowych kombinowanej funkcji celu, można ją potraktować jako kombinowaną funkcję przystosowania  $F_j$   $j$ -tego osobnika w populacji wygenerowanych wariantów:

$$\begin{aligned} F_j = F(\mathbf{x}_j) &= \\ &= \sum_{s=1}^S w_s u_s(\mathbf{x}_j) + w_{rank}R_{fi}(\mathbf{x}_j) + w_{count}C_{fi}(\mathbf{x}_j) + w_{distance}[1 - d_{fi}(\mathbf{x}_j)] + \sum_{p=1}^P w_p P(\mathbf{x}_j)_p^p = \\ &= w_1 u_1(\mathbf{x}_j) + \dots + w_s u_s(\mathbf{x}_j) + \dots + w_S u_S(\mathbf{x}_j) + w_{rank}R_{fi}(\mathbf{x}_j) + w_{count}C_{fi}(\mathbf{x}_j) + \\ &+ w_{distance}[1 - d_{fi}(\mathbf{x}_j)] + \sum_{p=1}^P w_p P(\mathbf{x}_j)_p^p \rightarrow \max! \end{aligned} \quad (6.13)$$

$$\begin{aligned} \text{kombinowana funkcja przystosowania} &= \\ &= \text{kryteria optymalizacji} + \text{szeregowanie} + \text{licznik dominacji} + \\ &+ \text{odległość od rozwiązania asymptotycznego} + \text{ograniczenia} \end{aligned}$$

Taka właśnie postać kombinowanej funkcji przystosowania została zrealizowana w zaproponowanej przez autora strategii ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku.

W zaproponowanej postaci kombinowana funkcja przystosowania zawiera instrumenty, które zdaniem autora umożliwiają skuteczne rozwiązanie wielokryterialnego zadania optymalizacji KKSM z ograniczeniami. Są to: *przystosowanie = kryteria + szeregowanie + licznik dominacji + odległość + ograniczenia*, gdzie *kryteria* reprezentują nacisk selekcyjny w kierunku pożądanych wartości kryteriów optymalizacji; *szeregowanie* oraz *licznik dominacji* reprezentują nacisk selekcyjny związany z położeniem wariantu dopuszczalnego w odniesieniu do frontu ocen rozwiązań niezdominowanych oraz ocen innych rozwiązań w zbiorze dopuszczalnym, mierzonym odpowiednimi atrybutami dominacji; *odległość* reprezentuje nacisk selekcyjny związany z odległością oceny rozwiązania dopuszczalnego od oceny rozwiązania asymptotycznego; *ograniczenia* reprezentuje zmniejszenie jakości rozwiązania i związane z tym zmniejszenie prawdopodobieństwa selekcji spowodowane naruszeniem ograniczeń. Ponieważ wartości wskaźnika szeregowania, licznika dominacji oraz odległości od rozwiązania asymptotycznego obliczane są tylko dla wariantów dopuszczalnych, oznacza to również dodatkowe promowanie takich wariantów. Odpowiednie wykorzystanie proponowanych składowych funkcji przystosowania umożli-

---

<sup>4</sup> Oczywiście jest to subiektywne oczekiwanie autora; optymalizację można prowadzić bez tak jawnie sformułowanego wymagania zbieżności z rozwiązaniem asymptotycznym.



wia bardzo elastyczne i efektywne rozwiązywanie zadań optymalizacji wielokryterialnej z wykorzystaniem algorytmu genetycznego.

Dominacja w funkcji przystosowania składowej *szeregowanie* (ang. *rank*) służy promowaniu wariantów należących do zbioru przybliżającego lub znajdujących się w pobliżu, zwiększając ich szansę na udział w reprodukcji i przekazanie cech większej liczbie osobników potomnych, zwiększa więc właściwości eksploatacji obszarów przestrzeni rozwiązań zawierających korzystne rozwiązania. Warianty odległe od zbioru przybliżającego mają mniejsze szanse na reprodukcję. Taka strategia umacnia istniejący skład zbioru przybliżającego, nie sprzyja jednak zasilaniu go wariantami o nowych potencjalnie korzystnych cechach. Jest to więc strategia reprezentująca dominację eksploatacji obszaru zawierającego warianty niezdominowane nad eksploracją przestrzeni rozwiązań.

Dominacja składowej *licznik dominacji* (ang. *count*) przeciwnie – zmniejsza prawdopodobieństwo reprodukcji wariantów należących do zbioru przybliżającego (zastosowanie strategii elitarnych może osłabić ten efekt), zwiększa jednak szansę reprodukcji wariantów z obszarów odległych od tego zbioru, stwarzając szansę zasilenia zbioru przybliżającego wariantami o nowych pożądanach właściwościach. Strategia ta reprezentuje więc dominację eksploracji przestrzeni rozwiązań nad eksploatacją już odszukanych obszarów, zawierających warianty o pożądanach cechach. Wybór strategii zależy od konkretnego zadania i powinien być poprzedzony obliczeniami testowymi. Autor proponuje zastosować dominację *licznika dominacji* w przypadku, gdy liczba wariantów generowanych w trakcie symulacji jest niewielkim ułamkiem liczby wszystkich wariantów możliwych do wygenerowania w danym modelu optymalizacyjnym, przy czym wymagania dotyczące dokładności odszukania rozwiązania kompromisowego nie są wygórowane. W takim przypadku intensywna eksploracja przestrzeni rozwiązań zwiększa szansę odszukania zadowalającego rozwiązania. Gdy jednak użytkownikowi zależy na dużej dokładności znalezionej rozwiązania niezdominowanego przybliżającego front Pareto, zalecić można realizację dominacji *szeregowania*.

W zaproponowanym algorytmie odszukane warianty niezdominowane zapisywane są w zewnętrznym zbiorze, aktualizowanym w każdym pokoleniu. Warianty te jednak nie mają zapewnionego udziału w dalszej selekcji, chyba że są jednocześnie członkami bieżącego pokolenia, w ramach którego dokonuje się selekcji. Nie zrealizowano więc strategii elitarnej zapewniającej bezwzględne przetrwanie wszystkim odszukanym dotychczas wariantom niezdominowanym. Oczywiście zrealizowanie takiej strategii nie jest trudne.

#### 6.1.9. Szerokość i głębokość zbioru przybliżającego

Do śledzenia i oceny ewolucji zbiorów przybliżających, a także do oceny jakości zbiorów przybliżających zaproponowano dodatkowo dwie wielkości – szerokość zbioru przybliżającego<sup>5</sup> oraz głębokość zbioru przybliżającego (rysunek 6.9):

**Definicja 6.4. Szerokość zbioru przybliżającego.** Jest to kątowa rozpiętość zbioru przybliżającego, mierzona w unormowanej przestrzeni ocen największą wartością kąta  $\beta$

---

<sup>5</sup> Paczkowski (1999) zaproponował niezależne od autora zastosowanie zdefiniowanego w podobny sposób kąta kooperacji kryteriów optymalizacji do mierzenia przeciwstawności funkcji celu.


między wektorami wodzącymi ocen rozwiązań należących do tego zbioru (wartością kąta pomiędzy ocenami rozwiązań leżących na przeciwnych krańcach zbioru przybliżającego). ■

**Definicja 6.5. Głębokość zbioru przybliżającego.** Jest to wyznaczana w unormowanej przestrzeni ocen różnica  $d_{AS}$  pomiędzy największą i najmniejszą odległością ocen rozwiązań niezdominowanych od oceny asymptotycznej. ■

Duże wartości szerokości i głębokości zbioru przybliżającego świadczą o zróżnicowaniu rozwiązań w zbiorze i przewadze eksploracji przestrzeni rozwiązań nad eksploatacją obszarów zapewniających korzystne wartości kryteriów oceny.

Zmniejszanie szerokości i głębokości zbiorów przybliżających świadczy z kolei o zmniejszaniu się roli eksploracji i skupianiu się rozwiązań w obszarach zapewniających korzystne wartości kryteriów. Ułatwia to decyzję o wyborze jednego rozwiązania zadania, jeśli jednak następuje ona zbyt szybko, trudno znaleźć wszystkie korzystne warianty.

Zwróćmy uwagę, że „klasycznie” zdefiniowane pojęcie punktu idealnego  $f^*$  oznacza, że szerokość zbioru przybliżającego jest stała ( $\beta = 90^\circ$ ), nie zmienia się zatem w toku symulacji (rysunek 6.9).



Rys. 6.9. Ilustracja koncepcji: odległości od oceny asymptotycznej  $r$ , szerokości zbioru przybliżającego  $\beta$  oraz głębokości zbioru przybliżającego  $d_{AS}$ ; linią przerywaną zaznaczono „klasyczne” określenie oceny idealnej

### 6.1.10. Ocena jakości zbiorów przybliżających

Przypomnijmy, że w przypadku zadań optymalizacji wielokryterialnej nie sformułowano dotychczas bezpośrednich ścisłych metod oceny uzyskanych rozwiązań, czyli zbiorów  $\Psi_f$  ocen rozwiązań niezdominowanych przybliżających front ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Ponieważ w pracy tej zaproponowano ewolucyjny algorytm optymalizacji wielokryterialnej, umożliwiający, dzięki zaproponowanej postaci kombinowanej funkcji przystosowania, wybór kilku strategii selekcji wariantów, należy opracować narzędzia potrzebne do oceny, jak dobre są uzyskane rozwiązania sformułowanego zadania wielokryterialnej optymalizacji KKSM. Związane z tym trudności szczegółowo omówiono w rozdziale 5.

W pracy tej zaproponowano metodę ilościowej oceny jakości zbioru przybliżającego  $\Psi_f$ , w której jakość każdego zbioru opisywana jest wektorem liczb rzeczywistych odpowiadających różnym aspektom jakości tego zbioru.

W rozdziale 5 stwierdzono, że najbardziej naturalnym sposobem porównywania dwóch zbiorów przybliżających  $\Psi_A$  i  $\Psi_B$ , wygenerowanych przez dwa różne optymalizatory wielokryterialne, jest wykorzystanie struktury preferencji leżącej u jej podstaw. W pracy przyjęto, że strukturę tę określa dwuwartościowa relacja słabej dominacji Pareto. Istnieje jednak potrzeba bardziej precyzyjnego sformułowania jakości rozwiązań w postaci ilościowej na ciągłej skali wartości. W związku z tym zaproponować trzeba ilościowe miary jakości zbiorów przybliżających. W rozdziale 5 zdefiniowano skalarne  $QI: \Psi_f \rightarrow \mathbb{R}$  i wektorowe **QI**:  $\Psi_f \rightarrow \mathbb{R}^Q$  wskaźniki jakości jako użyteczne narzędzia do ilościowej oceny jakości zbiorów przybliżających.

Dysponując sformułowanymi wskaźnikami jakości, można przeprowadzić wnioskowanie według przedstawionej w tabelicy 6.1 procedury. Na przykład, jeśli przyjmiemy skalarne wskaźnik jakości  $QI_N$  równy liczbie ocen w zbiorze przybliżającym  $\Psi_f$ , taki, że większa wartość wskaźnika jest bardziej preferowana, to dla zbiorów przybliżających przedstawionych w tabelicy 6.1 otrzymamy  $QI_N(\Psi_A) = 11$  i  $QI_N(\Psi_B) = 14$ , czyli  $QI_N(\Psi_B) > QI_N(\Psi_A)$ ; zatem mamy podstawy, aby stwierdzić, że zbiór  $\Psi_B$  przybliżający front ocen rozwiązań optymalnych Pareto  $\Psi_P$  jest lepszy od zbioru  $\Psi_A$ , jeśli liczba ocen rozwiązań w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta:


$$QI_N(\Psi_B) > QI_N(\Psi_A) \Rightarrow \uparrow QI_N \Rightarrow \Psi_B \blacktriangleright \Psi_A$$

Czyli: ponieważ liczba ocen w zbiorze  $\Psi_B$  przybliżającym front ocen rozwiązań optymalnych Pareto  $QI_N(\Psi_B)$  jest większa od liczby ocen  $QI_N(\Psi_A)$  w zbiorze  $\Psi_A$  i ponieważ liczba ocen w zbiorze przybliżającym  $QI_N$  odzwierciedla preferencje decydenta w taki sposób, że większe wartości  $QI_N$  są bardziej preferowane, mamy podstawy do tego, aby stwierdzić, że zbiór  $\Psi_B$  przybliżający front optymalny Pareto jest lepszy od zbioru  $\Psi_A$ . Uogólniając ten wniosek na algorytmy optymalizacyjne, mamy podstawy, aby stwierdzić, że algorytm optymalizacji wielokryterialnej, który wygenerował zbiór przybliżający  $\Psi_B$  jest skuteczniejszy od algorytmu, który wygenerował zbiór  $\Psi_A$ , jeśli wskaźnik jakości równy liczbie ocen w uzyskanych zbiorach przybliżających odzwierciedla preferencje decydenta dotyczące skuteczności algorytmów optymalizacyjnych.

W pracy do oceny zbiorów przybliżających  $\Psi_f$  zastosowano jednak nie pojedyncze wskaźniki jakości, a kombinację różnych wskaźników mierzących różne cechy zbiorów przybliżających. Są to: liczność zbioru przybliżającego, odległość zbioru od oceny asymptotycznej, rozpiętość i głębokość zbioru przybliżającego, objętość zdominowanej przestrzeni ocen, które można traktować jak składowe wektorowego wskaźnika jakości **QI**:

$$\mathbf{QI} = [(liczność\ zbioru) \ (odległość\ zbioru\ do\ oceny\ asymptotycznej) \ (rozpiętość\ zbioru) \ (głębokość\ zbioru) \ (objętość\ zdominowanej\ części\ przestrzeni\ ocen)]^T$$

Tablica 6.1. Schemat wnioskowania o jakości zbiorów przybliżających  $\Psi_f$  na podstawie wektorowych wskaźników jakości  $\mathbf{QI}$  reprezentujących dodatkowe, nieuwjęte w algorytmie optymalizacyjnym, preferencje decydenta; wartości składowych wskaźników jakości  $QI_q$ ,  $q = 1, 2, \dots, 5$  założono arbitralnie na potrzeby schematu



W ten sposób wprowadzone wyżej pojęcia: liczności zbioru przybliżającego, odległości od oceny rozwiązania asymptotycznego, szerokości zbioru przybliżającego, głębokości zbioru przybliżającego, wielkości zdominowanej części przestrzeni ocen mogą być podstawą oceny jakości wygenerowanych zbiorów przybliżających. Mogą być zatem skalar-  
nymi wskaźnikami jakości  $QI_q$  zbiorów przybliżających  $\Psi_f$ .

– odległość zbioru przybliżającego od oceny rozwiązania asymptotycznego

$$q = 1 \Rightarrow QI_1 = QI_{AD}: QI_{AD}(\Psi_A) < QI_{AD}(\Psi_B) \Rightarrow \downarrow QI_{AD} \Rightarrow \Psi_A \blacktriangleright \Psi_B \quad (6.14)$$

– szerokość zbioru przybliżającego

$$q = 2 \Rightarrow QI_2 = QI_B: QI_B(\Psi_A) > QI_B(\Psi_B) \Rightarrow \uparrow QI_B \Rightarrow \Psi_A \blacktriangleright \Psi_B \quad (6.15)$$

– głębokość zbioru przybliżającego

$$q = 3 \Rightarrow QI_3 = QI_D: QI_D(\Psi_A) > QI_D(\Psi_B) \Rightarrow \uparrow QI_D \Rightarrow \Psi_A \blacktriangleright \Psi_B \quad (6.16)$$

– wielkość zdominowanej części przestrzeni ocen

$$q = 4 \Rightarrow QI_4 = QI_H: QI_H(\Psi_A) > QI_H(\Psi_B) \Rightarrow \uparrow QI_H \Rightarrow \Psi_A \blacktriangleright \Psi_B \quad (6.17)$$

– udział (względny wkład) wyników z danej symulacji w agregowanym zbiorze przybliżeń

$$q = 5 \Rightarrow QI_5 = QI_{NF}: QI_{NF}(\Psi_A) > QI_{NF}(\Psi_B) \Rightarrow \uparrow QI_{NF} \Rightarrow \Psi_A \blacktriangleright \Psi_B \quad (6.18)$$

Wskaźniki te można traktować jako składowe pięciowymiarowego wektorowego wskaźnika jakości **QI** zbiorów przybliżających  $\Psi_f$ :

$$\begin{aligned} \mathbf{QI}(\Psi_f) &= [QI_1(\Psi_f) \quad QI_2(\Psi_f) \quad QI_3(\Psi_f) \quad QI_4(\Psi_f) \quad QI_5(\Psi_f)]^T = \\ &= [QI_{AD}(\Psi_f) \quad QI_B(\Psi_f) \quad QI_D(\Psi_f) \quad QI_H(\Psi_f) \quad QI_{NF}(\Psi_f)]^T \end{aligned} \quad (6.19)$$

W pracy przyjęto, że wygenerowane zbiory przybliżające  $\Psi_f$  oceniane będą trzema metodami oceny jakości rezultatów ewolucyjnych algorytmów optymalizacji wielokryterialnej: (1) metodą oceny wizualnej (*VAM*), (2) metodą relacji dominacji (*DRM*), (3) metodą wskaźników jakości (*QIM*). Metody te przedyskutowano szczegółowo w rozdziale 5. Ze względu na brak praktycznych możliwości wygenerowania, dzięki realizacji różnych strategii selekcji, istotnych statystycznie prób rozwiązania zadania optymalizacji KKS, metody statystyczne zostaną pominięte.

## 6.2. Program komputerowy


Z oczywistych względów algorytmy genetyczne nie nadają się do obliczeń wykonywanych ręcznie, w związku z czym ich przydatność do rozwiązywania zadań optymalizacyjnych, unifikujących optymalizację topologii i optymalizację wymiarów elementów konstrukcyjnych kadłuba statków morskich, została zweryfikowana na drodze symulacji komputerowych za pomocą autorskiego programu komputerowego. Program ten zbudowano na podstawie prostego algorytmu genetycznego, opisanego w wielu publikacjach (Goldberg 1989, Davis 1991, Cytowski 1996, Michalewicz 1996, Mitchell 1996, autorzy publikacji *Handbook of Evolutionary Computation* 1997, Gen i Cheng 1997, Coley 1999, Man i in. 1999, Bäck i in. 2000 a, b, Arabas 2001, Wierchoń 2001, Grzymkowski i in. 2008), uzupełniając go wieloma oryginalnymi procedurami obliczeniowymi umożliwiającymi wielokryterialną opty-

malizację KKSM z wykorzystaniem specjalnie opracowanych technik obliczeniowych omówionych w podrozdziale 6.1. Najważniejsze z nich to procedury: (1) odkodowywania chromosomów i obliczania rzeczywistych wartości zmiennych konstrukcyjnych (odpowiada to transformacji z przestrzeni genotypu do przestrzeni rozwiązań – przestrzeni zmiennych decyzyjnych); (2) budowy wariantów konstrukcji kadłuba statku na podstawie wartości zmiennych konstrukcyjnych; (3) analizy zbudowanych wariantów pod kątem spełnienia nałożonych ograniczeń, przede wszystkim analizy wytrzymałości konstrukcji na podstawie przepisów towarzystw klasyfikacyjnych; (4) obliczeń charakterystyk projektowych generowanych wariantów oraz kryteriów optymalizacji; (5) badania zbioru dopuszczalnego  $\Phi_f$  z obliczeniem wskaźnika szeregowania, licznika dominacji, odległości od oceny rozwiązania asymptotycznego, szerokości i głębokości zbioru przybliżającego  $\Psi_f$ ; (6) obliczeń wartości kombinowanej funkcji przystosowania. Schemat koncepcyjny opracowanego programu komputerowego w postaci schematu blokowego przedstawiono na rysunku 6.10.

Program realizuje obliczenia automatycznie na podstawie przygotowanych przez użytkownika zbiorów danych wejściowych, zawierających informacje o przyjętym do optymalizacji modelu KKSM, strukturze chromosomu oraz wartościach parametrów sterujących. Aktualizowany w każdym pokoleniu zbiór wariantów niezdominowanych stanowi przybliżenie frontu ocen rozwiązań optymalnych Pareto. Na końcu obliczana jest wartość funkcji przystosowania proporcjonalna do prawdopodobieństwa selekcji wariantu i udziału w operacjach genetycznych następnego pokolenia. Dzięki wprowadzeniu kombinowanej funkcji przystosowania podczas obliczania jej wartości stosuje się wybraną przez użytkownika strategię uwzględniającą w procesie selekcji kryteria optymalizacji, atrybuty dominacji i odległość od rozwiązania asymptotycznego.

Podstawowe informacje o generowanych wariantach konstrukcji, m.in. wartości zmiennych konstrukcyjnych, wartości funkcji przystosowania, wartości kryteriów optymalizacji, wartości atrybutów dominacji, odległości od rozwiązania asymptotycznego, zapisywane są w zewnętrznym zbiorze tekstowym. W osobnym zbiorze zapisywane są także charakterystyki populacji generowanych rozwiązań, m.in. największa wartość funkcji przystosowania, średnia w populacji wartość funkcji przystosowania, najmniejsza wartość funkcji przystosowania, najmniejsza odległość od rozwiązania asymptotycznego, szerokość zbioru przybliżającego, głębokość zbioru przybliżającego.

Zbudowany program komputerowy umożliwia zrealizowanie czterech strategii selekcji omówionych w podrozdziale 4.3 i przedstawionych na rysunku 4.2; są to strategie selekcji pod względem: (1) zastępczej skalarnej funkcji celu z ustalonymi wartościami współczynników wagowych częściowych kryteriów optymalizacji – rysunek 4.2 (a), (2) zastępczej skalarnej funkcji celu z losowymi wartościami współczynników wagowych częściowych kryteriów optymalizacji – rysunek 4.2 (b), (3) losowo wybranych pojedynczych kryteriów optymalizacji – rysunek 4.2 (c), (4) atrybutów dominacji (wskaźnika szeregowania lub licznika dominacji) – rysunek 4.2 (d). Dodatkowo możliwe jest zrealizowanie (5) selekcji pod względem odległości od oceny rozwiązania asymptotycznego oraz (6) selekcji pod względem pełnej kombinowanej funkcji przystosowania CFMOEA – zależność (6.13). Wybór odpowiedniej strategii selekcji odbywa się poprzez przyjęcie wartości odpowiednich współczynników wagowych ( $w_s$ ,  $w_{rank}$ ,  $w_{count}$  i  $w_{distance}$ ) składowych kombinowanej funkcji przystosowania  $F$  – zależność (6.13).



Rys. 6.10. Schemat koncepcyjny oparty na algorytmie genetycznym programu komputerowego do wielokryterialnej optymalizacji konstrukcji kadłuba statków morskich z kombinowaną funkcją przystosowania

Program przeprowadza analizę wariantów dopuszczalnych populacji potomnych, wybierając warianty niezdominowane i budując w ten sposób archiwum wariantów niezdominowanych. Archiwum to jest zbiorem zewnętrznym; warianty, które są w nim zapisane, nie biorą udziału w „hodowli” wariantów kolejnych pokoleń, chyba że zdołały przetrwać „w sposób naturalny” w kolejnych populacjach niezniszczone lub wykluczone przez operatory genetyczne. Proces generowania i oceny potomnych populacji wariantów próbnych oraz aktualizacji archiwum wariantów niezdominowanych powtarzany jest aż do momentu, gdy zostanie osiągnięta ustalona liczba pokoleń, stanowiąca warunek zakończenia symulacji<sup>6</sup>. Po zakończeniu symulacji wygenerowany zbiór rozwiązań niezdominowanych  $\Psi_f$ , przybliżający front ocen rozwiązań optymalnych Pareto, zostaje uznany za poszukiwane rozwiązanie zadania optymalizacji wielokryterialnej – zbiór przybliżający  $\Psi_{\text{symi}}$  wygenerowany w trakcie symulacji symi. Jako pojedynczy wariant, stanowiący rozwiązanie sformułowanego zadania, można uznać także wariant niezdominowany najbliższy rozwiązaniu asymptotycznemu  $f_{\text{symi}}^{\approx}$ .

Wartości parametrów sterujących operatorami genetycznymi ustalane są przez użytkownika przed rozpoczęciem symulacji. Odpowiednie ustalenie tych wartości jest bardzo ważne i wymaga znacznego doświadczenia; jest jednak decydujące dla osiągnięcia oczekiwanej zbieżności obliczeń, wyrażonej w: (1) jakości odnajdywanych rozwiązań, (2) szybkości ich odnajdywania oraz (3) ponoszonych nakładach obliczeniowych.

### 6.3. Obliczenia testowe (próbne)

W przypadku algorytmów ewolucyjnych, wykorzystujących procesy losowe do generowania kolejnych populacji wariantów, nie opracowano dotychczas uznanych kryteriów zbieżności. Nie opracowano również analitycznych metod analizy wrażliwości algorytmów na zmiany parametrów modelu optymalizacyjnego i parametrów sterujących symulacjami komputerowymi. Istotny jest fakt, że parametrów tych nawet w niewielkim zadaniu może być kilkadziesiąt, a w przypadku większych zadań – nawet kilkaset. Interpretację wyników symulacji komputerowych utrudnia także fakt, że algorytmy są losowe, a zatem przebieg i uzyskane wyniki nie są powtarzalne. Nawet niewielka zmiana wartości któregośkolwiek z parametrów modelu optymalizacyjnego lub sterującego symulacją powoduje, że historia symulowanej ewolucji przebiega odmiennie, w związku z czym nie sposób przewidzieć jej wyniku. Bez wnikliwych analiz statystycznych nie można rozstrzygnąć, czy obserwowane zmiany przebiegu symulacji i uzyskanych rezultatów spowodowane są zmianą wartości parametru czy losową zmianą historii ewolucji w trakcie symulacji. W związku z tym określanie wartości parametrów jest działaniem heurystycznym, w którym bardzo duże znaczenie mają wiedza i doświadczenie użytkownika. Może ono stanowić także odrębne złożone zadanie badawcze.<sup>7</sup> Obliczenia próbne, których celem jest ustalenie wartości parametrów, wyko-

---

<sup>6</sup> Można przyjąć także inne warunki zakończenia, np. brak zwiększenia wartości funkcji przystosowania przez określoną liczbę pokoleń, niewygenerowanie nowych wariantów włączanych do zbioru przybliżającego przez określoną liczbę pokoleń, osiągnięcie określonych wartości kryteriów oceny, osiągnięcie określonej wartości odległości zbioru przybliżającego od oceny rozwiązania asymptotycznego.

<sup>7</sup> Autor planuje podjęcie takich badań.



nuje się bardzo często w trakcie formułowania modelu optymalizacyjnego i przygotowywania danych do obliczeń, a osiągnięty wynik akceptuje się arbitralnie tylko na podstawie zadowalającego przebiegu obliczeń oraz osiągniętych rezultatów. Ilość i różnorodność parametrów oraz brak algorytmicznego sposobu działania powodują, że przeprowadzone obliczenia testowe są trudne do udokumentowania. Jednocześnie rola tych czynności jest trudna do przecenienia, przy czym od doświadczenia oraz trafności ocen użytkownika zależą niezbędny koszt obliczeniowy oraz zadowalające wyniki optymalizacji.

## 6.4. Podsumowanie i wnioski

Na potrzeby opracowanego narzędzia obliczeniowego do wielokryterialnej optymalizacji konstrukcji kadłuba statku morskiego zrealizowano wiele szczegółowych koncepcji, umożliwiających skuteczne rozwiązanie sformułowanego zadania, takich jak:

- (1) sformułowanie matematycznej postaci funkcji użyteczności kryteriów oceny, umożliwiającej zastąpienie fizycznych wartości kryteriów oceny unormowanymi wartościami odpowiednich funkcji użyteczności, spełniającymi wymagania algorytmu genetycznego;
- (2) sformułowanie matematycznej postaci funkcji kary za naruszenie ograniczeń, umożliwiającej miękką selekcję pod względem ograniczeń reprezentowanych przez funkcje kary;
- (3) sformułowanie matematycznej postaci wskaźnika dopuszczalności wariantu konstrukcji, umożliwiającej rozmycie granicy zbioru wariantów dopuszczalnych;
- (4) opracowanie wielopunktowych operatorów krzyżowania zwiększających skuteczność krzyżowania osobników reprezentowanych przez długie łańcuchy chromosomów;
- (5) opracowanie algorytmu archiwizowania rozwiązań niezdominowanych w zewnętrznym zbiorze przybliżającym;
- (6) sformułowanie koncepcji rozwiązania asymptotycznego i odległości od tego rozwiązania oraz wskazanie roli tej koncepcji w śledzeniu zbieżności algorytmu podczas symulacji komputerowej oraz odgrywanej przez to rozwiązanie roli atraktora zawężającego zbiór przybliżający;
- (7) opracowanie procedury obliczania wartości szeregowania wariantów dopuszczalnych, umożliwiającej promowanie w procesie selekcji wariantów dopuszczalnych, leżących blisko zbioru przybliżającego, a tym samym zwiększenie zdolności eksploatacyjnych algorytmu;
- (8) opracowanie procedury obliczania wartości licznika dominacji wariantów dopuszczalnych, umożliwiającej promowanie w procesie selekcji wariantów dopuszczalnych odległych od zbioru przybliżającego, a tym samym zwiększenie zdolności eksploracyjnych algorytmu;
- (9) matematyczne sformułowanie kombinowanej funkcji przystosowania umożliwiającej selekcję wariantów pod względem kryteriów optymalizacji, szeregowania i licznika dominacji, odległości od rozwiązania asymptotycznego oraz stopnia naruszenia ograniczeń reprezentowanych przez składowe funkcje kary;
- (10) opracowanie koncepcji szerokości zbioru przybliżającego oraz wskazanie roli tej koncepcji w śledzeniu zbieżności algorytmu podczas symulacji komputerowych;
- (11) opracowanie koncepcji głębokości zbioru przybliżającego oraz wskazanie roli tej koncepcji w śledzeniu zbieżności algorytmu podczas symulacji komputerowych;

(12) sformułowanie pojęcia wektorowych wskaźników jakości zbiorów przybliżających oraz opracowanie algorytmu oceny jakości zbiorów przybliżających za pomocą wektorowych wskaźników jakości.

Koncepcje (1), (2), (3), (6), (7), (8), (9), (10) i (11) są całkowicie autorskimi propozycjami, opracowanymi na potrzeby budowanego narzędzia obliczeniowego. Propozycje (4), (5) i (12) są oryginalnymi i niezależnymi sformułowaniami lub rozszerzeniem koncepcji zaproponowanych również przez innych badaczy.

Oryginalnym dziełem autora jest także obliczeniowe narzędzie obliczeniowe – system programów komputerowych do realizacji zaproponowanych koncepcji i opracowany algorytm.

Formułując wektorowy wskaźnik jakości **QI** zbiorów przybliżających, przyjęto, że składowymi tego wskaźnika będą: (1) odległość zbioru przybliżającego od oceny rozwiązania asymptotycznego  $QI_{AD}$ , (2) szerokość zbioru przybliżającego  $QI_B$ , (3) głębokość zbioru przybliżającego  $QI_D$ , (4) wielkość zdominowanej części przestrzeni ocen  $QI_H$  oraz (5) udział (względny wkład) wyników danej symulacji w agregowanym zbiorze przybliżeń  $QI_{NF}$ .

Zaproponowana metoda algorytmu ewolucyjnego z kombinowaną funkcją przystosowania, wykorzystująca w procesie selekcji kombinowaną funkcję przystosowania, która jest ważoną sumą składników reprezentujących: (1) kryteria optymalizacji, (2) szeregowanie wariantów dopuszczalnych pod względem relacji dominacji, (3) licznik dominacji wariantów dopuszczalnych, (4) odległość wariantów dopuszczalnych od rozwiązania asymptotycznego, oraz (5) stopień naruszenia ograniczeń, zostanie w dalszej części pracy przetestowana w serii symulacji komputerowych na przykładzie wielokryterialnej optymalizacji konstrukcji kadłuba szybkiego promu pasażersko-samochodowego.

## **7. Sformułowanie zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku. Modele obliczeniowe**

### **7.1. Ogólna charakterystyka statku**

#### **7.1.1. Założenia i dane dotyczące optymalizacji**

Do przeprowadzenia symulacji komputerowych i zweryfikowania poprawności opracowanej metody wybrano konstrukcję kadłuba szybkiego promu pasażersko-samochodowego projektu Auto Express 82 (*Third Auto Express 82 Arrives in Northern Europe* 1997, *Polish fast ferry „Boomerang”* 1997, *Boomerang: catamaran ferry for Baltic Service* 1997). Warunki eksploatacji określono jak dla promu Boomerang eksploatowanego przez krótki czas przez polskiego armatora Polską Żeglugę Bałtycką w zachodniej części Morza Bałtyckiego na trasie Świnoujście–Malmö. Ilościowe charakterystyki statku, niezbędne do opracowania modelu obliczeniowego, zestawiono w tablicy 7.1. Do wymiarowania wiązań przyjęto formuły obliczeniowe zawarte w przepisach klasyfikacyjnych BV (1995).

Prom pasażersko-samochodowy, projektu Auto Express 82 australijskiej firmy Austal to katamaran semi-SWATH (podwodne części kadłubów bocznych, o dużej wyporności, połączone są z platformą pylonami – bardzo smukłymi na dziobie i rozszerzającymi się w kierunku rufy), przeznaczony jest do przewozu pasażerów i samochodów osobowych z szybkością sięgającą 42 węzłów (rysunek B.1). Przyjęte wartości charakterystyk projektowych dotyczą wszystkich opisanych w następnym rozdziale symulacji komputerowych.

Opisy techniczne jednostek projektu Auto Express 82, opublikowane w materiałach informacyjnych i reklamowych, fotografie przedstawiające szczegóły konstrukcyjne oraz obserwacje autora dokonane na jednostce Boomerang wskazują, że kadłuby boczne zbudowane są we wzdlużnym układzie wiązań. Jest to korzystniejsze rozwiązanie, w stosunku do układu poprzecznego, z punktu widzenia minimalizacji ciężaru. Wzdłużne usztywnienia wykonano w postaci profili wyciskanych przyspawanych do blach poszycia. Ramy poprzeczne wykonano w postaci ram płytowych prefabrykowanych z elementów wycinanych z blach. Pomosty, połączone z kadłubami bocznymi w integralną konstrukcyjnie bryłę kadłuba, zbudowano również we wzdlużnym układzie wiązań, z zapewnieniem ciągłości wiązań, szczególnie w obszarach styku pomostu i kadłubów bocznych. Wzdłużniki wykonano w postaci spawanych konstrukcji płytowych w taki sam sposób jak w przypadku morskich statków towarowych. Konstrukcja nadbudówek zależy od kondygnacji. Dwie najniższe kondygnacje zbudowane są we wzdlużnym układzie wiązań, z ciągłym przejściem w wiązania pomostu i kadłubów bocznych. Górna kondygnacja zbudowana jest w poprzecznym układzie wiązań, z zapewnieniem ciągłości z układem wzdlużnym niższych kondygnacji nadbudówki.

Pozostałe szczegóły cech geometrycznych modelu, niewynikające bezpośrednio z identyfikacji, podano w podrozdziałach 7.2 i 7.3, w których zdefiniowano modele konstrukcji statku strukturalny i matematyczny, przyjęte do optymalizacji.

Tablica 7.1. Przyjęte ilościowe cechy projektowe modelu statku

| Oznaczenie | Jednostka | Wartość | Opis                                     |
|------------|-----------|---------|------------------------------------------|
| $L$        | m         | 90,00   | całkowita długość kadłuba                |
| $L_{lw}$   | m         | 82,00   | długość statku na linii wodnej           |
| $B$        | m         | 23,00   | szerokość statku                         |
| $B_k$      | m         | 5,30    | szerokość kadłuba                        |
| $H_m$      | m         | 5,20    | wysokość boczna do pokładu „mokrego”     |
| $H_{sam}$  | m         | 6,80    | wysokość boczna do pokładu samochodowego |
| $H_{mp}$   | m         | 9,25    | wysokość boczna do międzypokładu         |
| $H_{pas}$  | m         | 11,70   | wysokość boczna do pokładu pasażerskiego |
| $T$        | m         | 3,30    | zanurzenie statku                        |
| $v$        | w         | 42,00   | szybkość eksploatacyjna                  |

Formułując w dalszej części zadanie optymalizacji oraz odpowiednie modele optymalizacyjne, założono, że znane są wymiary główne statku, rozplanowanie przestrzenne, charakterystyki techniczne i eksploatacyjne, materiał konstrukcyjny oraz obciążenie konstrukcji. Poszukiwane zaś będą rozmieszczenie przestrzenne elementów konstrukcyjnych oraz wymiary tych elementów (blach poszycia i kształtowników).

### 7.1.2. Szlak żeglutowy

W trakcie projektowania konstrukcji kadłuba statku podstawowymi informacjami o szlaku są charakterystyki warunków środowiskowych: prędkość i siła wiatru, temperatura powietrza i wody morskiej, stan falowania morskiego, zalodzenie i inne. Z listy tej na etapie projektu wstępnego najważniejsze jest falowanie morskie, ponieważ w decydujący sposób wpływa na wielkość obciążeń eksploatacyjnych (ciśnienia wody zaburtowej oraz oddziaływania ładunku podczas ruchu statku na sfalowanej wodzie). Na podstawie danych statystycznych falowania występującego na akwenie w okresie eksploatacji jednostki określa się tzw. widmo falowania. Wśród wielu charakterystyk widma najważniejsza jest wartość znaczącej wysokości fali  $H_{1/3}$  i określany na tej podstawie profil żeglugi, który zawiera informację o największej szybkości statku przy określonej wysokości fali. Jest to niezbędne do określenia obciążeń morskich projektowanej konstrukcji, szacowanych na podstawie odpowiednich przepisów klasyfikacyjnych.

Przyjęty w badaniach obszar operacyjny statku obejmuje południowy Bałtyk i cieśniny duńskie. Na podstawie danych dotyczących szybkości wiatru na akwenie w pobliżu Rugii i południowej Szwecji, odpowiadających założonemu rejonowi żeglugi, przedstawionych przez Defanta (cyt. za Łomniewskim i in. 1975), oraz danych ITTC (cyt. za Dudziakiem 1980) oszacowano miesięczne wartości znaczącej wysokości fali  $H_{1/3}$  na akwenie eksploatacji:

$$H_{1/3} = 0,04m^2 - 0,51m + 2,51 \quad (7.1)$$

gdzie:  $m$  – numer kolejnego miesiąca w roku.

Okres od maja do sierpnia charakteryzują wartości znaczącej wysokości fali mniejsze niż  $H_{1/3} = 1,0$  m. Od września do grudnia następuje zdecydowany wzrost wysokości fali. W grudniu znacząca wysokość fali osiąga największą wartość roczną  $H_{1/3} = 2,3$  m. W miesiącach następnych, od stycznia do maja, następuje spadek wartości znaczącej wysokości fali  $H_{1/3}$  do wartości najmniejszej  $H_{1/3} = 1,0$  m.

Jako wartość ekstremalną przyjęto największą wartość znaczącej wysokości fali na akwenie:  $H_{1/3max} = 2,3$  m. Jest to wartość z grudnia, czyli przypadająca na sezon zimowy, w którym możliwości eksploatacji szybkich statków budzą wątpliwości (są bardzo ograniczone lub ich eksploatacja jest niemożliwa).

### 7.1.3. Kryteria optymalizacji

W praktyce optymalizacja wielokryterialna polega na porównaniu różnych dopuszczalnych wariantów konstrukcji generowanych przez narzędzie obliczeniowe w celu sklasyfikowania i wyboru wariantów niezdominowanych pod względem kryteriów optymalizacji oraz włączenia ich do zbioru  $\Psi_f$  przybliżającego zbiór optymalny Pareto  $\Psi_p$ .

Tarnowski (2009) zwraca uwagę na kluczową rolę kryteriów optymalizacji w skutecznym przeprowadzaniu procesu optymalizacji. Błędne przyjęcie kryteriów i relacji między nimi może spowodować, że rezultaty optymalizacji nie zostaną zaakceptowane, a wysiłek poniesiony na przygotowanie i wykonanie obliczeń optymalizacyjnych będzie stracony.

W celu przyjęcia właściwego zbioru kryteriów Tarnowski (1997) zaproponował zastosowanie metody dekompozycji zadania projektowego. W jej wyniku otrzymuje się następującą hierarchię kryteriów optymalizacji: (1) pierwotne kryterium optymalizacji  $\Phi_p$ , (2) nadrzędne kryterium optymalizacji  $\Phi_n$  oraz (3) zadaniowe kryterium optymalizacji  $f$ . Pierwotne kryterium optymalizacji konstrukcji kadłuba  $\Phi_p$  powinno wynikać z wymagań stawianych statkowi jako obiektowi projektowanemu i budowanemu w celu zaspokojenia określonej potrzeby społecznej. Nadrzędne kryterium optymalizacji  $\Phi_n$  to konkretna właściwość konstrukcji kadłuba, określona na początku procesu projektowania, która powinna być najlepsza (maksymalna lub minimalna). Kryterium to powinno wynikać z kryterium nadrzędnego  $\Phi_n$ . Zadaniowe kryterium optymalizacji  $f_s$  jest cząstkową miarą jakości konstrukcji kadłuba statku ze względu na przyjęte wcześniej nadrzędne kryterium optymalizacji  $\Phi_n$ . Musi być ono mierzalne i odpowiednie dla danego zadania optymalizacji oraz mieć jednoznaczną postać formalną.

Każdy statek będący przedmiotem projektowania ma zaspokoić określoną potrzebę społeczną w jak najlepszy sposób w określonych warunkach. Można przyjąć, że budowanie

statku towarowego to przede wszystkim przedsięwzięcie ekonomiczne, które powinno przynieść określone korzyści zarówno armatorowi zamawiającemu statek, jak i stoczni realizującej zamówienie. Można zatem założyć, że pierwotnym kryterium optymalizacji  $\Phi_p$  jest zysk, jaki przyszła eksploatacja statku przyniesie armatorowi lub zysk, jaki budowa statku przyniesie stoczni.

Dalsze uszczegóławianie pierwotnego kryterium optymalizacji może doprowadzić do sformułowania nadrzędnego kryterium optymalizacji  $\Phi_n$ . Dla armatora kryterium nadrzędnym może być ładowność statku, ponieważ ona decydować będzie o przychodach z eksploatacji, lub koszt budowy, ponieważ ważne dla armatora są niskie koszty początkowe inwestycji. Dla stoczni może to też być koszt budowy, ponieważ przy zakontraktowanej cenie za zbudowanie statku wpłynie on na możliwość osiągnięcia zysku z budowy statku. Cena zbudowanego statku powinna być utrzymana na możliwie najniższym poziomie, aby zapewnić konkurencyjność stoczni. Pierwotnymi kryteriami optymalizacji mogą być także wskaźniki ekonomiczne, np. okres zwrotu zaangażowanego kapitału, wartość bieżąca netto, księgowa stopa zwrotu i inne, określające efektywność finansową inwestycji związanej z budową statku. W pracy przyjęto, że nadrzędnym kryterium optymalizacji  $\Phi_n$  jest koszt zbudowania statku.

Aby w sposób skuteczny przeprowadzić optymalizację konstrukcji kadłuba statku, trzeba określić ilościowy sposób pomiaru jakości generowanych wariantów za pomocą wielkości liczbowych, zależnych od zmiennych konstrukcyjnych  $x_i$ , czyli określić zadaniowe kryteria optymalizacji lub inaczej: kryteria oceny  $f_s$ .

Ponieważ zagadnienia ekonomiczne są integralną częścią działalności technicznej, najogólniejszym kryterium optymalizacji mógłby być koszt konstrukcji, przy spełnieniu wszystkich wymagań technicznych i funkcjonalnych (Szymczak 1998). Jednak wartość pieniądza jako skali porównawczej kosztów ulega zmianom i, podobnie jak wzajemny stosunek poszczególnych składników kosztu konstrukcji, zależy od lokalnych warunków społeczno-ekonomicznych. Próbuując uniknąć tej trudności jako kryteria optymalizacji konstrukcji lub jej elementów często przyjmuje się ich objętość lub ciężar. Wykorzystując odpowiednie dane o zbudowanych podobnych jednostkach, na etapie projektu wstępnego do wskaźnikowego oszacowania kosztów budowy kadłuba można wykorzystać ciężar konstrukcji.

Ciężar kadłuba statku powinien być także uwzględniony w analizie możliwości wykonawczych stoczni, które określają między innymi: udźwig pochylni lub nośność doku, udźwig kołowych, kolejowych lub wodnych środków transportu i dźwigów do transportu elementów budowanego statku.

Każda oszczędność związana z ciężarem, zarówno kadłuba statku, jak i układu napędowego, lub innych systemów bądź elementów wyposażenia, pozwala uzyskać zwiększenie szybkości statku lub polepszenie jego innych właściwości (Potyrała 1967). Przy ustalonej wyporności zmniejszenie ciężaru konstrukcji umożliwia zwiększenie ładowności statku. Jeśli natomiast ustalona zostanie ładowność statku, można będzie zmniejszyć jego wyporność, a w konsekwencji moc napędu głównego i zużycie paliwa. Ogólnie rzecz biorąc, konstruując kadłub statku, powinno się więc dążyć do zminimalizowania ciężaru. Powinno to pozwolić na obniżenie kosztów budowy, zmniejszenie strat nośności ładunku, spowodowanych ciężarem konstrukcji, oraz zmniejszenie zużycia paliwa.

Jako zadaniowe kryteria optymalizacji można przyjmować także pewne kryteria odzwierciedlające w sposób przybliżony nakład pracy podczas wykonywania konstrukcji lub jej konserwacji. Może to być na przykład objętość lub długość spoin w projektowanej konstrukcji stalowej lub jej powierzchnia zewnętrzna, która podlega konserwacji. Również w tym wypadku metody wskaźnikowe pozwalają oszacować pracochłonność i koszt wykonania konstrukcji na etapie projektu wstępnego.

Trzeba również zauważyć, że (1) w projekcie wstępnym ilość informacji o projektowanej konstrukcji jest jeszcze bardzo ograniczona, a jej pewność – bardzo niewielka; (2) optymalizacja konstrukcji statku morskiego wymaga uwzględnienia w modelu optymalizacyjnym wielu uproszczeń, aby optymalizacja ta była w ogóle możliwa; (3) wymagane jest szybkie przygotowanie modeli obliczeniowych oraz obliczeń numerycznych, umożliwiające ocenę wielu rozwiązań w stosunkowo krótkim czasie. Z tych powodów opracowany i przyjęty model optymalizacyjny powinien być względnie prosty i pozbawiony wielu szczegółów, które zostaną wypracowane na kolejnych etapach projektowania. Nie ma również potrzeby stosowania wyrafinowanych, a przy tym praco- i czasochłonnych metod analizy konstrukcji, ponieważ byłaby ona przeprowadzona przy bardzo niewielkiej i niepewnej wiedzy o projekcie, co zmniejszyłoby rzeczywistą wartość z trudem wypracowanych rezultatów.

W przypadku poszukiwania optymalnej spawanej KKSM na etapie projektu wstępnego (w którym można wziąć pod uwagę potrzebę minimalizacji trzech kryteriów, na przykład: objętości konstrukcji, objętości lub długości spoin oraz powierzchni zewnętrznej konstrukcji) graficzne przedstawienie i interpretacja wyników są bardzo trudne. W pracy liczbę kryteriów ograniczono do (1) ciężaru konstrukcji<sup>1</sup>, proporcjonalnego do objętości elementów konstrukcyjnych, oraz do (2) pola powierzchni zewnętrznej do malowania i konserwacji. Inaczej mówiąc, przyjęte kryteria optymalizacji odpowiadają w przybliżeniu optymalizacji (1) kosztu konstrukcji i (2) pracochłonności budowy.

Przyjęto zatem, że w przypadku KKSM ciężar kadłuba oraz łączna powierzchnia zewnętrzna elementów konstrukcyjnych (łączna suma wszystkich powierzchni, które należy oczyścić i zakonserwować) mogą być określone jako dobrze zdefiniowane wielkości fizyczne, możliwe do wyrażenia w postaci funkcji zmiennych konstrukcyjnych:

$$\text{ciężar konstrukcji kadłuba} \rightarrow f_1 = f_1(\mathbf{x}) = f_1(x_1, x_2, \dots, x_n) \rightarrow \min! \quad (7.2)$$

$$\text{pole powierzchni zewnętrznej elementów} \rightarrow f_2 = f_2(\mathbf{x}) = f_2(x_1, x_2, \dots, x_n) \rightarrow \min! \quad (7.3)$$

Mogą być one także wyznaczone ilościowo w dowolnej fazie projektowania. Mogą być zatem przyjęte jako zadaniowe kryteria optymalizacji  $f_s$ .

Przyjęto, że na etapie projektu wstępnego ciężar konstrukcji jest sumą ciężarów za projektowanych elementów konstrukcyjnych i oszacowań ciężaru pozostałych elementów. Podstawą tych oszacowań są ciężary zaprojektowanych elementów.

---

<sup>1</sup> W tym samym znaczeniu powszechnie używa się pojęcia „masa konstrukcji”, która oczywiście jest bardziej obiektywną miarą niż ciężar. Przyjęcie jako kryterium optymalizacji ciężaru uzasadnia to, że: (1) ciężar konstrukcji może być bezpośrednio porównany z wyrażoną w jednostkach ciężaru nośnością urządzeń transportowych, np. dźwigów, pochylni i innych wykorzystywanych podczas budowy statku; (2) ciężar konstrukcji jest siłą, w związku z czym może być bezpośrednio zastosowany w obliczeniach wytrzymałości konstrukcji kadłuba statku.

Przyjęte w pracy zadaniowe kryteria optymalizacji nie są oczywiście jedynymi możliwymi. Na przykład Mansour (1972), Bronskij i in. (1974), Daidola i Basar (1980), Jastrzębski (1994) wymieniają wiele kryteriów projektowania KKSM<sup>2</sup>, które można podzielić na:

(a) kryteria techniczno-eksploatacyjne: ciężar kadłuba, pojemność pomieszczeń, przyspieszenie pionowe, efektywność eksploatacji statku, poziom drgań i hałasów, wielkość i kształt deformacji eksploatacyjnych;

(b) kryteria wytrzymałościowe: naprężenia (normalne, styczne, zredukowane), wielkość i kształt deformacji (odkształcenia), uplastycznienie (najczęściej na skutek zginania), nośność plastyczna, wyboczenie na skutek niestateczności przy ściskaniu (np. konstrukcji pokładu wytrzymałościowego w saggingu), kruche pęknięcie, pęknięcie zmęczeniowe, odporność kolizyjna;

(c) kryteria technologiczne: stopień normalizacji, przystosowanie do przewidzianych technik wytwarzania, koszty wytwarzania, deformacje technologiczne, ciężar sekcji i bloków kadłuba.

Klasyfikacja ta może posłużyć do wyboru innych zadaniowych kryteriów optymalizacji  $f_s$ .

Jak podaje Kozielecki (1977), w psychologicznej teorii decyzji zaleca się, aby lista kryteriów optymalizacyjnych nie obejmowała więcej niż 7–9 kryteriów. Jednocześnie wyniki badań statystycznych, opisywane tzw. krzywą Lorenca lub krzywą Pareto, wskazują, że ok. 20% najważniejszych kryteriów wpływa w 80% na jakość ocenianego obiektu (Tarnowski 1997). W praktyce interpretacja i ocena wyników optymalizacji, przy uwzględnieniu kilku kryteriów, jest bardzo trudna, a interpretacja wyników obliczeń – niepewna. W niniejszej pracy ograniczono liczbę kryteriów do dwóch, co oznacza sformułowanie dwukryterialnego zadania optymalizacji.

Przyjęty w zadaniu optymalizacyjnym zbiór kryteriów oceny oraz relacji między nimi Tarnowski (2009) nazywa systemem wartości. System ten składa się z przyjętych zadaniowych kryteriów oceny oraz z relacji ważności (preferencji) między nimi. Modelem matematycznym kryteriów  $f_s$ :  $s = 1, \dots, S$  nazwać się będą zależności od zmiennych konstrukcyjnych:  $f_s = f(x_1, x_2, \dots, x_n)$ . Na przyjęty w pracy system wartości składają się: (1) kryteria optymalizacji, ciężar konstrukcji  $f_1(\mathbf{x})$  – zależność (7.2) i pole powierzchni elementów konstrukcyjnych kadłuba do malowania i konserwacji  $f_2(\mathbf{x})$  – zależność (7.3), a także (2) przedstawione na rysunku 4.2 strategie umożliwiające uwzględnienie kryteriów optymalizacji w ewolucyjnych algorytmach optymalizacji wielokryterialnej. W przypadku strategii, przedstawionych na rysunkach 4.2 (a) i 4.2 (b), formułuje się skalarnie kryterium optymalizacji i różne metody ustalania wartości współczynników wagowych. W przypadku strategii, przedstawionych na rysunkach 4.2 (c) i 4.2 (d) skalarnie kryterium optymalizacji nie jest formułowane. W przypadku przedstawionym na rysunku 4.2 (c) selekcja rozwiązań następuje pod względem jednego wybranego (zazwyczaj losowo) kryterium optymalizacji. W przypadku przedstawionym na rysunku 4.2 (d) selekcja następuje pod względem atrybutów dominacji, czyli miar opisujących wewnętrzną strukturę zbioru dopuszczalnego i położenie wybranego wariantu względem innych wariantów dopuszczalnych.

---

<sup>2</sup> Paczkowski (1999) podaje listę 192 kryteriów optymalizacji obiektów budowlanych: 14 kryteriów nadrzędnych, 45 kryteriów ekonomicznych, 40 kryteriów konstrukcyjnych, 24 kryteriów architektonicznych, 36 kryteriów technologicznych, 12 kryteriów funkcjonalnych i 21 kryteriów ekologicznych. Wiele z nich może być także zastosowanych w przypadku optymalizacji KKSM.



Tarnowski (2009) formułuje wymagania stawiane przyjętym kryteriom oceny  $f_s$ . Korzystając z nich, można stwierdzić, że: (1) przyjęte kryteria wynikają z nadrzędnego kryterium optymalizacji  $\Phi_n$ ; (2) przyjęte kryteria są wyczerpujące, tzn. w pełni opisują nadrzędne kryterium optymalizacji  $\Phi_n$ ; (3) liczność  $S = 2$  zbioru kryteriów jest najmniejsza w przypadku wielokryterialnego zadania optymalizacji; (4) oba kryteria są zdefiniowane i mierzalne; (5) dla każdego generowanego losowo wariantu konstrukcji możliwe jest obliczenie wartości kryteriów; (6) przyjęte kryteria oceny są dostępne pomiarowo, co ma ścisły związek z właściwościami (4) i (5), co oznacza, że istnieje możliwość wyznaczenia wartości każdego kryterium  $f_s$  dla każdego generowanego wariantu KKSM; (7) przyjęte kryteria są wzajemnie niezależne ze względu na użyteczność – każda z cech jakościowych projektowanej KKSM (koszt konstrukcji oraz pracochłonność) jest opisana tylko przez jedno kryterium oceny.

## 7.2. Modele konstrukcji kadłuba statku

### 7.2.1. Geometryczny model konstrukcji

Niezależnie od naturalnego podziału katamarana na rejony architektoniczne, kadłuby boczne, platformę, nadbudówkę, jego konstrukcję podzielono dodatkowo na rejony konstrukcyjne, różniące się pod względem działających obciążeń i algorytmów wymiarowania wiązań. Rozróżniono następujące rejony konstrukcyjne:

(a) zewnętrzne – poddawane bezpośrednio wpływowi środowiska i pochodzącym od niego obciążeniom: dno, burty, pokład „mokry”, ściany nadbudówek, pokład otwarty;

(b) wewnętrzne – przystosowane do przewozu ładunków, zapasów i wyposażenia, poddawane obciążeniom statycznym i obciążeniom uderowym: dno wewnętrzne, pokłady wewnętrzne, grodzie wodoszczelne i grodzie zbiorników.


Każdy z wymienionych rejonów stanowi typową okrętową konstrukcję cienkościenną, składającą się z poszycia podpieranego przez usztywnienia zwykłe i ramowe.

Przyjęto wzdłużny układ wiązań konstrukcji kadłuba. Założono wykonanie wzdłużnych usztywnień w postaci profili wyciskanych przyspawanych do blach poszycia. W przypadku ram poprzecznych założono ich wykonanie z wyciskanych profili teowych. Dla pomostu, platformy połączonej z kadłubami bocznymi w integralną konstrukcyjnie bryłę kadłuba, przyjęto również wzdłużny układ wiązań, z zapewnieniem ciągłości wiązań, szczególnie w obszarach łączenia pomostu i kadłubów bocznych. Wzdłużniki przyjęto w postaci wyciskanych profili teowych.<sup>3</sup> Dla nadbudówki założono wzdłużny układ wiązań, z ciągłym przejściem w wiązania pomostu i kadłubów bocznych.

Przyjęty geometryczny model konstrukcji kadłuba statku przedstawiono na rysunku 7.1 w postaci uproszczonych schematów zładu poprzecznego i zładu wzdłużnego. Wielkość zadania obliczeniowego ograniczono poprzez wydzielenie obszaru konstrukcji poddanego analizie wiązań w kierunku wzdłużnym – pomiędzy dwoma sąsiednimi grodziami wodoszczelnymi. Utworzono w ten sposób wokół owręża sekcję przestrzenną o długości 17,5 m.

---

<sup>3</sup> W przypadku statków morskich typowe jest wykonywanie ram poprzecznych oraz wzdłużników w postaci prefabrykowanej z elementów wyciętych z blach. W pracy tej przyjęto jednak znormalizowane (w handlowych katalogach producentów) profile wyciskane, identyfikowane przez jedną zmienną konstrukcyjną, ograniczając tym samym znacznie liczbę zmiennych konstrukcyjnych, a więc i wielkość zadania optymalizacyjnego.



Rys. 7.1. Schematy zładu poprzecznego i zładu wzdłużnego geometrycznego modelu konstrukcji kadłuba statku

W obrębie sekcji wydzielono dziewięć rejonów konstrukcyjnych. Dla wszystkich rejonów przyjęto wzdłużny układ wiązań. Liczba (odstęp) ram poprzecznych jest zmienną poszukiwaną w procesie optymalizacji lub jest parametrem konstrukcji w badaniach wpływu parametrów konstrukcji na cechy eksploatacyjne. Również liczba (odstęp) usztywnień wzdłużnych w każdym rejonie może być zmienną konstrukcyjną lub parametrem. Rozpiętość usztywnień jest ustalona dla całej konstrukcji i równa odstępowi ram poprzecznych. Lokalizacja wzdłużnych wiązarów pomostu i pokładów jest ustalona. W płaszczyznach wiązarów wzdłużnych wręgi ramowe wzmacniane są podporami.

Pozostałe szczegóły cech geometrycznych modelu, niewynikające bezpośrednio z identyfikacji, zamieszczono w podrozdziale 7.3, w którym zdefiniowano matematyczny model optymalizacji.

### 7.2.2. Materiałowe cechy konstrukcji

Wymagania dotyczące właściwości mechanicznych wybranych stopów aluminium z grup 5000 i 6000, przeznaczonych na spawane konstrukcje statków szybkich, zawarte są w odpowiednich przepisach towarzystw klasyfikacyjnych. Podano tam wartości przyjmowane do obliczeń wymiarujących wiązania konstrukcyjne (tablice 7.2 i 7.3).

Tablica 7.2. Cechy mechaniczne i fizyczne materiałów konstrukcyjnych; właściwości stopów aluminium na blachy poszycia

| Cecha                                        | Stop aluminium<br>5454O | Stop aluminium<br>5086O | Stop aluminium<br>5083O |
|----------------------------------------------|-------------------------|-------------------------|-------------------------|
| Gęstość $\rho$ , t/m <sup>3</sup>            | 2,66                    | 2,66                    | 2,66                    |
| Umowna granica plastyczności $R_{0,2}$ , MPa | 85                      | 100                     | 115                     |
| Wytrzymałość na rozciąganie $R_m$ , MPa      | 215                     | 240                     | 275                     |
| Moduł sprężystości $E$ , MPa                 | 70 000                  | 70 000                  | 70 000                  |
| Współczynnik Poissona $\nu$                  | 0,33                    | 0,33                    | 0,33                    |
| Wytrzymałość właściwa $\sqrt{R_m} / \rho$    | 5,51                    | 5,82                    | 6,23                    |
| Sztywność właściwa $\sqrt{E} / \rho$         | 99,50                   | 99,50                   | 99,50                   |

O – wyżarzany.

Źródło: BV (1995), *Aluminium and the Sea* (1993).

Tablica 7.3. Cechy mechaniczne i fizyczne materiałów konstrukcyjnych; właściwości stopów aluminium na profile wyciskane

| Cecha                                        | Stop aluminium<br>6106T5 | Stop aluminium<br>6061T6 | Stop aluminium<br>6082T6 |
|----------------------------------------------|--------------------------|--------------------------|--------------------------|
| Gęstość $\rho$ , t/m <sup>3</sup>            | 2,66                     | 2,66                     | 2,66                     |
| Umowna granica plastyczności $R_{0,2}$ , MPa | 195                      | 240                      | 250                      |
| Wytrzymałość na rozciąganie $R_m$ , MPa      | 240                      | 260                      | 290                      |
| Moduł sprężystości $E$ , MPa                 | 70 000                   | 70 000                   | 70 000                   |
| Współczynnik Poissona $\nu$                  | 0,33                     | 0,33                     | 0,33                     |
| Wytrzymałość właściwa $\sqrt{R_m} / \rho$    | 5,82                     | 6,06                     | 6,40                     |
| Sztywność właściwa $\sqrt{E} / \rho$         | 99,50                    | 99,50                    | 99,50                    |

T5 – sztucznie starzony, T6 – obrabiany cieplnie w roztworze + sztucznie starzony.

Źródło: BV (1995), *Aluminium and the Sea* (1993).

Przegląd dotychczasowych badań wskazuje, że rozważa się również możliwości zastosowania kompozytów polimerowych oraz stali o wysokiej wytrzymałości. W przypadku kompozytów nie rozwiązano jeszcze wszystkich problemów związanych z ich zastosowaniem do konstrukcji dużych jednostek. Nie zbudowano dotychczas z kompozytów promów pasażersko-samochodowych, a w literaturze nawet nie podaje się informacji o planach budowy takich jednostek. Jedyne znane zastosowania dotyczą małej i średniej wielkości promów pasażerskich. Stal jest materiałem o mniejszej, od stopów aluminium, wytrzymałości

właściwej<sup>4</sup>; przewiduje się jej stosowanie w przypadku jednostek znacznie większych od eksploatowanych dzisiaj, dla których wymagania wytrzymałościowe konstrukcji są ważniejsze od wymagania minimalizacji ciężaru.

Jak wskazują Bowden i Embry (1989) oraz Czimmek i Schaub (1991), na konstrukcje dużych jednostek (o długości powyżej około 200 m) przewiduje się stosowanie stali o wysokiej wytrzymałości. W przypadku zastosowania takich stali nie należy jednak oczekiwać zmniejszenia ciężaru konstrukcji, proporcjonalnego do wzrostu wartości granicy plastyczności stali, ponieważ w przypadku elementów płytowych poszycia kadłuba, które stanowią główną składową ciężaru konstrukcji statku, bardzo często krytyczną formą zniszczenia konstrukcji jest utrata stateczności, zależna od wartości modułu Younga, która jest taka sama dla wszystkich rodzajów stali.

Grubości blach poszycia oraz wymiary kształtowników łebkowych (przyjętych na usztywnienia) i kształtowników teowych (przyjętych na wiązania ramowe) założono zgodnie katalogiem producenta oraz zestawiono w załączniku C. Kształtowniki łebkowe zastosowano na usztywnienia wzdłużne, natomiast kształtowniki teowe – na wiązary (poprzeczne i wzdłużne). W praktyce stoczniowej (zgodnie z wymaganiami towarzystw klasyfikacyjnych) wiązary produkuje się w postaci prefabrykatów z elementów wycinanych z arkuszy blach. Wymiary przekroju poprzecznego ram prefabrykowanych (określające wytrzymałość i ciężar konstrukcji) powinny być opisane czterema zmiennymi konstrukcyjnymi (wysokością środnika, grubością środnika, szerokością mocnika i grubością mocnika), natomiast wymiary i charakterystyki geometryczne kształtowników wyciskanych mogą być jednoznacznie identyfikowane przez jedną liczbę – zmienną konstrukcyjną, wskazującą konkretny kształtownik w katalogu, co zmniejsza znacznie liczbę zmiennych konstrukcyjnych niezbędnych do opisu konstrukcji i wielkość zadania obliczeniowego, a przez to przyspiesza obliczenia.

### 7.2.3. Obciążenia projektowe konstrukcji

Do określania wartości obciążeń eksploatacyjnych przyjęto formuły odpowiednich przepisów towarzystw klasyfikacyjnych (BV 1995) – tablica 7.4. Na podstawie wartości wymiarów głównych statku oraz szybkości eksploatacyjnej, stosując podane w przepisach formuły obliczeniowe, można określić wartości obciążeń lokalnych i ogólnych w postaci różnych ciśnień, sił tnących i momentów gnących. W przypadku obciążeń slemmingowych formuły przepisów BV (1995) wymagają określenia warunków falowania opisanych wartością znaczącej wysokości fali  $H_{1/3}$ .

Informacje o znaczącej wysokości fali uwzględniono w postaci profilu żeglugi. Babage i in. (1997) podają w postaci graficznej profile żeglugi, zaproponowane dla wybranych typów dwukadłubowych statków szybkich. Nie znaleziono opublikowanych rzeczywistych profili żeglugi z eksploatacji statków szybkich. Na podstawie zidentyfikowanej w podrozdziale 7.1.2 największej wartości znaczącej wysokości fali  $H_{1/3max}$  oraz informacji uzyskanych od załogi statku Boomerang przyjęto następującą zależność pomiędzy znaczącą wyso-

---

<sup>4</sup> W tablicach 7.2 i 7.3 podano wartości wytrzymałości względnej dla wybranych stopów aluminium. W przypadku stali okrętowych odpowiednie wartości wynoszą: (1) 2,56–2,84 w przypadku stali o zwykłej wytrzymałości, (2) 2,84–3,19 w przypadku stali o podwyższonej wytrzymałości.

kością fali i odpowiadającą jej największą prędkością na przewidywanej trasie żeglugi (rysunek 7.2):

$$H_{1/3} = \begin{cases} 2,3 \text{ m dla } 0 \leq v \leq 38 \text{ w} \\ (-0,325v + 14,65) \text{ m dla } 38 < v \leq 42 \text{ w} \end{cases} \quad (7.4)$$


gdzie:  $H_{1/3}$  – aktualna znacząca wysokość fali na akwenu,  $v$  – aktualna szybkość żeglugi,  $w$  – węzeł.

Tablica 7.4. Przyjęte zależności do wyznaczania projektowych obciążeń konstrukcji

| Opis                                                    | Formuła obliczeniowa                                                                                          |
|---------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|
| Obciążenia ogólne                                       |                                                                                                               |
| Wzdłużny moment zginający                               | $M_{bl} = 1,15 \Delta L (1,0 - 1,5 C_B) (1,0 + a_{CG})$                                                       |
| Siła tnąca od zginania pionowego                        | $T_{bl} = \frac{3,1 M_{bl}}{L}$                                                                               |
| Poprzeczny moment zginający                             | $M_{bt} = \frac{\Delta b a_{CG} g}{4}$                                                                        |
| Siła tnąca od zginania poprzecznego                     | $T_{bt} = \frac{\Delta a_{CG} g}{3}$                                                                          |
| Obciążenia lokalne                                      |                                                                                                               |
| Ciśnienie uderowe dna                                   | $p_{sl} = 70 \frac{\Delta}{S_r} K_1 K_2 K_3 a_{CG}$                                                           |
| Ciśnienie uderowe pokładu „mokrego” i burt wewnętrznych | $p_{sl} = K_{CD} \left( 100 + \frac{L}{2} \right)$                                                            |
| Hydrostatyczne ciśnienie morza na dno i burty           | $p_s = 10 \left[ T + 0,75 S - \left( 1 - 0,25 \frac{S}{T} \right) z \right]$<br>lub<br>$p_s = 100(T + S - z)$ |
| Ciśnienie morza na ściany nadbudówek                    | $p_{su} = K_{su} \left[ 1 + \frac{x_1}{2L(C_B + 0,1)} \right] \cdot (1 + 0,045L - 0,38z_1)$                   |
| Obciążenia pokładów                                     | $p_d = p(1 + 0,4a_v)$                                                                                         |

Objaśnienia oznaczeń występujących w formułach obliczeniowych podają przepisy BV (1995).

Źródło: BV (1995).



Rys. 7.2. Graficzne przedstawienie przyjętego profilu żeglugi statku

W przypadku wymiarowania wiązań pokładów, przeznaczonych do przewozu samochodów, przyjęto obciążenia projektowe jak dla statków poziomego załadowania. Przyjęte na podstawie Pałucha i in. (1996) wartości obciążeń ciągłych podano w tablicy 7.5.

Tablica 7.5. Obciążenia projektowe przyjęte do wymiarowania konstrukcji pokładów do przewozu samochodów

| Rejon konstrukcyjny | Źródło obciążenia         | Obciążenie ciągłe, $\text{kN}\cdot\text{m}^{-2}$ |
|---------------------|---------------------------|--------------------------------------------------|
| Pokład samochodowy  | autobus                   | 20,0                                             |
| Międzypokład        | samochód osobowy, minivan | 2,0                                              |

Źródło: Pałucha i in. (1996).

### 7.3. Model optymalizacyjny konstrukcji kadłuba statku

#### 7.3.1. Zmienne konstrukcyjne

Racjonalny wybór konkretnego zbioru zmiennych konstrukcyjnych wynika z przyjętych kryteriów optymalizacji oraz oczekiwanej dokładności (tzn. szczegółowości) rozwiązania. Przy ustalonych pozostałych elementach modelu optymalizacyjnego ma on decydujący wpływ na wielkość zadania optymalizacyjnego, a zatem także na niezbędny wysiłek obliczeniowy i szybkość obliczeń. W pracy przyjęto, że zmiennymi konstrukcyjnymi będą rozplanowanie przestrzenne elementów konstrukcyjnych (usztywnień wzdłużnych i ram poprzecznych), opisujące topologię konstrukcji, oraz cechy wyrobów hutniczych zastosowanych na elementy konstrukcyjne: grubość blach poszycia, wymiary kształtowników łebkowych na usztywnienia i profili teowych na usztywnienia ramowe, determinujących wymiary elementów konstrukcyjnych. Cechy wyrobów hutniczych są jednoznacznie identyfikowane na podstawie numerów w przyjętym katalogu (patrz załącznik C). W dokonanym wyborze utrzymano wartości zmiennych w określonych przedziałach odpowiednich katalogów wyrobów hutniczych, unikając w ten sposób sytuacji, w której łączny czas generowania wystarczającej liczby wariantów byłby trudny do zaakceptowania w praktyce. Listę zmiennych konstrukcyjnych opisujących model konstrukcji statku podano w tablicy 7.6. Wszystkie zmienne są bezwymiarowe i są liczbami całkowitymi.

W rezultacie w sformułowanym zadaniu optymalizacji KKSM występuje 37 zmiennych konstrukcyjnych. Każdy wariant konstrukcji jest reprezentowany jako punkt w 37-wymiarowej przestrzeni poszukiwań  $\Phi$  ( $n = 37$ ), rozpiętej na współrzędnych  $(x_1, x_2, \dots, x_{37})$ .

Przyjęcie zmiennych konstrukcyjnych, reprezentujących liczbę ram poprzecznych  $x_4$  oraz liczbę usztywnień wzdłużnych w poszczególnych rejonach ( $x_5, x_9, x_{13}, x_{17}, x_{21}, x_{25}, x_{29}, x_{33}, x_{37}$ ), umożliwia jednoczesną optymalizację topologii i wymiarów wiązań w częściowo zunifikowanym modelu optymalizacji topologii i wymiarów elementów konstrukcyjnych.

Liczba usztywnień i ram poprzecznych, zmieniająca się w procesie optymalizacji, określa odpowiednie odstępów ram poprzecznych, usztywnień wzdłużnych oraz rozpiętość usztywnień. Wymiary oraz ciężar elementów konstrukcyjnych: blach poszycia, usztywnień i ram są zatem bezpośrednio uzależnione od odstępów oraz rozpiętości ram i usztywnień, czyli od topologicznych cech konstrukcji.

Tablica 7.6. Zmienne konstrukcyjne opisujące przyjęty model konstrukcji kadłuba statku

| Oznaczenie | Opis                                                                    |
|------------|-------------------------------------------------------------------------|
| $x_1$      | numer blachy na poszycie międzypokładu                                  |
| $x_2$      | numer kształtownika łebkowego na usztywnienia międzypokładu             |
| $x_3$      | numer profilu teowego na ramy międzypokładu                             |
| $x_4$      | liczba ram poprzecznych                                                 |
| $x_5$      | liczba usztywnień wzdłużnych międzypokładu                              |
| $x_6$      | numer blachy na poszycie nadbudówki I kondygnacji                       |
| $x_7$      | numer kształtownika łebkowego na usztywnienia nadbudówki I kondygnacji  |
| $x_8$      | numer profilu teowego na ramy nadbudówki I kondygnacji                  |
| $x_9$      | liczba usztywnień wzdłużnych nadbudówki I kondygnacji                   |
| $x_{10}$   | numer blachy na poszycie burty wewnętrznej                              |
| $x_{11}$   | numer kształtownika łebkowego na usztywnienia burty wewnętrznej         |
| $x_{12}$   | numer profilu teowego na ramy burty wewnętrznej                         |
| $x_{13}$   | liczba usztywnień wzdłużnych burty wewnętrznej                          |
| $x_{14}$   | numer blachy na poszycie dna                                            |
| $x_{15}$   | numer kształtownika łebkowego na usztywnienia dna                       |
| $x_{16}$   | numer profilu teowego na ramy dna                                       |
| $x_{17}$   | liczba usztywnień wzdłużnych dna                                        |
| $x_{18}$   | numer blachy na poszycie burty zewnętrznej                              |
| $x_{19}$   | numer kształtownika łebkowego na usztywnienia burty zewnętrznej         |
| $x_{20}$   | numer profilu teowego na ramy burty zewnętrznej                         |
| $x_{21}$   | liczba usztywnień wzdłużnych burty zewnętrznej                          |
| $x_{22}$   | numer blachy na poszycie pokładu "mokrego"                              |
| $x_{23}$   | numer kształtownika łebkowego na usztywnienia pokładu "mokrego"         |
| $x_{24}$   | numer profilu teowego na ramy pokładu "mokrego"                         |
| $x_{25}$   | liczba usztywnień wzdłużnych pokładu "mokrego"                          |
| $x_{26}$   | numer blachy na poszycie pokładu samochodowego                          |
| $x_{27}$   | numer kształtownika łebkowego na usztywnienia pokładu samochodowego     |
| $x_{28}$   | numer profilu teowego na ramy pokładu samochodowego                     |
| $x_{29}$   | liczba usztywnień wzdłużnych pokładu samochodowego                      |
| $x_{30}$   | numer blachy na poszycie nadbudówki II kondygnacji                      |
| $x_{31}$   | numer kształtownika łebkowego na usztywnienia nadbudówki II kondygnacji |
| $x_{32}$   | numer profilu teowego na ramy nadbudówki II kondygnacji                 |
| $x_{33}$   | liczba usztywnień wzdłużnych nadbudówki II kondygnacji                  |
| $x_{34}$   | numer blachy na poszycie pokładu pasażerskiego                          |
| $x_{35}$   | numer kształtownika łebkowego na usztywnienia pokładu pasażerskiego     |
| $x_{36}$   | numer profilu teowego na ramy pokładu pasażerskiego                     |
| $x_{37}$   | liczba usztywnień wzdłużnych pokładu pasażerskiego                      |

Diagrama przedstawia przekrój poprzeczny kadłuba statku, który jest symetryczny względem osi pionowej. W centralnej części znajduje się pokład pasażerski, który jest otoczony przez pokład samochodowy i pokład "mokry". Poniżej pokładu "mokrego" znajduje się burt wewnętrzna, a na samym dole – dno. Po bokach kadłuba znajdują się nadbudówki I i II kondygnacji. Rama poprzeczna jest zaznaczona jako linia przerywana. Oznaczenia elementów konstrukcyjnych są następujące:

- pokład pasażerski:  $x_{34}, x_{35}, x_{36}, x_{37}$
- międzypokład:  $x_{11}, x_{21}, x_{31}, x_5$
- pokład samochodowy:  $x_{26}, x_{27}, x_{28}, x_{29}$
- pokład "mokry":  $x_{22}, x_{23}, x_{24}, x_{25}$
- burt wewnętrzna:  $x_{10}, x_{11}, x_{12}, x_{13}$
- dno:  $x_{14}, x_{15}, x_{16}, x_{17}$
- nadbudówka II:  $x_{30}, x_{31}, x_{32}, x_{33}$
- nadbudówka I:  $x_6, x_7, x_8, x_9$
- rama poprzeczna:  $x_4$
- burt zewnętrzna:  $x_{18}, x_{19}, x_{20}, x_{21}$

Optymalizując topologię konstrukcji kadłuba statku, rozwiązać trzeba trudny problem dotyczący zależności pomiędzy liczbą wzdłużnych i poprzecznych elementów konstrukcyjnych a ich wymiarami wpływającymi bezpośrednio na ciężar konstrukcji. Uwzględnić przy tym należy ograniczenia dotyczące procesów wytwórczych i wymagań funkcjonalnych stawianych statkowi, np. otwory komunikacyjne, podparcie gniazd kontenerów w przypadku kontenerowców (zazwyczaj przez wzdłużniki i denniki dna podwójnego) lub montaż podparć na wzdłużnikach w odstępach umożliwiających wjazd pojazdów w przypadku statków przystosowanych do przewozu pojazdów samochodowych.

### 7.3.2. Parametry modelu optymalizacyjnego

W pracy przyjęto, że istnieje zbiór wymiarów i charakterystyk modelu konstrukcji kadłuba statku wspólnych dla wariantów alternatywnych i istotnych dla wymaganego spełnienia założeń projektowych. Założono, że wielkości te są parametrami modelu optymalizacyjnego. Do zbioru parametrów włączono główne wymiary liniowe statku i charakterystyki geometryczne kadłuba. Podstawowe parametry modelu konstrukcji statku oraz ich wartości zestawiono w tablicy 7.1. Parametrami modelu optymalizacyjnego są również charakterystyki fizyczne i mechaniczne materiałów konstrukcyjnych, które zestawiono w tablicach 7.2 i 7.3. Są nimi także charakterystyki obciążeń konstrukcji omówione w podrozdziale 7.2.3., np. znacząca wysokość fali, profil żeglugi, wartości obciążeń od pojazdów.

### 7.3.3. Funkcja celu

Aby uwzględnić w analizie optymalizacyjnej zarówno subiektywną atrakcyjność wartości poszczególnych kryteriów oceny  $f_s$ , jak i dążenie do żądanej zbieżności algorytmu, kryteria optymalizacji sformułowano w postaci funkcji użyteczności poprzez wprowadzenie w miejsce kryteriów oceny  $f_s$  odpowiednich funkcji użyteczności  $u_s$ . Problem ten omówiono szczegółowo w podrozdziale 6.1.1. Tam też podano przyjęte postaci funkcji użyteczności  $u_s$ . Wykorzystując przyjęte funkcje użyteczności  $u_s$ , sformułowano zastępczą skalarną funkcję celu  $F(\mathbf{x})$  w postaci zależności (6.4). Dzięki wymaganiom postawionym wcześniej funkcjom użyteczności  $u_s$  sformułowana funkcja celu  $F(\mathbf{x})$ , określona w zbiorze wariantów  $V_x$ , jest miarą jakości poszczególnych wariantów  $\mathbf{x}$ . Miara ta ma następujące cechy: (1) jest funkcją liczbową, (2) wartości funkcji są nieujemne, (3) umożliwia jednoznaczne uporządkowanie wariantów wg wartości wybranych kryteriów oceny  $f_s$ , (4) jest funkcją ściśle monotoniczną – rosnącą wraz z oceną wariantów, (5) nie ma jednoznacznej interpretacji fizycznej lub ekonomicznej, (6) jest ważna jedynie w sformułowanym w pracy zadaniu wyboru wariantów niezdominowanych.

Przyjęcie postaci skalarnej funkcji celu  $F(\mathbf{x})$  jako kombinacji liniowej zadaniowych kryteriów optymalizacji  $f_s$  równoznaczne jest z przyjęciem addytywnego modelu funkcji celu, w którym niedostatek jednej właściwości może być skompensowany odpowiednim wzrostem innej właściwości, np. większy ciężar konstrukcji statku może być skompensowany większą niezawodnością, odpornością kolizyjną i in. Możliwe są również inne podejścia do agregacji funkcji celu – patrz np. Tarnowski (1997).

Wykorzystując przyjęte funkcje użyteczności  $u_s$  i współczynniki wagowe  $w_s$ , skalarne kryterium optymalizacji  $F$  sformułowano w postaci:



$$F(\mathbf{x}) = F(f_1(\mathbf{x}), f_2(\mathbf{x})) = w_1 u_1(\mathbf{x}) + w_2 u_2(\mathbf{x}) \rightarrow \max! \quad (7.5)$$

gdzie:  $w_1, w_2$  – współczynniki wagowe odpowiednich zadaniowych kryteriów optymalizacji  $f_1(\mathbf{x})$  i  $f_2(\mathbf{x})$ . Wartości tych współczynników określone będą według wybranej przez użytkownika jednej z przedstawionych w podrozdziale 4.3 strategii wyboru kryteriów optymalizacji.

### 7.3.4. Ograniczenia

Wprowadzenie ograniczeń projektowych, wynikających z rezultatów wcześniejszych faz projektowania, oraz ograniczeń wytrzymałości, lokalnej i ogólnej, pozwala uniknąć niepożądanych charakterystyk generowanych wariantów konstrukcji i rozróżnić warianty dopuszczalne i niedopuszczalne. Pozwala również wprowadzić miary stopnia dopuszczalności wariantów, uwzględniane w obliczeniach wartości funkcji przystosowania  $\mathcal{F}$ . Wśród wariantów dopuszczalnych poszukiwane będą również rozwiązania niezdominowane formujące w toku ewolucji zbiór  $\Psi_f$  przybliżający front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , będący rozwiązaniem wielokryterialnego zadania optymalizacji.

Tarnowski (2009) omawia wiele ograniczeń, które można uwzględnić w procesie optymalizacji. Są to na przykład grupy ograniczeń funkcjonalnych, niezawodnościowych, ergonomicznych oraz estetycznych. Pappas i Allentuch (1973) zaproponowali przyjęty przez autora system klasyfikacji ograniczeń: (1) ograniczenia zachowawcze sformułowane w celu uniknięcia przejścia konstrukcji w stany traktowane jako zniszczenie lub utrata cech funkcjonalnych; (2) ograniczenia brzegowe, kostkowe, określające zakres zmienności zmiennych konstrukcyjnych; (3) ograniczenia geometryczne, nakładające ograniczenia na zależności przestrzenne między zmiennymi konstrukcyjnymi.

Wynikające z wytrzymałości lokalnej i ogólnej ograniczenia zachowawcze sformułowano na podstawie przepisów klasyfikacyjnych BV (1995). Matematyczną realizację ograniczeń w postaci odpowiednich funkcji kar omówiono w podrozdziale 6.1.2. Funkcje kar dla wszystkich ograniczeń zapisano „jawnie” w kodzie programu komputerowego. Przepisy klasyfikacyjne nie dały podstaw do sformułowania ograniczeń brzegowych dotyczących wytrzymałości lokalnej i ogólnej. Wynikające z przepisów ograniczenia geometryczne, dotyczące wytrzymałości lokalnej i ogólnej, odnoszą się do wymiarów i proporcji wymiarowych przekrojów poprzecznych wiązarów i usztywnień. Ponieważ w badaniach przyjęto profile hutnicze o wymiarach ustalonych w katalogu producenta (załącznik C), nie sformułowano ograniczeń geometrycznych wynikających z wytrzymałości lokalnej i ogólnej.

Ograniczenia zachowawcze stanowią część zbioru ograniczeń nierównościowych  $g_f(\mathbf{x})$ ; są to:

– wymagana grubość płyty poszycia  $t_{j,rule}$ , określona na podstawie dopuszczalnego poziomu naprężeń normalnych przy zginaniu ciśnieniem działającym prostopadle do poszycia:

$$t_j - t_{j,rule} \geq 0 \quad (7.6)$$

gdzie:  $t_j$  – bieżąca wartość płyty poszycia w  $j$ -tym rejonie;

– wymagany wskaźnik wytrzymałości usztywnień przy zginaniu ciśnieniem prostopadłym do pasa współpracującego poszycia  $Z_{s,j,rule}$ :

$$Z_{s,j} - Z_{s,j,rule} \geq 0 \quad (7.7)$$

gdzie:  $Z_{s,j}$  – bieżąca wartość wskaźnika wytrzymałości usztywnienia w  $j$ -tym rejonie;

– wymagany wskaźnik wytrzymałości wiązarów przy zginaniu ciśnieniem prostopadłym do pasa współpracującego poszycia  $Z_{f,j,rule}$ :

$$Z_{f,j} - Z_{f,rule} \geq 0 \quad (7.8)$$

gdzie:  $Z_{f,j}$  – bieżąca wartość wskaźnika wytrzymałości wiązara w  $j$ -tym rejonie;

– wymagane pole poddawanego ścinaniu przekroju poprzecznego usztywnień  $A_{t,s,j,rule}$ :

$$A_{t,s,j} - A_{t,s,j,rule} \geq 0 \quad (7.9)$$

gdzie:  $A_{t,s,j}$  – bieżąca wartość pola przekroju poprzecznego usztywnienia w  $j$ -tym rejonie;

– wymagane pole poddawanego ścinaniu przekroju poprzecznego wiązarów  $A_{t,f,j,rule}$ :

$$A_{t,f,j} - A_{t,f,j,rule} \geq 0 \quad (7.10)$$

gdzie:  $A_{t,f,j}$  – bieżąca wartość pola powierzchni przekroju poprzecznego wiązarów w  $j$ -tym rejonie.

Ograniczenia kostkowe, matematycznie zdefiniowane jako ograniczenia nierównościowe  $g_j(\mathbf{x})$ , dla zmiennych konstrukcyjnych podano w tablicy 7.7. Odpowiadają one ograniczeniom zbioru wyrobów hutniczych w katalogach producentów. Zmniejszając zakres zmienności zmiennych konstrukcyjnych, reprezentujących wyroby hutnicze w katalogach, oparto się na doświadczeniu autora wyniesionym z obliczeń próbnych w celu osiągnięcia pożądanej zbieżności algorytmu. Ograniczenia kostkowe nałożono także na wartości zmiennej konstrukcyjnej  $x_4$ , reprezentującej liczbę ram poprzecznych, oraz na wartości zmiennych konstrukcyjnych  $x_5$ ,  $x_9$ ,  $x_{13}$ ,  $x_{17}$ ,  $x_{21}$ ,  $x_{25}$ ,  $x_{29}$ ,  $x_{33}$  i  $x_{37}$ , reprezentujących liczbę usztywnień wzdłużnych w poszczególnych rejonach konstrukcyjnych (tablice 7.6 i 7.7 oraz rysunek 7.3).

Dodatkowe ograniczenia geometryczne sformułowano na podstawie doświadczenia wynikającego z dobrej praktyki projektowania i budowy konstrukcji kadłuba statków; są to:

– założony związek pomiędzy grubością blachy a grubością środnika przyspawanego do niego wiązara:

$$t_j - t_{f,w,j} \geq 0 \quad (7.11)$$

gdzie:  $t_j$  – bieżąca wartość grubości płyty poszycia w  $j$ -tym rejonie,  $t_{f,w,j}$  – bieżąca wartość grubości środnika ramy w  $j$ -tym rejonie;

– założony związek pomiędzy grubością blachy a grubością środnika przyspawanego do niego usztywnienia:

$$t_j - t_{s,w,j} \geq 0 \quad (7.12)$$

gdzie:  $t_j$  – bieżąca wartość grubości płyty poszycia w  $j$ -tym rejonie,  $t_{s,w,j}$  – bieżąca wartość grubości środnika usztywnienia w  $j$ -tym rejonie;

– założona najmniejsza odległość pomiędzy sąsiednimi krawędziami mocników wiązarów:

$$l(x_4+1) - b_{f,j} \geq 0,3 \text{ m} \quad (7.13)$$


gdzie:  $b_{f,j}$  – bieżąca wartość szerokości mocnika wiązara w  $j$ -tym rejonie.

Ograniczenia te uzupełniają zbiór ograniczeń nierównościowych  $g_j(\mathbf{x})$ .

Tablica 7.7. Specyfikacja przyjętej bitowej reprezentacji zmiennych konstrukcyjnych modelu genetycznego konstrukcji kadłuba statku

| Oznaczenie<br>$x_i$               | Długość genu<br>$l_i$ | Wartość                    |                                               |                                                    |
|-----------------------------------|-----------------------|----------------------------|-----------------------------------------------|----------------------------------------------------|
|                                   |                       | najmniejsza<br>$x_{i,min}$ | największa<br>$x_{i,max}$                     | krok zmienności<br>(rozdzielczość)<br>$\Delta x_i$ |
| $x_1$                             | 4                     | 1                          | 10                                            | 0,60                                               |
| $x_2$                             | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_3$                             | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_4$                             | 3                     | 10                         | 16                                            | 0,86                                               |
| $x_5$                             | 4                     | 25                         | 40                                            | 1,00                                               |
| $x_6$                             | 4                     | 1                          | 10                                            | 0,60                                               |
| $x_7$                             | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_8$                             | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_9$                             | 3                     | 4                          | 11                                            | 1,00                                               |
| $x_{10}$                          | 4                     | 1                          | 10                                            | 0,60                                               |
| $x_{11}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{12}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{13}$                          | 3                     | 18                         | 25                                            | 0,73                                               |
| $x_{14}$                          | 4                     | 1                          | 12                                            | 0,73                                               |
| $x_{15}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{16}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{17}$                          | 4                     | 15                         | 25                                            | 0,67                                               |
| $x_{18}$                          | 4                     | 1                          | 12                                            | 0,73                                               |
| $x_{19}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{20}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{21}$                          | 4                     | 18                         | 33                                            | 1,00                                               |
| $x_{22}$                          | 4                     | 1                          | 12                                            | 0,73                                               |
| $x_{23}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{24}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{25}$                          | 4                     | 25                         | 40                                            | 1,00                                               |
| $x_{26}$                          | 4                     | 2                          | 12                                            | 0,67                                               |
| $x_{27}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{28}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{29}$                          | 4                     | 25                         | 40                                            | 1,00                                               |
| $x_{30}$                          | 4                     | 1                          | 10                                            | 0,60                                               |
| $x_{31}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{32}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{33}$                          | 3                     | 4                          | 11                                            | 1,00                                               |
| $x_{34}$                          | 4                     | 1                          | 10                                            | 0,60                                               |
| $x_{35}$                          | 3                     | 1                          | 7                                             | 0,86                                               |
| $x_{36}$                          | 4                     | 42                         | 52                                            | 0,67                                               |
| $x_{37}$                          | 4                     | 25                         | 40                                            | 1,00                                               |
| Długość chromosomu $l_{ch}$ : 135 |                       |                            | Liczba możliwych wariantów: $\approx 10^{38}$ |                                                    |

Objaśnienie symboli  $x_i$ , oznaczających zmienne konstrukcyjne podano w tablicy 7.6.



Rys. 7.3. Bitowa reprezentacja konstrukcji przyjętego modelu konstrukcji pokładu głównego statku

## 7.4. Genetyczny model optymalizacyjny konstrukcji kadłuba statku

### 7.4.1. Uwagi ogólne

Zdefiniowany w podrozdziale 7.3 model optymalizacyjny KKS nie może być bezpośrednio zastosowany do poszukiwania rozwiązań niezdominowanych, należących do zbiorów przybliżających  $\Psi_f$ , za pomocą optymalizatora realizującego algorytm genetyczny. Dlatego na jego podstawie sformułowano model genetyczny spełniający szczególne wymagania tego algorytmu. Model ten obejmuje:

- (a) zdefiniowanie struktury chromosomu,
- (b) sformułowanie funkcji przystosowania  $F(\mathbf{x}) \rightarrow \max!$ ,
- (c) zbudowanie operatorów genetycznych odpowiednich do zdefiniowanej struktury chromosomu i sformułowanego zadania optymalizacji,
- (d) wyspecyfikowanie parametrów sterujących symulacjami komputerowymi.

### 7.4.2. Struktura chromosomu

Algorytm genetyczny nie operuje bezpośrednio na zmiennych konstrukcyjnych, ale na ich zakodowanej reprezentacji zapisanej w chromosomie. Zdefiniowanie chromosomu wymaga określenia:

- (a) najmniejszej i największej wartości zmiennych konstrukcyjnych (fenotypów),

- (b) sposobu kodowania zmiennych konstrukcyjnych w chromosomie,
- (c) kolejności kodowania zmiennych konstrukcyjnych w chromosomie,
- (d) zdolności rozdzielczej kodowania zmiennych konstrukcyjnych,
- (e) liczby bitów kodujących wartości kolejnych zmiennych konstrukcyjnych.

Goldberg (1989), Bäck (1996), Michalewicz (1996), Haupt i Haupt (1998) podają schematy kodowania zmiennych, przyjmowane w zależności od typu zmiennych (np. zmienne liczbowe, drzewiaste). W pracy przyjęto kodowanie binarne, tradycyjnie stosowane w przypadku zmiennych liczbowych.

Kolejność kodowania zmiennych w chromosomie jest dowolna i nie wpływa na cechy obliczeniowe algorytmu, musi być jednak dokładnie określona dla poprawnego odcodowania chromosomu (genotypu) i wyznaczenia odpowiednich wartości zmiennych konstrukcyjnych (fenotypu). Przyjęta i podana w tablicy 7.7 kolejność kodowania zmiennych w chromosomie jest zgodna z przyjętą i przedstawioną w tablicy 7.6 kolejnością specyfikowania zmiennych konstrukcyjnych modelu optymalizacyjnego.

Zdolność rozdzielcza próbkowania przestrzeni wariantów oraz długości genów są ze sobą ściśle związane. Zdolność rozdzielcza określa gęstość próbkowania przestrzeni rozwiązań. Ponieważ zapis bitowy na łańcuchu o skończonej długości  $l_i$  pozwala na zakodowanie liczby o skończonej wartości, związek pomiędzy najmniejszą wartością  $x_{i,min}$  i największą wartością zmiennej  $x_{i,max}$ , długością chromosomu  $l_i$  i rozdzielczością  $\Delta x_i$  zapisano w postaci:

$$\Delta x_i = \frac{x_{i,max} - x_{i,min}}{2^{l_i} - 1} \quad (7.14)$$

Większa zdolność rozdzielcza pozwala przebadać więcej punktów przestrzeni rozwiązań, zwiększając prawdopodobieństwo wykrycia interesujących ekstremów. Jednak zwiększenie zdolności rozdzielczej, przy zachowaniu brzegowych wartości zmiennych  $x_{i,min}$  i  $x_{i,max}$ , pociąga za sobą konieczność zwiększenia długości genów  $l_i$  i odpowiednio długości chromosomu  $l_{ch} = \sum_{i=1}^n l_i$ , a w konsekwencji wydłużenie czasu potrzebnego na wykonanie operacji genetycznych i ostatecznie na wydłużenie czasu obliczeń optymalizacyjnych. Przyjęto więc najmniejsze długości genów umożliwiające osiągnięcie wymaganej zdolności rozdzielczej. W rozwiązywanym zadaniu zmienne konstrukcyjne są liczbami naturalnymi w określonym przedziale zmienności. W związku z tym najmniejsze i największe wartości zmiennych  $x_{i,min}$  i  $x_{i,max}$  oraz długości genów  $l_i$  dobrano tak, aby rozdzielczość  $\Delta x_i$  była nie większa od jedności (tablica 7.7). Brzegowe wartości zmiennych  $x_{i,min}$  i  $x_{i,max}$  ustalono na podstawie doświadczenia z obliczeń próbnych w taki sposób, aby uzyskać zadowalającą zbieżność algorytmu przy akceptowanym czasie obliczeń.

Ustalenie liczby bitów w chromosomie wymaga większej uwagi, zwłaszcza że większa liczba bitów wymaga większej pamięci komputera i dłuższego czasu obliczeń. Z tego powodu liczba genów (długość chromosomu) nie powinna być zbyt duża. Jednak większa długość chromosomu (przy ustalonej liczbie zmiennych konstrukcyjnych reprezentowanych przez geny, odcinki chromosomu) umożliwia próbkowanie przestrzeni rozwiązań z większą dokładnością. Dokładność ta nie może być jednak zbyt mała, ponieważ operatory mutacji i krzyżowania nie mogą pracować skutecznie na zbyt krótkich chromosomach, w związku

z czym rozdzielczość algorytmu byłaby zbyt mała. Kompromis pomiędzy wysiłkiem obliczeniowym a zdolnością rozdzielczą próbkowania przestrzeni rozwiązań powinien być określony przez użytkownika na podstawie jego własnego doświadczenia. Doświadczenie autora wskazuje, że w przypadku optymalizacji KKSM, w której czas pojedynczej symulacji jest bardzo długi, zdolność rozdzielcza powinna być ustalona na najmniejszym akceptowanym poziomie (krótki chromosom), pozwalającym skrócić czas obliczeń. Wymagania dotyczące pamięci mają dzisiaj znaczenie drugorzędne. Przegląd literatury i własne doświadczenie autora wskazują, że wystarczające jest kodowanie zmiennych decyzyjnych na odcinkach chromosomu o długości od 5 do 20 bitów.

Wariant (chromosom, osobnik w populacji, projekt, rozwiązanie) budowano, łącząc ciągi bitowe, tworzące geny reprezentujące każdą zmienną w łańcuch bitowy. Połączenie to nazywane jest agregacją łańcucha (ciągu) bitowego wariantu. W tablicy 7.7 zestawiono przyjęte długości łańcuchów reprezentujących odpowiednie zmienne  $x_i$ . W sumie łańcuch chromosomu  $l_{ch} = 135$  bitów. Przyjęta struktura chromosomu pozwala na wygenerowanie prawie  $10^{38}$  wariantów projektowych.

W celu przeprowadzenia analizy konstrukcji kadłuba chromosomy były odkodowywane z postaci binarnej do postaci liczb dziesiętnych w przyjętym wcześniej zakresie. Ponieważ w przyjętym schemacie kodowania rozdzielczości wartości  $\Delta x_i$  mogą być mniejsze od jedności, a wartości zmiennych decyzyjnych są kolejnymi liczbami naturalnymi w przyjętym przedziale, formułę odkodowania łańcucha binarnego (genotypu) w celu uzyskania wartości fizycznych zmiennych konstrukcyjnych (fenotypu) zapisano w postaci:

$$x_i = \text{INT}\left(x_{i,\min} + \frac{x_{i,\max} - x_{i,\min}}{2^{l_i} - 1} \sum_{j=1}^{l_i} b_{ij} 2^{j-1}\right), b_{ij} \in [0,1] \quad (7.15)$$

gdzie:  $x_i$  – wartość zmiennej konstrukcyjnej,  $x_{i,\min}$  i  $x_{i,\max}$  – najmniejsza i największa wartość zmiennej konstrukcyjnej  $x_i$ ,  $l_i$  – długość genu kodującego wartość zmiennej konstrukcyjnej  $x_i$ ,  $b_{ij}$  – wartość  $j$ -tego bitu w genie kodującym wartość zmiennej konstrukcyjnej  $x_i$ .

Przy zdefiniowanej strukturze chromosomu i formule odkodowania chromosomu przyjęty schemat kodowania jest nadmiarowy. Oznacza to, że niektórym różnym wartościom genotypu odpowiadają równe wartości fenotypu – zmiennych konstrukcyjnych.

W pracy tej przestrzeń możliwych rozwiązań jest przestrzenią możliwych wariantów przyjętego modelu KKSM. Model konstrukcji jest opisany (zidentyfikowany) jako zbiór 37 zmiennych konstrukcyjnych  $x_i$  opisanych wyżej. Każda z nich zapisywana (reprezentowana) jest jako ciąg bitów (0 lub 1). Na przykład model pokładu statku jest opisany jako zbiór pięciu zmiennych konstrukcyjnych:  $x_4, x_{26}, x_{27}, x_{28}, x_{29}$ , w sposób pokazany na rysunku 7.3.

### 7.4.3. Funkcja przystosowania

Uwzględniając przyjęte kryteria optymalizacji, sformułowane ograniczenia, wpływ szeregowania rozwiązań dopuszczalnych, licznika dominacji rozwiązań dopuszczalnych oraz odległości ocen rozwiązań niezdominowanych od oceny rozwiązania asymptotycznego na selekcję rozwiązań próbnych, generowanych przez narzędzie obliczeniowe, przyjęto kombinowaną funkcję przystosowania omówioną w podrozdziale 6.1.8, która w przypadku dwóch kryteriów optymalizacji przyjmuje postać:

$$F_j \equiv F(\mathbf{x}_j) = w_1 u_1(\mathbf{x}_j) + w_2 u_2(\mathbf{x}_j) + w_{rank} R_{fi}(\mathbf{x}_j) + w_{count} C_{fi}(\mathbf{x}_j) + w_{distance} [1 - d_{fi}(\mathbf{x}_j)] + \sum_{p=1}^P w_p P(\mathbf{x}_j)_p^p \quad (7.16)$$

*kombinowana funkcja przystosowania = kryteria oceny + szeregowanie +  
+ licznik dominacji + odległość od rozwiązania asymptotycznego + ograniczenia*

Wszystkie zastosowane oznaczenia zostały omówione powyżej. W zależności (7.16) wprowadzono wyraz  $[1 - d_{fi}(\mathbf{x}_j)]$ , w którym odejmuje się mierzoną w unormowanej przestrzeni ocen odległość od oceny rozwiązania asymptotycznego od jedności, ponieważ dla obu przyjętych kryteriów optymalizacji, które są kryteriami typu min!, ocena rozwiązania asymptotycznego leży w lewym dolnym narożniku kartezjańskiego układu współrzędnych, a funkcja przystosowania powinna promować najmniejszą odległość od niego.

#### 7.4.4. Archiwizacja rozwiązań niezdominowanych

Rozwiązania niezdominowane zapisywane są w osobnym zbiorze, stale uzupełnianym i aktualizowanym w trakcie symulacji. Oceny zarchiwizowanych rozwiązań tworzą osiągnięte w trakcie symulacji przybliżenie  $\Psi_f$  frontu ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Po zakończeniu symulacji warianty, których oceny należą do zbioru przybliżającego, zostaną przyjęte jako rozwiązanie sformułowanego zadania optymalizacji wielokryterialnej. Ze względu na wpływ przynależności rozwiązań do zbioru rozwiązań niezdominowanych na udział w selekcji zrealizowano strategię egalitarną, w której przynależność ta nie ma wpływu na tę selekcję.

#### 7.4.5. Operatory genetyczne

Opracowany ewolucyjny algorytm optymalizacyjny wykorzystuje jako solver algorytm genetyczny, który generuje (składa odcinki łańcuchów chromosomów pochodzących od osobników rodzicielskich i wprowadza w nich losowe mutacje) warianty nowego pokolenia, realizując podstawowe operatory selekcji, mutacji i krzyżowania oraz, dodatkowo, operator aktualizacji i strategię pretendenta omówione w podrozdziale 6.1.4, są to:

(a) selekcja proporcjonalna według procedury opisywanej jako symulowane koło ruletki, w której prawdopodobieństwo wyboru osobnika do dalszych operacji genetycznych jest wprost proporcjonalne do wartości kombinowanej funkcji przystosowania;

(b) mutacja bitowa polegająca na losowej zmianie, z prawdopodobieństwem określonym przez wartość parametru  $p_m$  nazywanego prawdopodobieństwem mutacji, bitów budujących łańcuch chromosomu kodującego zmienne konstrukcyjne;

(c) operator krzyżowania umożliwiający losową wymianę odcinków chromosomów wyselekcjonowanych osobników, zrealizowany w postaci  $n$ -punktowego losowego operatora krzyżowania; parametrami operatora krzyżowania są najmniejsza  $n\_x\_site\_min$  i największa  $n\_x\_site\_max$  liczba punktów krzyżowania i prawdopodobieństwo krzyżowania  $p_c$ ; operator ustala automatycznie, niezależnie dla każdej krzyżowanej, z prawdopodobieństwem  $p_c$ , pary

osobników, liczbę punktów krzyżowania  $n\_x\_site$ , która jest zmienną losową o rozkładzie jednostajnym w zadanym przedziale  $[n\_x\_site\_min, n\_x\_site\_max]$ ;

(d) operator aktualizowania z ustalonym prawdopodobieństwem aktualizowania  $p_u$ , który wprowadza losowo wybranego osobnika z populacji rodzicielskiej do populacji potomnej, w miejsce osobnika potomnego mniej przystosowanego;

(e) strategia pretendenta umożliwiająca skopiowanie, z prawdopodobieństwem określonym przez wartość parametru  $p_u$  nazywanego prawdopodobieństwem aktualizacji, ustalonej liczby  $n_p$  najlepiej przystosowanych osobników rodzicielskich (bez zmian) do pokolenia potomnego.

Wartości parametrów sterujących operatorami genetycznymi przedstawiono w tabelicy 7.8.

Tabela 7.8. Parametry sterujące przebiegiem wielokryterialnej optymalizacji genetycznej

| Oznaczenie        | Opis                                                                                                                                                                                                                                                                                                                                                                                                                                               | Wartość                       |
|-------------------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------|
| $n_{dv}$          | liczba zmiennych konstrukcyjnych (liczba genów)                                                                                                                                                                                                                                                                                                                                                                                                    | 37                            |
| $l_{ch}$          | długość chromosomu (liczba bitów)                                                                                                                                                                                                                                                                                                                                                                                                                  | 135                           |
| $n_g$             | liczba pokoleń (generacji)                                                                                                                                                                                                                                                                                                                                                                                                                         | ustalone dla każdej symulacji |
| $n_i$             | wielkość populacji (liczba osobników w populacji)                                                                                                                                                                                                                                                                                                                                                                                                  | ustalone dla każdej symulacji |
| $n_p$             | liczba pretendentów                                                                                                                                                                                                                                                                                                                                                                                                                                | 3                             |
| $p_m$             | prawdopodobieństwo mutacji                                                                                                                                                                                                                                                                                                                                                                                                                         | 0,066                         |
| $p_c$             | prawdopodobieństwo krzyżowania                                                                                                                                                                                                                                                                                                                                                                                                                     | 0,80                          |
| $c\_strategy$     | oznaczenie strategii krzyżowania ( $c\_strategy = 0$ dla ustalonej liczby punktów krzyżowania, $c\_strategy = 1$ dla losowej liczby punktów krzyżowania)                                                                                                                                                                                                                                                                                           | 1                             |
| $n\_x\_site\_min$ | najmniejsza liczba punktów krzyżowania                                                                                                                                                                                                                                                                                                                                                                                                             | 1                             |
| $n\_x\_site\_max$ | największa liczba punktów krzyżowania                                                                                                                                                                                                                                                                                                                                                                                                              | 7                             |
| $p_u$             | prawdopodobieństwo aktualizacji                                                                                                                                                                                                                                                                                                                                                                                                                    | 0,33                          |
| $elitism$         | zmienna logiczna do włączenia ( $elitism = yes$ ) lub wyłączenia ( $elitism = no$ ) strategii selekcji pretendenta                                                                                                                                                                                                                                                                                                                                 | yes                           |
| $\mu_{min}$       | wskaźnik dopuszczalności wariantów (rozwiązań próbnych)                                                                                                                                                                                                                                                                                                                                                                                            | 0,975                         |
| $w\_strategy$     | przełącznik wyboru strategii optymalizacji wielokryterialnej ( $w\_strategy = 1$ do wyłączenia kryteriów optymalizacji, $w_1 = w_2 = 0$ , $w\_strategy = 2$ do ustalonych przez użytkownika wartości współczynników wagowych $w_1$ i $w_2$ , $w\_strategy = 3$ do losowego wyboru jednego z kryteriów optymalizacji i wyłączenia pozostałych, $w\_strategy = 4$ do losowych wartości współczynników wagowych $w_1$ i $w_2$ w przedziale $[0, 1]$ ) | ustalone dla każdej symulacji |
| $w_1$             | współczynnik wagowy pierwszego kryterium optymalizacji                                                                                                                                                                                                                                                                                                                                                                                             | ustalone dla każdej symulacji |
| $w_2$             | współczynnik wagowy drugiego kryterium optymalizacji                                                                                                                                                                                                                                                                                                                                                                                               | ustalone dla każdej symulacji |
| $w_{rank}$        | współczynnik wagowy szeregowania rozwiązań niezdominowanych                                                                                                                                                                                                                                                                                                                                                                                        | ustalone dla każdej symulacji |
| $w_{count}$       | współczynnik wagowy licznika dominacji                                                                                                                                                                                                                                                                                                                                                                                                             | ustalone dla każdej symulacji |
| $w_{distance}$    | współczynnik wagowy odległości od oceny asymptotycznej                                                                                                                                                                                                                                                                                                                                                                                             | ustalone dla każdej symulacji |



#### 7.4.6. Parametry sterujące

Przy zdefiniowanym modelu genetycznym każdą symulację komputerową charakteryzują wartości 19 parametrów sterujących (tablica 7.8). Wartości tych parametrów mogą służyć także do identyfikacji poszczególnych symulacji.

Dla liczby pokoleń oraz wielkości populacji przyjęto największe dopuszczalne wartości ze względu na czas obliczeń. Przy ustalonej liczbie pokoleń i wielkości populacji wartości pozostałych parametrów sterujących ustalono na podstawie obliczeń testowych, kierując się zadowalającą zbieżnością algorytmu. Przyjęte parametry sterujące oraz ich wartości przedstawiono w tablicy 7.8.

Liczba zmiennych konstrukcyjnych  $n_{dv}$  wynika ze sformułowanego w podrozdziale 7.3 modelu optymalizacyjnego konstrukcji kadłuba statku, a w szczególności z przyjętego w podrozdziale 7.3.1 zbioru zmiennych konstrukcyjnych. Długość chromosomu  $l_{ch}$  wynika z przyjętej w podrozdziale 7.4.2 struktury chromosomu, a w szczególności z liczby zmiennych konstrukcyjnych oraz z przyjętej rozdzielczości zmiennych konstrukcyjnych. Liczbę pokoleń  $n_g$  oraz wielkość populacji  $n_i$  ustalono tak, aby czas trwania pojedynczej symulacji był akceptowany<sup>5</sup>. Liczbę pretendentów  $n_p$  przyjęto arbitralnie i nie badano jej wpływu na zbieżność algorytmu. Prawdopodobieństwo mutacji  $p_m$  oraz prawdopodobieństwo krzyżowania  $p_c$  przyjęto na poziomie zbliżonym do stosowanego przez innych autorów. Wartości tych prawdopodobieństw jednak zwiększono arbitralnie o ok. 30% w celu zwiększenia zdolności eksploracyjnych algorytmu. Najmniejszą i największą liczbę punktów krzyżowania ( $n\_x\_site\_min$  i  $n\_x\_site\_max$ ) przyjęto na podstawie obliczeń testowych wskazujących, że zwiększenie liczby punktów krzyżowania nie zwiększa skuteczności algorytmu. Prawdopodobieństwo aktualizacji  $p_u$  przyjęto arbitralnie, oczekując, że w trakcie symulacji zachowane zostaną wygenerowane rozwiązania o korzystnych charakterystykach. Wskaźnik dopuszczalności wariantów (rozwiązań próbnych)  $\mu_{min}$  dobrano na podstawie obliczeń testowych w taki sposób, aby liczba rozwiązań sklasyfikowanych jako dopuszczalne była uznana za dużą i aby jednocześnie stopień naruszenia sformułowanych ograniczeń był zbliżony do spotykanego w praktyce projektowej. Wartości pozostałych parametrów sterujących dla poszczególnych symulacji podano w podrozdziale 8.1 zawierającym plan symulacji komputerowych.

#### 7.5. Podsumowanie i wnioski

Jako przedmiot optymalizacji wielokryterialnej wybrano konstrukcję zlokalizowanej na śródkręciu sekcji przestrzennej kadłuba szybkiego promu pasażersko-samochodowego projektu Auto Express 82. Na podstawie dostępnej literatury technicznej zidentyfikowano charakterystyki techniczne i wymiary przestrzenne statku wzorcowego, podstawowe cechy konstrukcyjne oraz materiał konstrukcyjny. Na podstawie tych danych opracowano model konstrukcji statku w rejonie przyjętym do obliczeń optymalizacyjnych. Model konstrukcji posłużył do opracowania modelu optymalizacyjnego obejmującego: wyspecyfikowanie

---

<sup>5</sup> Kod źródłowy programu napisano w języku Fortran 90. Obliczenia uruchamiano na komputerze klasy PC z procesorem Intel Core Duo 3,33 MHz, zarządzanym przez system operacyjny Windows XP. Czas trwania pojedynczej symulacji ( $n_g = 5000$ ,  $n_i = 3000$ ) wynosił 24 h.

zmiennych konstrukcyjnych, sformułowanie funkcji celu, sformułowanie ograniczeń oraz wyspecyfikowanie parametrów optymalizacji. Model ten został następnie wykorzystany do opracowania genetycznego modelu optymalizacyjnego obejmującego: wyspecyfikowanie struktury chromosomu, sformułowanie funkcji przystosowania, opracowanie operatorów genetycznych, wyspecyfikowanie listy parametrów sterujących.

Kryteria wytrzymałościowe na potrzeby obliczeń grubości blach poszycia oraz wskaźnika wytrzymałości usztywnień i wiązarów sformułowano zgodnie z przepisami towarzystwa klasyfikacyjnego. Założono, że dno, pokład „mokry”, burta zewnętrzna oraz I i II kondygnacja nadbudówki poddawane są działaniu ciśnienia wody, o wartościach zależnych od szybkości eksploatacyjnej statku i rejonu żeglugi. W przypadku pokładu głównego założono obciążenie ciężarem samochodów ciężarowych wywieranym przez opony ciągników i naczip, w przypadku międzypokładu – obciążenie ciężarem samochodów osobowych, w przypadku pokładu górnego – obciążenie ciężarem wyposażenia i pasażerów. Wartości ciśnienia projektowego obliczane były zgodnie z procedurami zawartymi w przepisach towarzystwa klasyfikacyjnego.

Ciężar konstrukcji (objętość elementów konstrukcyjnych) i całkowite pole zewnętrznej powierzchni elementów konstrukcyjnych, którą należy oczyścić i zakonserwować, przyjęto jako kryteria optymalizacji i włączono do funkcji celu. Dzięki temu wartości funkcji celu zależą jedynie od geometrycznych cech konstrukcji (przy założeniu ustalonego materiału konstrukcyjnego). Ograniczenia wytrzymałościowe, reprezentowane przez składowe funkcji kary, włączone do rozszerzonej funkcji celu, sformułowano na podstawie przepisów towarzystwa klasyfikacyjnego.

Sformułowane zadanie optymalizacji wielokryterialnej można uznać za względnie mało skomplikowane, lecz podstawowym celem podjętej pracy badawczej było opracowanie metody umożliwiającej wielokryterialną optymalizację topologii i wymiarów elementów konstrukcyjnych kadłuba statku, a także zbadanie możliwości zastosowania ewolucyjnego algorytmu optymalizacji wielokryterialnej do rozwiązania zunifikowanego zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku na etapie projektowania wstępnego.

Można formułować tezę, że opracowanie modelu konstrukcji, przeznaczonego do ewolucyjnych obliczeń optymalizacyjnych, to bardzo ważny twórczy etap optymalizacji przebiegający w takich etapach, jak: (1) identyfikacja obiektu optymalizacji, w tym wypadku konstrukcji kadłuba statku morskiego; (2) opracowanie modelu konstrukcyjnego; (3) opracowanie modelu optymalizacyjnego; (4) opracowanie genetycznego modelu optymalizacyjnego.

Przedstawiony w niniejszym rozdziale model optymalizacyjny jest podstawą symulacji komputerowych omówionych w następnym rozdziale.

## 8. Symulacje komputerowe – poszukiwanie zbiorów przybliżających

### 8.1. Plan symulacji komputerowych

W celu potwierdzenia przydatności zaproponowanej metody i narzędzia obliczeniowego do poszukiwania zbiorów przybliżających  $\Psi_f$  front ocen optymalnych w sensie Pareto wariantów konstrukcji  $\Psi_P$ , sformułowanego i omówionego w rozdziale 7 zadania wielokryterialnej optymalizacji KKSM, przeprowadzono wiele symulacji komputerowych (tablica 8.1) na sformułowanych i omówionych w rozdziale 7 modelach konstrukcji kadłuba.

Tablica 8.1. Parametry sterujące w symulacjach komputerowych

| Symulacja<br>symi | Wartości parametrów sterujących<br>( $n_{dv}$ , $l_{ch}$ , $n_g$ , $n_i$ , $n_p$ , $p_m$ , $p_c$ , $c\_strategy$ , $n\_x\_site\_min$ , $n\_x\_site\_max$ , $p_u$ , $elitist$ ,<br>$\mu_{min}$ , $w\_strategy$ , $w_1$ , $w_2$ , $w_{rank}$ , $w_{count}$ , $w_{distance}$ ) |
|-------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Seria 1.          |                                                                                                                                                                                                                                                                             |
| sym1-1            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 2, 0,5, 0,5, 0,0, 0,0, 0,0)                                                                                                                                                                    |
| sym1-2            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 4, losowe w [0,1], losowe w [0,1], 0,0, 0,0, 0,0)                                                                                                                                              |
| sym1-3            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 3, losowe 0 lub 1, losowe 0 lub 1, 0,0, 0,0, 0,0)                                                                                                                                              |
| Seria 2.          |                                                                                                                                                                                                                                                                             |
| sym2-1            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 1, 0, 0, 3,0, 0,0, 0,0)                                                                                                                                                                        |
| sym2-2            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 1, 0, 0, 0,0, 3,0, 0,0)                                                                                                                                                                        |
| sym2-3            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 1, 0, 0, 0,0, 0,0, 3,0)                                                                                                                                                                        |
| Seria 3.          |                                                                                                                                                                                                                                                                             |
| sym3-i            | (37, 135, 10 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 4, losowe w [0,1], losowe w [0,1], 0,1, 0,1, 0,1), $i = 1, 2, \dots, 10$                                                                                                                       |
| Seria 4.          |                                                                                                                                                                                                                                                                             |
| sym1-2-50000      | (37, 135, 50 000, 5000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 4, losowe w [0,1], losowe w [0,1], 0,0, 0,0, 0,0)                                                                                                                                              |
| sym12-50000       | (37, 135, 50 000, 10 000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 4, losowe w [0,1], losowe w [0,1], 0,1, 0,1, 0,2)                                                                                                                                            |
| sym9-50000        | (37, 135, 50 000, 10 000, 10, 0,086, 0,800, 1, 1, 7, 0,33, <i>yes</i> , 0,975, 4, losowe w [0,1], losowe w [0,1], 1,0, 1,0, 1,0)                                                                                                                                            |

### Seria 1. Symulacje sym1–1, sym1–2 i sym1–3

Celem serii symulacji było poszukiwanie zbiorów przybliżających  $\Psi_f$  zawierających oceny wariantów niezdominowanych ze względu na dwa kryteria optymalizacji, przy zmiennych strategiach ustalania współczynników wagowych kryteriów oceny (tablica 8.1). W symulacji oznaczonej symbolem sym1–1 przyjęto ustalone dla całej symulacji wartości współczynników wagowych  $w_1 = 0,5$  oraz  $w_2 = 0,5$ ; odpowiada to klasycznej metodzie ważonych celów. W symulacji oznaczonej symbolem sym1–2 wartości współczynników wagowych  $w_1$  oraz  $w_2$  były generowane programowo jako zmienne losowe w przedziale  $[0, 1]$ , niezależnie dla każdego wariantu w każdym przypadku, gdy liczona była wartość funkcji przystosowania. W symulacji oznaczonej symbolem sym1–3 wartości współczynników wagowych  $w_1$  oraz  $w_2$  były generowane programowo jako zmienne losowe 0 lub 1, niezależnie dla każdego wariantu w każdym przypadku, gdy liczona była wartość funkcji przystosowania; wartość współczynnika wagowego równa jeden przyjmowana była tylko dla jednego wybranego losowo kryterium –  $f_1$  lub  $f_2$ ; dla pozostałych wartości współczynników była równa zero. We wszystkich symulacjach przyjęto równe zero ( $w_{rank} = w_{count} = w_{distance} = 0,0$ ) wartości współczynników wagowych szeregowania  $R_{fi}$  i licznika dominacji  $C_{fi}$ , a także odległości  $d_{fi}$  ocen rozwiązań niezdominowanych od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$ . Oznacza to wyłączenie z selekcji atrybutów dominacji wariantów w zbiorze dopuszczalnym oraz odległości od rozwiązania asymptotycznego.

We wszystkich symulacjach funkcje kar za naruszenie ograniczeń były aktywne ( $w_p \neq 0,0, \forall p = 1, 2, \dots, P$ ).

W każdej przeprowadzonej symulacji wartości funkcji przystosowania obliczane były  $5 \cdot 10^7$  razy.

### Seria 2. Symulacje sym2–1, sym2–2 i sym2–3

Celem serii symulacji było poszukiwanie zbiorów przybliżających  $\Psi_f$ , przy wyłączeniu bezpośredniego wpływu kryteriów optymalizacji na proces selekcji wariantów  $w_1 = w_2 = 0,0$ , która w poszczególnych symulacjach kierowana była jedynie przez: (1) wartość szeregowania wariantów dopuszczalnych  $R_{fi}$  ( $w_{rank} = 3,0, w_{count} = 0,0, w_{distance} = 0,0$ ) w symulacji sym2–1; (2) wartość licznika dominacji wariantów dopuszczalnych  $C_{fi}$  ( $w_{count} = 3,0, w_{rank} = 0,0, w_{distance} = 0,0$ ) w symulacji sym2–2; (3) odległość  $d_{fi}$  oceny wariantu dopuszczalnego od oceny asymptotycznej  $\mathbf{f}^*$  ( $w_{distance} = 3,0, w_{rank} = 0,0, w_{count} = 0,0$ ) w symulacji sym2–3 (tablica 8.1).

W poszczególnych symulacjach zbadano, czy opracowane narzędzie jest skuteczne w przypadku selekcji uwzględniającej jedynie<sup>1</sup> (1) szeregowanie, (2) licznik dominacji lub (3) odległość od rozwiązania asymptotycznego  $\mathbf{f}^*$ . Odpowiada to nowoczesnym algorytmom ewolucyjnej optymalizacji wielokryterialnej, w których ewolucja kierowana jest jedynie przez atrybuty dominacji.

We wszystkich symulacjach funkcje kar za naruszenie ograniczeń były aktywne ( $w_p \neq 0,0, \forall p = 1, 2, \dots, P$ ).

W każdej symulacji wartości funkcji przystosowania obliczane były  $5 \cdot 10^7$  razy.

### Seria 3. Symulacje od sym3–1 do sym3–10

Celem symulacji sym3– $i$ ,  $i = 1, 2, \dots, 10$  (tablica 8.1) było poszukiwanie zbiorów przybliżających  $\Psi_f$  zawierających oceny wariantów niezdominowanych pod względem

---

<sup>1</sup> poza składowymi funkcji kar za naruszenie ograniczeń.

dwóch kryteriów optymalizacji, przy wartościach współczynników wagowych  $w_1$  oraz  $w_2$ , generowanych programowo jako zmienne losowe, o rozkładzie jednostajnym w przedziale  $[0, 1]$ , niezależnie dla każdego wariantu w każdym przypadku, gdy liczona była wartość funkcji przystosowania. Dodatkowo do selekcji włączono atrybuty dominacji  $R_{fi}$  i  $C_{fi}$  oraz odległość  $d_{fi}$  od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$ . Wartości współczynników wagowych szeregowania  $w_{rank} = 0,1$ , licznika dominacji  $w_{count} = 0,1$  oraz odległości od oceny rozwiązania asymptotycznego  $w_{distance} = 0,2$  przyjęto na podstawie obliczeń testowych tak, aby odpowiednie składowe funkcji przystosowania były tego samego rzędu; dzięki temu ich wpływ na proces selekcji wariantów był zbliżony (żaden składnik nie dominował nad pozostałymi w funkcjach przystosowania). Oczywiście w każdym przypadku wartości poszczególnych składowych były zmiennymi losowymi określonymi przez charakterystyki losowo generowanych wariantów konstrukcji.

Przy ustalonych wartościach parametrów sterujących zróżnicowanie dziesięciu symulacji uzyskano, zmieniając wartość parametru startowego *iseed* wykorzystywanego w funkcji wewnętrznej użytego języka programowania, generującej liczby pseudolosowe, używanej w numerycznej symulacji procesów losowych.

Ta seria symulacji jest propozycją sposobu praktycznego wykorzystania zbudowanego narzędzia obliczeniowego do optymalizacji poprzez wielokrotne uruchamianie symulacji i przyjęcie jako wyniku zbioru rozwiązań niezdominowanych wybranego z sumy zbiorów rozwiązań niezdominowanych odszukanych we wszystkich symulacjach.

We wszystkich symulacjach funkcje kar za naruszenie ograniczeń były aktywne ( $w_p \neq 0,0, \forall p = 1, 2, \dots, P$ ).

Łącznie w dziesięciu symulacjach funkcja przystosowania obliczana była  $5 \cdot 10^8$  razy. Liczba symulacji  $i$  może być dowolna, w zależności od możliwości i potrzeb użytkownika.

#### **Seria 4. Symulacje sym1–2–50000, sym12–50000 i sym9–50000**

Celem serii było poszukiwanie zbiorów przybliżających  $\Psi_f$  w pojedynczych dużych symulacjach (tablica 8.1). Symulacje takie mogą być również przykładami praktycznego wykorzystania zbudowanego narzędzia obliczeniowego w sposób polegający na uruchomieniu zamiast serii symulacji o mniejszych rozmiarach, podobnie jak w serii symulacji sym3– $i$  (mniejszy wysiłek obliczeniowy w przypadku symulacji o mniejszych rozmiarach), jednej symulacji o większym rozmiarze (jedna symulacja przy większym wysiłku obliczeniowym) i takich samych wartościach pozostałych parametrów sterujących oraz przyjęciu jako wyniku zbioru przybliżającego wygenerowanego w tej jednej symulacji.

W symulacji sym1–2–50000 przyjęto taką samą, jak we wszystkich poprzednich symulacjach, liczbę osobników w populacji  $n_i = 5000$ , jednak ta symulacja trwała znacznie (pięciokrotnie) dłużej; liczba pokoleń  $n_g = 50\,000$ . Symulacją kierowały kryteria optymalizacji, wartości współczynników wagowych  $w_1$  oraz  $w_2$ , generowane programowo jako zmienne losowe o rozkładzie jednostajnym w przedziale  $[0, 1]$ , oraz składowe reprezentujące funkcje kary za naruszenie ograniczeń ( $w_p \neq 0,0, \forall p = 1, 2, \dots, P$ ). Z kierowania symulacją wyłączono atrybuty dominacji  $R_{fi}$ , ( $w_{rank} = 0,0$ ),  $C_{fi}$  ( $w_{count} = 0,0$ ), oraz odległość  $d_{fi}$  od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  ( $w_{distance} = 0,0$ ). W tej symulacji wartości funkcji przystosowania obliczane były  $2,5 \cdot 10^8$  razy.

W symulacji sym12–50000 przyjęto większą, niż we wszystkich poprzednich symulacjach, liczbę osobników w populacji  $n_i = 10\,000$ , zwiększając również liczbę pokoleń do  $n_g = 50\,000$ . Symulacją kierują kryteria optymalizacji, wartości współczynników wagowych  $w_1$  oraz  $w_2$ , generowane programowo jako zmienne losowe o rozkładzie jednostajnym w przedziale  $[0, 1]$ , składowe reprezentujące funkcje kary za naruszenie ograniczeń ( $w_p \neq 0, \forall p = 1, 2, \dots, P$ ) oraz atrybuty dominacji  $R_{fi}$  ( $w_{rank} = 0,1$ ),  $C_{fi}$  ( $w_{count} = 0,1$ ), a także odległość  $d_{fi}$  od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  ( $w_{distance} = 0,2$ ). W tej symulacji wartości funkcji przystosowania obliczane były  $5 \cdot 10^8$  razy. Liczba obliczeń wartości funkcji przystosowania w pojedynczej symulacji równa była liczbie obliczeń wartości funkcji przystosowania w serii dziesięciu symulacji sym3–i o mniejszych rozmiarach.

W symulacji sym9–50000 zachowano dużą liczbę osobników w populacji  $n_i = 10\,000$  oraz większą liczbę pokoleń  $n_g = 50\,000$ . Tak jak w symulacji poprzedniej symulacją kierują kryteria optymalizacji, wartości współczynników wagowych  $w_1$  oraz  $w_2$ , generowane programowo jako zmienne losowe o rozkładzie jednostajnym w przedziale  $[0, 1]$  oraz składowe reprezentujące funkcje kary za naruszenie ograniczeń ( $w_p \neq 0, \forall p = 1, 2, \dots, P$ ). Arbitralnie wzmocniono jednak wpływ atrybutów dominacji  $R_{fi}$  i  $C_{fi}$  oraz odległości  $d_{fi}$  od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  ( $w_{rank} = 1,0$ ,  $w_{count} = 1,0$ ,  $w_{distance} = 1,0$ ). W tej symulacji wartości funkcji przystosowania obliczane były  $5 \cdot 10^8$  razy. Liczba obliczeń wartości funkcji przystosowania w pojedynczej symulacji równa była liczbie obliczeń wartości funkcji przystosowania w serii dziesięciu symulacji sym3–i o mniejszych rozmiarach. Przeprowadzenie tej symulacji umożliwiło zbadanie wpływu wzmocnienia udziału atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego na jakość rezultatów symulacji.

We wszystkich symulacjach zbadano także: (1) ewolucję odległości od oceny rozwiązania asymptotycznego, (2) ewolucję szerokości zbioru ocen rozwiązań niezdominowanych oraz (3) ewolucję głębokości zbioru ocen rozwiązań niezdominowanych.

Symulacje przeprowadzono dla zadań dwukryterialnych, ponieważ w takich przypadkach istnieje możliwość wielorakiej prezentacji wyników w formie graficznej umożliwiającej ich interpretację i analizę.

## 8.2. Wyniki symulacji komputerowych


### 8.2.1. Seria 1.

Rezultaty pierwszej symulacji (sym1–1) przedstawiono najbardziej szczegółowo; omówiono wyniki charakterystyczne dla ewolucyjnej optymalizacji wielokryterialnej, a w szczególności dotyczące zaproponowanej metody. W przypadku pozostałych symulacji przedstawione zostaną tylko wyniki najważniejsze.

Na rysunkach 8.1 i D.1 (a) przedstawiono przebiegającą w trakcie symulacji sym1–1 ewolucję makroskopowych wielkości charakteryzujących generowane i oceniane populacje wariantów konstrukcji kadłuba statku: (1) największej wartości funkcji przystosowania  $f_{max}$ ,<sup>2</sup> (2) najmniejszej odległości oceny wariantu dopuszczalnego od oceny rozwiązania asymptotycznego, (3) szerokości zbioru przybliżającego oraz (4) głębokości zbioru przybliżającego.

---


<sup>2</sup> Największa wartość funkcji przystosowania wśród wartości tej funkcji osiągniętych dla wszystkich osobników w aktualnej populacji.



Rys. 8.1. Wynik ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, zrealizowanej podczas symulacji sym1-1; wartości bezwymiarowe są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odszukanych w trakcie symulacji

Na rysunkach widać pożądaną stałą wartość największej wartości funkcji przystosowania  $f_{max}$ , wskazującą na wzrost jakości najlepszych wygenerowanych wariantów próbnych. Największa wartość funkcji przystosowania nasycą się już w 1668. pokoleniu, co oznacza, że w kolejnych pokoleniach nie wygenerowano rozwiązania lepiej przystosowanego do przyjętej funkcji przystosowania i że wysiłek obliczeniowy został wykorzystany na odtwarzanie zbioru przybliżającego  $\Psi_{sym1-1}$ . Odległość zbioru przybliżającego  $\Psi_{sym1-1}$  (najmniejsza odległość oceny rozwiązania niezdominowanego w tym zbiorze) od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  zmienia się w trakcie ewolucji, lecz w niewielkim zakresie (powyżej 87,38%) wartości największej odszukanej w trakcie symulacji. Na przykład w 857. pokoleniu odległość oceny rozwiązania najbliższego ocenie rozwiązania asymptotycznego  $\mathbf{f}_{857}^*(\mathbf{x})$  wynosiła 1,114 – rysunek 8.2 (a) i (b), podczas gdy w kolejnym 858. pokoleniu odległość  $\mathbf{f}_{858}^*(\mathbf{x})$  zwiększyła się do 1,177 – rysunek 8.2 (c) i (d). W obu pokoleniach oceną najbliższą była ta sama ocena, a zmiana odległości od oceny rozwiązania asymptotycznego nastąpiła jedynie w wyniku zmiany struktury zbioru ocen rozwiązań niezdominowanych. Natomiast w 2156. pokoleniu odległość oceny najbliższego wariantu od oceny rozwiązania asymptotycznego  $\mathbf{f}_{2156}^*(\mathbf{x})$  wynosiła 1,187 – rysunek 8.3 (a) i (b), podczas gdy w kolejnym 2157. pokoleniu odległość ta  $\mathbf{f}_{2157}^*(\mathbf{x})$  zmniejszyła się do 1,087 – rysunek 8.3 (c) i (d). W tym przypadku zmiana struktury zbioru ocen rozwiązań niezdominowanych spowodowała, że inna, istniejąca dotychczas w tym zbiorze, ocena stała się oceną najbliższą ocenie rozwiązania asymptotycznego  $\mathbf{f}^*$ .

Na rysunkach 8.4 i E.1 przedstawiono ewolucję struktury zbioru przybliżającego  $\Psi_f$  konstrukcji kadłuba statku na przykładach sześciu przekrojów czasowych tego zbioru, tj. w 1., 2000., 4000., 6000., 8000. i 10 000. pokoleniu. Widoczne są systematyczny wzrost liczności zbioru (6, 6, 9, 12, 11 i 14 ocen rozwiązań niezdominowanych w kolejnych przekrojach czasowych) oraz pożądaną przesuwanie się tego zbioru w kierunku korzystniejszych, mniejszych, wartości kryteriów optymalizacji.




Rys. 8.2. Zmiana struktury zbioru przybliżającego  $\Psi_f$  przy przejściu od pokolenia 857. do pokolenia 858. w trakcie ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, zrealizowanej w symulacji sym1-1, przedstawiona odpowiednio w fizycznej (a), (c) i unormowanej przestrzeni ocen (b), (d); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny wariantów niezdominowanych najbliższe oceny asymptotycznej; wartości bezwymiarowe są standaryzowane w przedziale  $[0,1]$  względem największych wartości w zbiorze

Na rysunkach 8.5 (a) i (b) pokazano strukturę zbioru przybliżającego  $\Psi_{\text{sym1-1}}$ . Natomiast w tablicy 8.2 oraz na rysunkach G.1 (a) i (b) pokazano szczegółową strukturę tego zbioru. W symulacji wygenerowano zbiór rozwiązań niezdominowanych, zawierający 14 wariantów konstrukcji kadłuba statku. Generowanie wariantów niezdominowanych trwało przez cały czas symulacji, w związku z czym można przypuszczać, że jej przedłużenie zaowocowałoby wygenerowaniem również innych wariantów niezdominowanych. Dla każdego wariantu niezdominowanego podano wartości kryteriów optymalizacji – ciężaru konstrukcji  $f_1(\mathbf{x})$  i pola powierzchni do czyszczenia i malowania  $f_2(\mathbf{x})$ . Spośród nich projektant może wybrać jeden wariant lub większą liczbę wariantów.




tów uznanych przez niego za najlepsze i skierować je do dalszego projektowania w kolejnych fazach procesu. Dla wygenerowanego w 5116. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{5116}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,096$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1086,28$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7422,11$  m<sup>2</sup>. Wariant ten może być rekomendowany wówczas, gdy istnieje potrzeba wskazania jednego rozwiązania sformułowanego zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku:


$$\mathbf{f}_{\text{sym1-1}}^{\approx} = \mathbf{f}_{5116}^{\approx}(\mathbf{x}) = [f_{1,5116}^{\approx}(\mathbf{x}) \quad f_{2,5116}^{\approx}(\mathbf{x})]^T = [1086,28 \text{ kN} \quad 7422,11 \text{ m}^2]^T \quad (8.1)$$



Rys. 8.3. Zmiana struktury zbioru przybliżającego  $\Psi_f$  przy przejściu od pokolenia 2156. do pokolenia 2157. w trakcie ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, zrealizowanej w symulacji sym1-1, przedstawiona odpowiednio w fizycznej (a), (c) i unormowanej przestrzeni ocen (b), (d); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny wariantów niezdominowanych najbliższe oceny asymptotycznej; wartości bezwymiarowe są standaryzowane w przedziale  $[0,1]$  względem największych wartości w zbiorze




Rys. 8.4. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym1-1 przedstawiona na przykładzie sześciu wybranych pokoleń: 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny wariantów niezdominowanych najbliższe ocenie asymptotycznej  $\tilde{f}$



Rys. 8.5. Struktura zbiorów przybliżających  $\Psi_{\text{sym}i}$  wygenerowanych podczas symulacji sym1-1 (a) i (b), sym1-2 (c) i (d) oraz sym1-3 (e) i (f); wartości bezwymiarowe przedstawione na rysunkach (b), (d) i (f) są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odszukanych w trakcie symulacji

Tablica 8.2. Wynik ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku uzyskany podczas symulacji sym1–1. Szczegółowa specyfikacja zbioru przybliżającego  $\Psi_{\text{sym1-1}}$

| Warianty w zbiorze przybliżającym |             |                |                |              |
|-----------------------------------|-------------|----------------|----------------|--------------|
| nr pokolenia                      | nr osobnika | $f_1$          | $f_2$          | $d_{f_i}$    |
| 596                               | 4199        | 1233,45        | 7336,25        | 1,121        |
| 763                               | 4563        | 1261,80        | 7203,27        | 1,114        |
| 858                               | 325         | 1655,25        | 7139,30        | 1,219        |
| 1859                              | 911         | 1052,95        | 7601,65        | 1,109        |
| 2265                              | 2826        | 1423,81        | 7169,20        | 1,154        |
| 2568                              | 652         | 1070,91        | 7585,92        | 1,111        |
| 3929                              | 3527        | 1176,25        | 7351,07        | 1,109        |
| 4021                              | 4221        | 1627,94        | 7158,49        | 1,213        |
| <b>5116</b>                       | <b>1380</b> | <b>1086,28</b> | <b>7422,11</b> | <b>1,096</b> |
| 5441                              | 2673        | 2095,38        | 7026,13        | 1,355        |
| 7081                              | 1262        | 1675,43        | 7050,17        | 1,217        |
| 8051                              | 1491        | 1050,30        | 7688,47        | 1,119        |
| 8712                              | 1128        | 1293,97        | 7181,55        | 1,120        |
| 9390                              | 3064        | 1588,76        | 7162,20        | 1,201        |



$f_1, f_2$  – kryteria optymalizacji,  $d_{f_i}$  – odległość oceny od oceny asymptotycznej  $f^*$ ; na rysunkach (a) i (b) przedstawiono strukturę zbioru przybliżającego odpowiednio w fizycznej i unormowanej przestrzeni ocen; wartości bezwymiarowe są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odszukanych w trakcie symulacji. Pogrubioną czcionką wyróżniono ocenę wariantu najbliższego rozwiązaniu asymptotycznemu.

Autor uznał za interesujące zbadanie, w jaki sposób ewolucyjny algorytm optymalizacyjny buduje zbiór ocen rozwiązań niezdominowanych  $\Psi_f$ , stanowiący przybliżenie frontu Pareto  $\Psi_P$ . Czy słuszna jest, przedstawiona na rysunku 4.1 (a), hipoteza, że w trakcie ewolucji zbiór ocen rozwiązań dopuszczalnych  $\Phi_f$  przemieszcza się w kierunku oceny rozwiązania asymptotycznego  $\mathbf{f}^*$ , a zbiór  $\Psi_f$  ocen rozwiązań niezdominowanych, przybliżający front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , jest brzegiem zbioru ocen rozwiązań dopuszczalnych  $\Phi_f$ ? W skrajnym przypadku, po zakończeniu symulacji, wszystkie rozwiązania dopuszczalne będą rozwiązaniami niezdominowanymi. W celu zweryfikowania tej hipotezy na rysunku 8.6 przedstawiono zbiory ocen rozwiązań dopuszczalnych  $\Phi_f$  oraz zbiory przybliżające  $\Psi_f$  dla przekrojów czasowych odpowiadających sześciu pierwszym modyfikacjom zbioru przybliżającego  $\Psi_f$ , to znaczy dla: 1., 2., 3., 5., 6. i 7. pokolenia. Na rysunku 8.7 przedstawiono zbiory przybliżające  $\Psi_f$  dla przekrojów czasowych odpowiadających sześciu ostatnim modyfikacjom zbioru przybliżającego, to znaczy dla: 5441., 5882., 7081., 8051., 8712. i 9390. pokolenia. Modyfikacja zbioru przybliżającego przebiegała w sposób opisany w podrozdziale 6.1.5.


Wyniki przedstawione na rysunku 8.6 potwierdzają, zgodnie z rysunkiem 8.1, że w pierwszych pokoleniach algorytm bardzo intensywnie buduje zbiór przybliżający  $\Psi_f$ , praktycznie w każdym kolejnym pokoleniu nowa ocena zostaje włączona do zbioru przybliżającego. Zauważa się powolne oddalanie się zbioru przybliżającego od zbioru rozwiązań dopuszczalnych w kierunku początku układu współrzędnych, czyli w kierunku oceny rozwiązania asymptotycznego  $\mathbf{f}^*$ . Zbiór ocen rozwiązań dopuszczalnych  $\Phi_f$  nie zmienia swojego położenia w przestrzeni ocen; nie zmienia także rozpiętości w tej przestrzeni.

Rysunek 8.7 potwierdza bardzo powoli przebiegającą budowę zbioru przybliżającego w końcowych etapach symulacji; ewolucja przebiega bardzo powoli, a kolejno generowane warianty niezdominowane oddziela prawie 1000 pokoleń ewolucji symulowanej za pomocą algorytmu. Zbiór przybliżający  $\Psi_f$  oddzielił się już wyraźnie od zbioru ocen rozwiązań dopuszczalnych  $\Phi_f$ , a kolejno dołączane do niego rozwiązania niezdominowane pokonują w przestrzeni ocen  $V_f$  znaczącą odległość pomiędzy zbiorem przybliżającym a zbiorem dopuszczalnym<sup>3</sup>. Pokonywanie tak dużych odległości w przestrzeni ocen jest możliwe dzięki bardzo atrakcyjnym mutacjom w chromosomach osobników. Położenie zbioru dopuszczalnego i jego rozległość w przestrzeni ocen nie ulegają znacznym zmianom w toku ewolucji. Można dostrzec nieco większe skupienie zbioru przybliżającego w późnych etapach ewolucji (rysunek 8.7), jednak to, czy jest to efekt rzeczywisty czy pozorny, wymaga dalszych badań.


Zaprezentowane rezultaty ewolucji zbioru przybliżającego wskazują, że może ona przebiegać także w ten sposób, że zbiór ocen rozwiązań dopuszczalnych zachowa mniej więcej stałe położenie w przestrzeni ocen rozwiązań  $V_f$ , natomiast znajdowane kolejno rozwiązania niezdominowane będą jednostkowymi bardzo dobrymi rozwiązaniami odszukanymi w trakcie ewolucji symulowanej za pomocą algorytmu i utworzą zbiór przybliżający  $\Psi_f$  oddalający się w toku symulacji od zbioru ocen rozwiązań dopuszczalnych w kierunku ocen asymptotycznych.

---

<sup>3</sup> Pamiętajmy, że tak naprawdę nie ma dwóch osobnych zbiorów  $\Psi_f$  i  $\Phi_f$ . Wszystkie rozwiązania niezdominowane, których oceny należą do zbioru przybliżającego  $\Psi_f$ , są przecież rozwiązaniami dopuszczalnymi, a zatem  $\Psi_f \subset \Phi_f$ . W skrajnym przypadku, gdy wszystkie rozwiązania dopuszczalne są niezdominowane,  $\Psi_f = \Phi_f$ .



Rys. 8.6. Historia budowania zbioru przybliżającego  $\Psi_f$  w pierwszych sześciu przekrojach czasowych, tj. w pokoleniach 1. (a), 2. (b), 3. (c), 5. (d), 6. (e) i 7. (f), w których nastąpiła zmiana struktury zbioru ocen wariantów niezdominowanych podczas ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku zrealizowanej w symulacji sym1-1; koła oznaczają oceny wariantów dopuszczalnych, okręgi oznaczają oceny wariantów niezdominowanych; w przypadku pierwszego pokolenia dwa istniejące już warianty niezdominowane pochodzą z wygenerowanego losowo pokolenia początkowego



Rys. 8.7. Historia budowania zbioru przybliżającego  $\Psi_f$  w ostatnich sześciu przekrojach czasowych, tj. w pokoleniach 5441. (a), 5882. (b), 7081. (c), 8051. (d), 8712. (e) i 9390. (f), w których nastąpiła zmiana struktury zbioru ocen wariantów niezdominowanych podczas ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku zrealizowanej w symulacji sym1-1; koła oznaczają oceny wariantów dopuszczalnych, okręgi oznaczają oceny wariantów niezdominowanych

Taki sposób ewolucji autor proponuje nazwać skapywaniem, ponieważ przypomina spadanie kropeł deszczu z chmury na powierzchnię ziemi; w takim przypadku zbiór ocen zdominowanych rozwiązań dopuszczalnych reprezentuje chmurę deszczową, natomiast zbiór ocen rozwiązań niezdominowanych (zbiór przybliżający) reprezentuje krople, które spadły na powierzchnię ziemi. Autor nie zna prac innych badaczy wskazujących na podobny przebieg budowy zbioru przybliżającego  $\Psi_f$  w przestrzeni ocen  $V_f$ .

Na rysunkach D.1 (b) i (c) przedstawiono ewolucję makroskopowych wielkości charakteryzujących ewolucję populacji generowanych i ocenianych wariantów konstrukcji kadłuba statku w trakcie symulacji sym1–2 i sym1–3. Na zamieszczonych wykresach widać pożądaną stałą wzrost największej wartości funkcji przystosowania  $f_{max}$ , wskazujący na stały wzrost jakości najlepszych wygenerowanych wariantów próbnych. W przypadku symulacji sym1–2 największa wartość funkcji przystosowania nasycza się już w 1416. pokoleniu. Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 86,69% wartości największej odszukanej w trakcie symulacji. Następujące kolejno zmiany najmniejszej odległości od oceny rozwiązania asymptotycznego są nieznaczne. W przypadku symulacji sym1–3 na wykresie widać bardzo wczesne ustabilizowanie się największej wartości funkcji przystosowania  $f_{max}$  i jej gwałtowny wzrost do wartości nasycenia dopiero w 8888. pokoleniu. Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 88,30% wartości największej odszukanej w trakcie symulacji. Następujące kolejno zmiany najmniejszej odległości od oceny rozwiązania asymptotycznego są nieznaczne, z wyjątkiem zmian w 2006. pokoleniu (zwiększenie się odległości oceny rozwiązania najbliższego od oceny rozwiązania asymptotycznego) oraz w 3863. pokoleniu (zmniejszenie się odległości oceny rozwiązania najbliższego od oceny rozwiązania asymptotycznego).

Na rysunku E.2 przedstawiono ewolucję struktury zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym1–2 na przykładach przekrojów czasowych tego zbioru, tj. w 1., 2000., 4000., 6000., 8000. i 10 000. pokoleniu. Widoczny jest systematyczny wzrost liczności zbioru przybliżającego 8, 9, 13, 12, 10 i 8 ocen rozwiązań niezdominowanych w kolejnych przekrojach czasowych oraz pożądanę przesuwanie się tego zbioru w kierunku korzystniejszych wartości kryteriów optymalizacji. Na rysunku E.3 przedstawiono w tych samych przekrojach czasowych ewolucję struktury zbioru przybliżającego w trakcie symulacji sym1–3. Także w tym wypadku widoczny jest systematyczny wzrost liczności zbioru 6, 18, 12, 12, 11 i 15 ocen rozwiązań niezdominowanych w kolejnych przekrojach czasowych oraz pożądanę przesuwanie się tego zbioru w kierunku korzystniejszych wartości kryteriów optymalizacji.

Na rysunkach 8.5 (c) i (d) pokazano strukturę zbioru przybliżającego  $\Psi_{\text{sym1-2}}$ , wygenerowanego podczas symulacji sym1–2, przedstawioną w fizycznej przestrzeni ocen i unormowanej przestrzeni ocen. Na rysunkach G.1 (c) i (d) przedstawiono natomiast szczegółowo strukturę tego zbioru. Widać, że w trakcie symulacji odszukano zbiór przybliżający zawierający 8 wariantów konstrukcji kadłuba statku. W przypadku odszukanego w 6145. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{6145}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,088$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1113,66$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7361,45$  m<sup>2</sup>. Wariant ten może być rekomendowany jako



jedno rozwiązanie sformułowanego zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku:

$$\mathbf{f}_{\text{sym1-2}}^{\approx} = \mathbf{f}_{6145}^{\approx}(\mathbf{x}) = [f_{1,6145}^{\approx}(\mathbf{x}) \quad f_{2,6145}^{\approx}(\mathbf{x})]^T = [1113,66 \text{ kN} \quad 7361,45 \text{ m}^2]^T \quad (8.2)$$

Na rysunkach 8.5 (e) i (f) przedstawiono strukturę zbioru przybliżającego  $\Psi_{\text{sym1-3}}$  wygenerowanego w trakcie symulacji sym1–3. Szczegółowo strukturę tego zbioru pokazano natomiast na rysunkach G.2 (a) i (b). W trakcie symulacji odszukano zbiór przybliżający zawierający 15 wariantów konstrukcji kadłuba statku. Dla odszukanego w 7611. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{7611}^{\approx}(\mathbf{x})$  odległość  $d_{\hat{f}} = 1,123$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1153,68 \text{ kN}$ , pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7381,57 \text{ m}^2$ :


$$\mathbf{f}_{\text{sym1-3}}^{\approx} = \mathbf{f}_{7611}^{\approx}(\mathbf{x}) = [f_{1,7611}^{\approx}(\mathbf{x}) \quad f_{2,7611}^{\approx}(\mathbf{x})]^T = [1153,68 \text{ kN} \quad 7381,57 \text{ m}^2]^T \quad (8.3)$$

### 8.2.2. Seria 2.

Na rysunku D.2 zamieszczono wykresy przedstawiające ewolucję makroskopowych wielkości charakteryzujących ewolucję populacji wariantów konstrukcji kadłuba statku generowanych i ocenianych w trakcie symulacji sym2–1, sym2–2 i sym2–3. W przypadku symulacji sym2–1 – rysunek D.2 (a) – obserwuje się bardzo wczesne, już w 585. pokoleniu, nasycenie się największej wartości funkcji przystosowania  $f_{\text{max}}$ . Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego  $\mathbf{f}^{\approx}$  zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 79,42% wartości największej odszukanej w trakcie symulacji. Zmiany szerokości i głębokości zbioru przybliżającego w trakcie symulacji są również nieznaczne. W przypadku symulacji sym2–2 – rysunek D.2 (b) – widoczne jest późne, w 7301. pokoleniu, nasycenie się największej wartości funkcji przystosowania  $f_{\text{max}}$ . Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie. W przypadku symulacji sym2–3 – rysunek D.2 (c) – widoczne jest późne, w 5714. pokoleniu, nasycenie się największej wartości funkcji przystosowania  $f_{\text{max}}$ . Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 83,25% wartości największej odszukanej w trakcie symulacji. Zmiany szerokości i głębokości zbioru przybliżającego w trakcie symulacji są również nieznaczne.

Na rysunkach E.4, E.5 i E.6 przedstawiono ewolucję wygenerowanych w poszczególnych symulacjach zbiorów przybliżających na przykładach przekrojów czasowych w 1., 2000., 4000., 6000., 8000. i 10 000. pokoleniu. Widoczny jest systematyczny wzrost liczności zbiorów w kolejnych przekrojach oraz pożądane przesuwanie się tych zbiorów w kierunku korzystniejszych wartości kryteriów optymalizacji.

Na rysunku 8.8 przedstawiono strukturę zbiorów przybliżających  $\Psi_{\text{sym2-1}}$ ,  $\Psi_{\text{sym2-2}}$  i  $\Psi_{\text{sym2-3}}$ , uzyskanych odpowiednio w symulacjach sym2–1, sym2–2 i sym2–3. Szczegółowo strukturę tych zbiorów pokazano natomiast na rysunkach G.2 (c) i (d) oraz G.3.



Rys. 8.8. Struktura zbiorów przybliżających  $\Psi_{\text{symi}}$  wygenerowanych podczas symulacji sym2-1 (a) i (b), sym2-2 (c) i (d) oraz sym2-3 (e) i (f); wartości bezwymiarowe przedstawione na rysunkach (b), (d) i (f) są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odzyskanych w trakcie symulacji

W przypadku symulacji sym2–1 odszukano zbiór przybliżający  $\Psi_{\text{sym2-1}}$  zawierający 10 wariantów konstrukcji kadłuba statku. Dla odszukanego już w 196. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{196}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,064$  w unormowanej przestrzeni ocen wariantów, ciężar konstrukcji  $f_1(\mathbf{x}) = 1105,95$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7345,11$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym2-1}}^{\approx} = \mathbf{f}_{196}^{\approx}(\mathbf{x}) = [f_{1,196}^{\approx}(\mathbf{x}) \quad f_{2,196}^{\approx}(\mathbf{x})]^T = [1105,95 \text{ kN} \quad 7345,11 \text{ m}^2]^T \quad (8.4)$$

W trakcie symulacji sym2–2 odszukano zbiór przybliżający  $\Psi_{\text{sym2-2}}$  zawierający 13 wariantów konstrukcji kadłuba statku. Dla odszukanego w 5533. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{5533}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,047$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1192,04$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7327,41$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym2-2}}^{\approx} = \mathbf{f}_{5533}^{\approx}(\mathbf{x}) = [f_{1,5533}^{\approx}(\mathbf{x}) \quad f_{2,5533}^{\approx}(\mathbf{x})]^T = [1192,04 \text{ kN} \quad 7327,41 \text{ m}^2]^T \quad (8.5)$$

W trakcie symulacji sym2–3 odszukano zbiór przybliżający  $\Psi_{\text{sym2-3}}$  zawierający także 13 wariantów konstrukcji statku. Dla odszukanego w 5305. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{5305}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,085$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1060,03$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7485,93$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym2-3}}^{\approx} = \mathbf{f}_{5305}^{\approx}(\mathbf{x}) = [f_{1,5305}^{\approx}(\mathbf{x}) \quad f_{2,5305}^{\approx}(\mathbf{x})]^T = [1060,03 \text{ kN} \quad 7485,93 \text{ m}^2]^T \quad (8.6)$$

### 8.2.3. Seria 3.


Na rysunkach F.1 i F.2 przedstawiono strukturę dziesięciu zbiorów przybliżających  $\Psi_{\text{sym3-i}}$  wygenerowanych w serii symulacji od sym3–1 do sym3–10. W trakcie poszczególnych symulacji odszukano od 5 do 14 niezdominowanych wariantów konstrukcji kadłuba statku.

Z dziesięciu zbiorów przybliżających (od  $\Psi_{\text{sym3-1}}$  do  $\Psi_{\text{sym3-10}}$ ) wygenerowanych w trakcie poszczególnych symulacji zbudowano ich sumę, w której z kolei wyłoniono warianty niezdominowane. Strukturę takiego zbioru przybliżającego  $\Psi_{\text{sym3}}$  przedstawiono na rysunku 8.9 oraz szczegółowo na rysunkach G.4 (a) i (b). Zbiór ten można uznać za zbiór przybliżający, wygenerowany w serii dziesięciu symulacji sym3–i. Dla odszukanego w trakcie dziesięciu symulacji wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{\text{sym3-5}}^{\approx} = \mathbf{f}_{7847}^{\approx}(\mathbf{x})$ , odległość  $d_{fi} = 1,125$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1019,80$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7305,15$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym3}}^{\approx} = \mathbf{f}_{\text{sym3-5}}^{\approx} = \mathbf{f}_{7847}^{\approx}(\mathbf{x}) = [f_{1,7847}^{\approx}(\mathbf{x}) \quad f_{2,7847}^{\approx}(\mathbf{x})]^T = [1019,80 \text{ kN} \quad 7305,15 \text{ m}^2]^T \quad (8.7)$$

Seria przeprowadzonych symulacji pozwala wyraźnie dostrzec losowy charakter algorytmu optymalizacyjnego – w poszczególnych symulacjach uzyskano bardzo różne zbiory przybliżające  $\Psi_{\text{sym3-i}}$ . Stąd wniosek, że w przypadku ewolucyjnej optymalizacji wielokryterialnej nie można zakładać, że rozwiązania otrzymane w trakcie poszczególnych symulacji są najlepsze z możliwych rozwiązań sformułowanego zadania optymalizacji; są to jedynie najlepsze rozwiązania uzyskane w trakcie danej symulacji; obliczenia przeprowadzone

w trakcie innej symulacji, nawet przy niewielkiej zmianie wartości parametrów modelu optymalizacyjnego lub parametrów sterujących, pozwalają uzyskać inne rozwiązania, może nawet o korzystniejszych wartościach kryteriów optymalizacji  $f_s(\mathbf{x})$ .




Rys. 8.9. Struktura zbioru przybliżającego  $\Psi_{\text{symi}}$  uzyskanego w wyniku uruchomienia serii dziesięciu symulacji sym3-[1-10] przedstawiona w fizycznej (a) i unormowanej (b) przestrzeni ocen; wartości bezwymiarowe są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odszukanых w trakcie symulacji

#### 8.2.4. Seria 4.

Na rysunku D.3 przedstawiono ewolucję makroskopowych wielkości charakteryzujących ewolucję populacji generowanych i ocenianych wariantów konstrukcji kadłuba statku w trakcie symulacji sym1-2-50000, sym12-50000 i sym9-50000.

W przypadku sym1-2-50000 – rysunek D.3 (a) – widoczne jest powolne i długotrwałe nasycanie się największej wartości funkcji przystosowania  $f_{\text{max}}$ , osiągnięte dopiero w 40 528. pokoleniu. Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmieniała się w trakcie ewolucji w szerokim zakresie – powyżej 83,27% wartości największej odszukanej w trakcie symulacji. Zmiany szerokości i głębokości zbioru ocen rozwiązań niezdominowanych w trakcie symulacji także są znaczące. Również w przypadku sym12-50000 – rysunek D.3 (b) – widoczne jest powolne i długotrwałe nasycanie się największej wartości funkcji przystosowania  $f_{\text{max}}$ , osiągnięte dopiero w 44 660. pokoleniu. Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 88,73% wartości największej odszukanej w trakcie symulacji. Zmiany szerokości i głębokości zbioru ocen rozwiązań niezdominowanych w trakcie symulacji są również nieznaczne. W przypadku symulacji sym9-50000 – rysunek D.3 (c) – widoczne jest szybsze, niż w poprzednich symulacjach, nasycanie się największej wartości funkcji przystosowania  $f_{\text{max}}$ , osiągnięte już w 21 244. pokoleniu. Najmniejsza odległość oceny rozwiązania niezdominowanego od oceny rozwiązania asymptotycznego zmienia się w trakcie ewolucji, lecz w niewielkim zakresie – powyżej 91,86% wartości największej odszukanej w trakcie symulacji. Zmiany szerokości i głębokości zbioru ocen rozwiązań niezdominowanych w trakcie symulacji są również nieznaczne.



Rys. 8.10. Struktura zbiorów przybliżających  $\Psi_{\text{symi}}$  wygenerowanych podczas symulacji sym1–2–50000 (a) i (b), sym12–50000 (c) i (d) oraz sym9–50000 (e) i (f); wartości bezwymiarowe przedstawione na rysunkach (b), (d) i (f) są standaryzowane w przedziale  $[0, 1]$  względem największych wartości odszukanych w trakcie symulacji

Na rysunkach 8.10 (a) i (b) przedstawiono strukturę zbioru przybliżającego  $\Psi_{\text{sym1-2-50000}}$  wygenerowanego w trakcie symulacji sym1-2-50000; odszukano zbiór przybliżający zawierający 10 wariantów konstrukcji kadłuba statku. Na rysunkach G.4 (c) i (d) szczegółowo przedstawiono strukturę tego zbioru. Dla odszukanego w 45 020. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{45020}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,082$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1167,71$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7226,54$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym1-2-50000}}^{\approx} = \mathbf{f}_{45020}^{\approx}(\mathbf{x}) = [\mathbf{f}_{1,45020}^{\approx}(\mathbf{x}) \quad \mathbf{f}_{2,45020}^{\approx}(\mathbf{x})]^T = [1167,71 \text{ kN} \quad 7226,54 \text{ m}^2]^T \quad (8.8)$$

Na rysunkach 8.10 (c) i (d) oraz G.5 (a) i (b) przedstawiono strukturę zbioru przybliżającego  $\Psi_{\text{sym12-50000}}$  wygenerowanego w trakcie symulacji sym12-50000. Podczas symulacji odszukano zbiór przybliżający zawierający 17 wariantów konstrukcji kadłuba statku. Dla odszukanego w 24 561. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{24561}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,089$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1128,18$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7229,02$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym12-50000}}^{\approx} = \mathbf{f}_{24561}^{\approx}(\mathbf{x}) = [f_{1,24561}^{\approx}(\mathbf{x}) \quad f_{2,24561}^{\approx}(\mathbf{x})]^T = [1128,18 \text{ kN} \quad 7229,02 \text{ m}^2]^T \quad (8.9)$$

Na rysunkach 8.10 (e) i (f) oraz G.5 (c) i (d) przedstawiono strukturę zbioru przybliżającego  $\Psi_{\text{sym9-50000}}$  wygenerowanego w trakcie symulacji sym9-50000. Podczas symulacji zbudowano zbiór przybliżający zawierający 14 wariantów konstrukcji kadłuba statku. Dla odszukanego w 33 555. pokoleniu wariantu najbliższego rozwiązaniu asymptotycznemu  $\mathbf{f}_{33555}^{\approx}(\mathbf{x})$  odległość  $d_{fi} = 1,107$  w unormowanej przestrzeni ocen, ciężar konstrukcji  $f_1(\mathbf{x}) = 1124,65$  kN, pole powierzchni do czyszczenia i malowania  $f_2(\mathbf{x}) = 7303,18$  m<sup>2</sup>:

$$\mathbf{f}_{\text{sym9-50000}}^{\approx} = \mathbf{f}_{33555}^{\approx}(\mathbf{x}) = [f_{1,33555}^{\approx}(\mathbf{x}) \quad f_{2,33555}^{\approx}(\mathbf{x})]^T = [1124,65 \text{ kN} \quad 7303,18 \text{ m}^2]^T \quad (8.10)$$

### 8.3. Analiza wyników

Rezultatem przeprowadzenia serii symulacji komputerowych są zbiory ocen rozwiązań niezdominowanych, szczegółowo przedstawione w załączniku G, będące osiągnięciami podczas symulacji przybliżeniami  $\Psi_f$  zbiorów ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Zbiory te mogą być przyjęte jako rozwiązanie sformułowanego w pracy zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku morskiego. Warianty konstrukcji należące do zbiorów przybliżających  $\Psi_f$  mogą stanowić założenie podczas podejmowania decyzji projektowej, to znaczy podczas wyboru jednego lub kilku wariantów do dalszych prac projektowych. Analizie jakości uzyskanych zbiorów przybliżających poświęcony będzie następny rozdział. W przypadku, gdy projektant oczekuje wskazania jednego rozwiązania zadania optymalizacji wielokryterialnej, można zaproponować wygenerowane w trakcie poszczególnych symulacji rozwiązanie niezdominowane najbliższe rozwiązaniu asymptotycznemu  $\mathbf{f}^{\approx}$  (tablica 8.3). Oczywiście wybór któregoś z wariantów najbliższych musi być oparty na innych przesłankach nie zapisanych w modelu obliczeniowym. Decydent wprowadza więc do zadania nowe kryteria, może nawet ściśle niezdefiniowane (np. estetyki, łatwości montażu). Przed podjęciem decyzji musi jednak „zobaczyć” rozwiązanie w przestrzeni zmiennych konstrukcyjnych.

Tablica 8.3. Wynik ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku pod względem ciężaru konstrukcji  $f_1$  i pola powierzchni do malowania i konserwacji  $f_2$ . Specyfikacja rozwiązań najbliższych rozwiązaniu asymptotycznemu  $\mathbf{f}^*$ , wygenerowanych w trakcie poszczególnych symulacji komputerowych  $\text{sym}i$

| Symulacja $\text{sym}i$ | Rozwiązania najbliższe rozwiązaniu asymptotycznemu                                                                                                                                    |
|-------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Seria 1.                |                                                                                                                                                                                       |
| $\text{sym}1-1$         | $\mathbf{f}_{\text{sym}1-1}^* = \mathbf{f}_{5116}^* (\mathbf{x}) = [f_{1,5116}^* (\mathbf{x}) \ f_{2,5116}^* (\mathbf{x})]^T = [1086,28 \text{ kN} \ 7422,11 \text{ m}^2]^T$          |
| $\text{sym}1-2$         | $\mathbf{f}_{\text{sym}1-2}^* = \mathbf{f}_{6145}^* (\mathbf{x}) = [f_{1,6145}^* (\mathbf{x}) \ f_{2,6145}^* (\mathbf{x})]^T = [1113,65 \text{ kN} \ 7361,45 \text{ m}^2]^T$          |
| $\text{sym}1-3$         | $\mathbf{f}_{\text{sym}1-3}^* = \mathbf{f}_{7611}^* (\mathbf{x}) = [f_{1,7611}^* (\mathbf{x}) \ f_{2,7611}^* (\mathbf{x})]^T = [1153,68 \text{ kN} \ 7381,57 \text{ m}^2]^T$          |
| Seria 2.                |                                                                                                                                                                                       |
| $\text{sym}2-1$         | $\mathbf{f}_{\text{sym}2-1}^* = \mathbf{f}_{196}^* (\mathbf{x}) = [f_{1,196}^* (\mathbf{x}) \ f_{2,196}^* (\mathbf{x})]^T = [1105,95 \text{ kN} \ 7345,11 \text{ m}^2]^T$             |
| $\text{sym}2-2$         | $\mathbf{f}_{\text{sym}2-2}^* = \mathbf{f}_{5533}^* (\mathbf{x}) = [f_{1,5533}^* (\mathbf{x}) \ f_{2,5533}^* (\mathbf{x})]^T = [1192,04 \text{ kN} \ 7327,41 \text{ m}^2]^T$          |
| $\text{sym}2-3$         | $\mathbf{f}_{\text{sym}2-3}^* = \mathbf{f}_{5305}^* (\mathbf{x}) = [f_{1,5305}^* (\mathbf{x}) \ f_{2,5305}^* (\mathbf{x})]^T = [1060,03 \text{ kN} \ 7485,93 \text{ m}^2]^T$          |
| Seria 3.                |                                                                                                                                                                                       |
| $\text{sym}3-i$         | $\mathbf{f}_{\text{sym}3-5}^* = \mathbf{f}_{7847}^* (\mathbf{x}) = [f_{1,7847}^* (\mathbf{x}) \ f_{2,7847}^* (\mathbf{x})]^T = [1019,80 \text{ kN} \ 7305,15 \text{ m}^2]^T$          |
| Seria 4.                |                                                                                                                                                                                       |
| $\text{sym}1-2-50000$   | $\mathbf{f}_{\text{sym}1-2-50000}^* = \mathbf{f}_{45020}^* (\mathbf{x}) = [f_{1,45020}^* (\mathbf{x}) \ f_{2,45020}^* (\mathbf{x})]^T = [1167,71 \text{ kN} \ 7226,54 \text{ m}^2]^T$ |
| $\text{sym}12-50000$    | $\mathbf{f}_{\text{sym}12-50000}^* = \mathbf{f}_{24561}^* (\mathbf{x}) = [f_{1,24561}^* (\mathbf{x}) \ f_{2,24561}^* (\mathbf{x})]^T = [1128,18 \text{ kN} \ 7229,02 \text{ m}^2]^T$  |
| $\text{sym}9-50000$     | $\mathbf{f}_{\text{sym}9-50000}^* = \mathbf{f}_{33555}^* (\mathbf{x}) = [f_{1,33555}^* (\mathbf{x}) \ f_{2,33555}^* (\mathbf{x})]^T = [1124,65 \text{ kN} \ 7303,18 \text{ m}^2]^T$   |


Można jednak postawić pytanie: W jaki sposób wybrać jedno lub więcej rozwiązań niezdominowanych na podstawie zbiorów przybliżających  $\Psi_f$  wygenerowanych w trakcie skończonej liczby symulacji? Weźmy na przykład serię 1. (symulacje  $\text{sym}1-1$ ,  $\text{sym}1-2$  i  $\text{sym}1-3$ ), w której wygenerowano następujące rozwiązania najbliższe rozwiązaniu asymptotycznemu  $\mathbf{f}^*$ :

- (a)  $\mathbf{f}_{\text{sym}1-1}^*: f_1(\mathbf{x}) = 1086,28 \text{ kN}, f_2(\mathbf{x}) = 7422,11 \text{ m}^2$ ,
- (b)  $\mathbf{f}_{\text{sym}1-2}^*: f_1(\mathbf{x}) = 1113,65 \text{ kN}, f_2(\mathbf{x}) = 7361,45 \text{ m}^2$ ,
- (c)  $\mathbf{f}_{\text{sym}1-3}^*: f_1(\mathbf{x}) = 1153,68 \text{ kN}, f_2(\mathbf{x}) = 7381,57 \text{ m}^2$ .

Które z nich można rekomendować jako najlepsze?<sup>4</sup> Autor w tym miejscu sugeruje następujące postępowanie: Uzyskane w trakcie symulacji  $\text{sym}1-1$ ,  $\text{sym}1-2$  i  $\text{sym}1-3$  w serii 1. zbiory przybliżające  $\Psi_{\text{sym}1-1}$ ,  $\Psi_{\text{sym}1-2}$  i  $\Psi_{\text{sym}1-3}$  można zsumować i zbudować w ten sposób tymczasowy zbiór ocen rozwiązań pokazany na rysunku 8.11 (a). W zbiorze tym tylko niektóre oceny rozwiązań są ocenami niezdominowanymi i te właśnie oceny wchodziły w skład nowego zbioru przybliżającego  $\Psi_{\text{sym}1}$  – rysunek 8.11 (b). W zbudowanym na podstawie rezultatów trzech symulacji zbiorze przybliżającym  $\Psi_{\text{sym}1}$ , zawierającym 15 ocen rozwiązań niezdominowanych, można określić odległość każdego z nich od oceny rozwiązania asymptotycznego w unormowanej przestrzeni ocen – rysunek 8.11 (c). Najmniejszą odległość  $d_{f_i} = 1,082$  uzyskano dla oceny  $\mathbf{f}_{\text{sym}1-2}^*: f_1(\mathbf{x}) = 1113,65 \text{ kN}$  i  $f_2(\mathbf{x}) = 7361,45 \text{ m}^2$ , od-

<sup>4</sup> Pamiętajmy, że w przypadku optymalizacji wielokryterialnej nie ma jednego najlepszego rozwiązania zadania, a sformułowana rekomendacja powinna być traktowana jako subiektywny wybór decydenta.

szukanej w symulacji sym1–2 (losowe wartości współczynników wagowych  $w_1$  i  $w_2$  w przedziale  $[0, 1]$ ). Rozwiązanie to można rekomendować (przy założeniu, że odległość od oceny rozwiązania asymptotycznego jest miarą jakości) na podstawie trzech symulacji przeprowadzonych w serii 1. jako rozwiązanie sformułowanego zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku.




Rys. 8.11. Ilustracja wyboru jednego rekomendowanego wariantu na podstawie zbiorów przybliżających wygenerowanych w serii 1. trzech symulacji komputerowych; (a) suma trzech zbiorów przybliżających, (b) oceny wariantów niezdominowanych wyłonięnych z trzech zbiorów przybliżających, (c) odległości ocen wyłonięnych wariantów od oceny rozwiązania asymptotycznego w unormowanej przestrzeni ocen, (d) odległość oceny wariantu najbliższego ocenie rozwiązania asymptotycznego w unormowanej przestrzeni ocen

W taki sam sposób postępowano również w przypadku pozostałych serii symulacji, a rezultaty przedstawiono na rysunku H.1 dotyczącym serii 2., na rysunku H.2 dotyczącym serii 3. oraz na rysunku H.3 dotyczącym serii 4.

Przeprowadzone symulacje komputerowe potwierdziły skuteczność opracowanej metody oraz zbudowanego narzędzia obliczeniowego w rozwiązywaniu sformułowanego zadania



nia wielokryterialnej optymalizacji KKSM, unifikującego zadania optymalizacji topologii i wymiarów elementów konstrukcyjnych. Poszczególne symulacje komputerowe pozwoliły odszukać kilkanaście rozwiązań niezdominowanych, których oceny stanowią zbiory przybliżające  $\Psi_f$  front ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Spośród odszukanych rozwiązań decydent może wybrać wariant lub warianty do dalszych prac w kolejnych etapach procesu projektowania. Opracowany algorytm pozwala również wskazać w rezultacie każdej symulacji jeden wariant, którego ocena jest najbliższa ocenie asymptotycznej  $\mathbf{f}^*$ . Wariant ten może być przyjęty jako rozwiązanie zadania optymalizacji wielokryterialnej. Wszystkie przeprowadzone symulacje wskazują, że najlepszym rozwiązaniem jest rozwiązanie o następujących wartościach ocen:  $f_1(\mathbf{x}) = 1019,80 \text{ kN}$ ,  $f_2(\mathbf{x}) = 7305,15 \text{ m}^2$ , odszukane w trakcie serii dziesięciu symulacji sym3-*i*. Na rysunku 8.12 przedstawiono wymiary wiązań konstrukcji tego wariantu.



Rys. 8.12. Wymiary konstrukcji kadłuba statku uzyskane w rezultacie w serii 3. dziesięciu symulacji sym3-*i* ewolucyjnej optymalizacji wielokryterialnej konstrukcji statku pod względem ciężaru konstrukcji  $f_1$  i pola powierzchni do malowania i konserwacji  $f_2$ ; model materiałowy konstrukcji – stop aluminium 5083 na blachy poszycia stop 6082 na profile wyciskane

Rezultaty uzyskane w serii 1. trzech symulacji (sym1-1, sym1-2 i sym1-3) nie umożliwiają jednoznacznego stwierdzenia przewagi którejś ze zbadanych strategii agregacji funkcji celu<sup>5</sup>, jednak kształty uzyskanych zbiorów przybliżających  $\Psi_{\text{sym1-1}}$ ,  $\Psi_{\text{sym1-2}}$  oraz  $\Psi_{\text{sym1-3}}$  sugerują przewagę strategii z losowymi wartościami współczynników wagowych  $w_s$  kryteriów optymalizacji (sym1-2) oraz wskazują na najmniejszą skuteczność strategii z ustalonymi wartościami współczynników wagowych  $w_s$  (sym1-1). Skuteczność strategii z losowym

<sup>5</sup> Przeprowadzona w rozdziale 5 dyskusja, dotycząca problemu oceny jakości zbiorów przybliżających oraz skuteczności algorytmów, wskazuje, że stwierdzenie takie w ogóle nie jest możliwe.

wyborem pojedynczych kryteriów optymalizacji w procesie selekcji (sym1–3) jest pośrednia pomiędzy skutecznością strategii zrealizowanej w symulacjach sym1–1 i sym1–2. Okazuje się również, że w przypadku zadań z ograniczeniami składowe funkcji kar za naruszenie ograniczeń wnoszą losowy wkład do funkcji przystosowania, powodując, że strategia z ustalonymi wartościami współczynników wagowych  $w_s$  (sym1–1) staje się strategią zbliżoną do dwu pozostałych i także ona pozwala wygenerować zbiór przybliżający o zadowalającej jakości.

Podobnie w przypadku zrealizowanych w trakcie serii 2. (symulacje sym2–1, sym2–2 i sym2–3) strategii włączających do procesu selekcji atrybuty dominacji i odległość od oceny rozwiązania asymptotycznego, przy jednoczesnym wyłączeniu kryteriów optymalizacji, otrzymane rezultaty nie są rozstrzygające o wyborze strategii. Wyniki symulacji komputerowych zdają się wskazywać na przewagę strategii, w której selekcja wariantów kierowana jest przede wszystkim przez szeregowanie wariantów promujące warianty dopuszczalne leżące w pobliżu zbioru przybliżającego  $\Psi_f$ , zwiększając tym samym eksploatacyjne możliwości algorytmu. Zwiększenie w trakcie selekcji wpływu licznika dominacji, promującego warianty dopuszczalne odległe od zbioru przybliżającego  $\Psi_f$ , oraz odległości od oceny rozwiązania asymptotycznego  $\tilde{\mathbf{f}}$  nie pozwala na uzyskanie lepszego rozwiązania.

Przeprowadzenie w serii 3. dziesięciu symulacji sym3– $i$ , o wymiarach takich jak w poprzednich seriach, pozwala uzyskać zbiór przybliżający  $\Psi_{\text{sym3}}$  o większym skupieniu, w pobliżu oceny rozwiązania asymptotycznego  $\tilde{\mathbf{f}}$ .

Rezultaty przeprowadzenia dużych symulacji w ramach serii 4. (sym1–2–50000, sym12–50000 i sym9–50000) nie dają podstaw do jednoznacznego rozstrzygnięcia o opłacalności przeprowadzania dużych symulacji związanych ze znacznymi nakładami obliczeniowymi.

Bardzo ważnym elementem w naukach inżynierskich jest weryfikacja wyników uzyskanych na drodze symulacji komputerowych z odpowiednimi danymi dotyczącymi obiektów rzeczywistych. W przypadku badań podjętych przez autora rzeczywistym obiektem jest statek morski, w szczególności prom projektu Auto Express 82. Na potrzeby analiz porównawczych trzeba by dysponować dokumentacją konstrukcyjną tego statku lub wybranymi informacjami o charakterystykach konstrukcji, w szczególności wartościami kryteriów optymalizacji. Niestety, informacje tego typu nie są dostępne w publikacjach naukowych lub technicznych, ponieważ są chronione przez producentów. Podjęte przez autora próby uzyskania tych danych poprzez kontakty osobiste zakończyły się niepowodzeniem.

Oprócz trudności z dostępem do wiarygodnych danych „wrażliwych”, umożliwiających weryfikację otrzymanych rezultatów, autor dostrzega również trudności innej natury. Kadłub statku morskiego jest bardzo złożoną strukturą inżynierską. Obecnie istniejące narzędzia optymalizacyjne, algorytmy i sprzęt komputerowy wymagają znacznego uproszczenia konstrukcji rzeczywistej podczas formułowania modeli optymalizacyjnych, w związku z czym pomija się znaczną ilość informacji, np. liczbę i wymiary otworów przełazowo-ulżeniowych w dennikach, liczbę i wymiary skalopsów i przejść usztywnień, liczbę i wymiary węzłówek oraz płyt wspornikowych, a także lokalnych wzmocnień konstrukcji. Rezultaty optymalizacji obciążone będą zatem trudnym do oszacowania błędem. Ponadto nawet dysponując dokumentacją projektową statku, nie można mieć pewności, w jaki sposób ustalono finalne wymiary wiązań – konstruktor mógł przeprowadzić dodatkowe analizy i sugerując

się wynikami, zwiększył wymiary części wiązań; podczas wymiarowania konstrukcji często istnieje pewna swoboda przyjmowania wartości współczynników w formułach obliczeniowych; informacje o przyjętych wartościach nie są dostępne; konstruktor mógł także ustalić wymiary wiązań, uwzględniając doświadczenie z projektowania konstrukcji podobnych. Zatem nawet dostęp do dokumentacji i danych projektowych nie zapewnia możliwości weryfikacji obliczeń. Sekulski (2009 a) wyraził tę opinię i nie spotkała się ona z negatywną oceną recenzentów.

Autor podjął jednak próbę zmniejszenia omówionych trudności. Na potrzeby weryfikacji obliczeń optymalizacyjnych wykonano ręcznie projekt konstrukcji statku wzorcowego, dążąc do zachowania wszystkich procedur, zgodnie z opracowanym algorytmem optymalizacyjnym i przyjętym modelem optymalizacyjnej konstrukcji statku (Sekulski i Czyrkun 2003). Niestety, projekt ten wykonano wówczas pod kątem weryfikacji wyników optymalizacji jednokryterialnej pod względem na ciężaru konstrukcji; dostępna jest jedynie wartość ciężaru konstrukcji  $f_{1,SCZ}(\mathbf{x}) = 1148,88$  kN. Najlepsze, odszukane na podstawie badań w trakcie symulacji sym3–5, rozwiązanie pod względem dwóch kryteriów oceny ma następujące wartości kryteriów:  $f_{1,sym3-5}(\mathbf{x}) = 1019,80$  kN,  $f_{2,sym3-5}(\mathbf{x}) = 7305,15$  m<sup>2</sup>. Najmniejszą (bez względu na wartość pola powierzchni elementów) wartość ciężaru konstrukcji  $f_1(\mathbf{x})$  uzyskano natomiast w trakcie symulacji sym9–50000:  $f_{1,sym9-50000}(\mathbf{x}) = 992,93$  kN,  $f_{2,sym9-50000}(\mathbf{x}) = 7590,88$  m<sup>2</sup> – patrz rysunki G.5 (c) i (d). Rozwiązanie wielokryterialnego zadania optymalizacji pozwoliło zatem zmniejszyć ciężar konstrukcji o ok. 10%:

$$f_{1,sym3-5}(\mathbf{x}) = 0,89f_{1,SCZ}(\mathbf{x})$$

$$f_{1,sym9-50000}(\mathbf{x}) = 0,86f_{1,SCZ}(\mathbf{x})$$

Dalsze zmniejszanie ciężaru może odbywać się kosztem zwiększania pola powierzchni elementów konstrukcyjnych, a zatem i kosztu konstrukcji, której miarą może być jej pracochłonność.

Z praktycznego punktu widzenia ważne jest stwierdzenie, które ze sformułowanych ograniczeń są aktywne w procesie optymalizacji, a które nie są. W przypadku pierwszych uzasadnione są nawet duże nakłady obliczeniowe niezbędne do ich skontrolowania. W przypadku drugich poniesione nakłady obliczeniowe mogą okazać się zbędne z punktu widzenia skuteczności procesu optymalizacji; w niektórych przypadkach można nawet zaniechać ich kontrolowania. W przypadku przyjętego w tej pracy modelu optymalizacyjnego aktywne okazały się ograniczenia sformułowane w postaci nierówności (7.8), dotyczące zgodnej z przepisami wartości wskaźnika na zginanie przekroju ram poprzecznych w trzech rejonach konstrukcyjnych: burty zewnętrznej, dna oraz pokładu „mokrego”:

$$Z \geq \frac{1000 \cdot p \cdot S^2}{m \cdot \sigma_{am}} \cdot b$$

gdzie:  $p$  – powierzchniowe ciśnienie działające na blachy poszycia,  $m$  – współczynnik momentu gnącego, uwzględniający sposób mocowania zakończeń wazara i warunki obciążenia,  $\sigma_{am}$  – naprężenia dopuszczalne przy zginaniu,  $b$  – odstęp między wazarami,  $S$  – rozpiętość wazara.

Cztery pierwsze wielkości są stałe w przyjętym modelu optymalizacyjnym, natomiast odstęp między wazarami  $b$  zależy bezpośrednio od liczby ram poprzecznych w obrębie sekcji przestrzennej kadłuba, czyli od zmiennej decyzyjnej  $x_4$  (patrz tablica 7.6). Przy tym ograniczeniu

brzeg rozwiązań dopuszczalnych jest linią prostą. Pozostałe ograniczenia, dotyczące przede wszystkim wymaganych grubości płyt poszycia oraz wymiarów usztywnień, spełnione są przy znacznym przekroczeniu wartości dopuszczalnych.

#### 8.4. Podsumowanie i wnioski

Wszystkie zbadane strategie ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku pozwoliły wygenerować i odszukać rozwiązania niezdominowane, których oceny formułują zbiory  $\Psi_f$  przybliżające fronty ocen rozwiązań optymalnych Pareto  $\Psi_P$ . Uzyskane rezultaty sugerują, że dla odwzorowania frontu optymalnego Pareto skuteczniejsze jest uruchomienie pojedynczych dużych symulacji, niż gromadzenie wyników z wielu mniejszych symulacji. Zgodnie z oczekiwaniami większa symulacja, określona liczbą osobników w pokoleniu  $n_i$  oraz liczbą pokoleń  $n_g$ , stwarza większą szansę na pełniejsze odwzorowanie zbioru optymalnego Pareto  $\Psi_P$ . Nie daje jednak pewności odnalezienia rozwiązania, którego ocena jest najbliższa ocenie asymptotycznej  $\mathbf{f}^*$  i które może być uważane za jedno rozwiązanie sformułowanego zadania. Zwiększenie udziału atrybutów dominacji w wytwarzaniu nacisku selekcyjnego w toku ewolucji nie daje pewności odnalezienia korzystniejszych rozwiązań i lepszego odwzorowania zbioru optymalnego Pareto  $\Psi_P$ .

Wyniki przeprowadzonych symulacji wyraźnie uwidaczniają losowy charakter opracowanej metody ewolucyjnej optymalizacji wielokryterialnej – w poszczególnych symulacjach uzyskano bardzo zróżnicowane zbiory przybliżające  $\Psi_{\text{symi}}$ . Stąd wniosek, że nie ma uzasadnienia formułowanie opinii, że rozwiązania otrzymane w trakcie poszczególnych symulacji są najlepszymi możliwymi rozwiązaniami dla sformułowanego zadania optymalizacji wielokryterialnej; są one jedynie najlepsze wśród uzyskanych w wyniku symulacji przeprowadzonej przy określonych wartościach parametrów sterujących. Symulacje przeprowadzone przy jakiegokolwiek zmianie parametrów sterujących prowadzą do uzyskania innych rozwiązań, może nawet lepszych, czyli o korzystniejszych wartościach kryteriów optymalizacji.

Zaletą przeprowadzenia wielu mniejszych symulacji jest możliwość łatwego rozproszenia wysiłku obliczeniowego na wiele komputerów w tym samym czasie lub na wiele procesorów tego samego komputera. Może się to okazać bardzo istotne wówczas, gdy czas przeznaczony na wykonanie obliczeń jest bardzo krótki, ponieważ rozpraszając obliczenia, można szybciej wykonać taką samą liczbę obliczeń, jakie są potrzebne w przypadku jednej dużej symulacji.

Interesujące jest to, w jaki sposób w trakcie symulacji / ewolucji budowany jest zbiór przybliżający  $\Psi_f$ . Uzyskane wyniki wskazują, że zbiór przybliżający  $\Psi_f$  budowany jest w sposób, który autorowi przypomina sączenie się kropel, co oznacza, że co jakiś czas bardzo szybko na początku symulacji (coraz rzadziej w jej toku) z „chmury” rozwiązań dopuszczalnych „spadają” do zbioru przybliżającego  $\Psi_f$  pojedyncze „krople” ocen rozwiązań niezdominowanych, zmieniając przy tym jego strukturę. Autorowi nie są znane podobne spostrzeżenia innych badaczy. Uważają oni, że w trakcie ewolucji cały zbiór ocen rozwiązań dopuszczalnych  $\Phi_f$  (zawierający zbiór przybliżający  $\Psi_f$ ) przemieszcza się stopniowo w kierunku frontu optymalnego Pareto  $\Psi_P$ . Jednak zdaniem autora w zadaniach podobnych do zadania sformułowanego w pracy duża liczba sformułowanych ograniczeń powoduje, że

zbiór ocen rozwiązań dopuszczalnych  $\Phi_f$  utrzymuje się daleko od powierzchni zbioru przybliżającego  $\Psi_f$ . Zdaniem autora może to wskazywać na istotną rolę eksploracji przestrzeni rozwiązań w celu wygenerowania wariantów zdolnych do opuszczenia zbioru dopuszczalnego i przemieszczenia się do zbioru przybliżającego. Efekt ten można uzyskać, zwiększając na przykład prawdopodobieństwo mutacji.

Zwrócono uwagę na trudne do usunięcia problemy związane z porównywaniem wyników symulacji komputerowych z charakterystykami konstrukcji rzeczywistych. W przedstawionej pracy wyniki symulacji komputerowych zweryfikowano, porównując je z wynikami tradycyjnego projektowania ręcznego prowadzonego w kontrolowanych warunkach. Porównanie to pozwala na pozytywną weryfikację opracowanego narzędzia i możliwość osiągnięcia ok. 10-procentowego zmniejszenia ciężaru dzięki zastosowaniu opracowanego narzędzia do wielokryterialnej optymalizacji konstrukcji kadłuba statku.

Wyniki symulacji komputerowych wskazują, że opracowane narzędzie obliczeniowe generuje zbiory przybliżające  $\Psi_f$  o dużej rozpiętości. Oznacza to duże zróżnicowanie rozwiązań w zbiorze przybliżającym oraz istotną rolę decydenta w wyborze pojedynczego rozwiązania lub większej liczby rozwiązań do dalszych prac projektowych.

Tarnowski (2009) zwraca uwagę na potrzebę sporządzania sprawozdania z optymalizacji. Powinno ono zawierać informacje o tym, jakie rozwiązanie optymalne zostało uzyskane oraz przy jakich ograniczeniach. Sprawozdanie powinno umożliwić wyrobienie poglądu, czy osiągnięto cele optymalizacji oraz jakie wnioski można z niej wyciągnąć. Autor ten proponuje również wzór planu takiego sprawozdania.

Załącznik I zawiera kopię plakatu przedstawiającego w zwartej formie dane i wyniki ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, uzyskane w trakcie symulacji sym2–1. Plakat ten jest propozycją praktycznego przedstawienia najważniejszych rezultatów osiągniętych w toku ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku, a zatem może być formą sprawozdania z przeprowadzonej optymalizacji.

W następnym rozdziale przedstawiono szczegółową analizę jakości zbiorów przybliżających  $\Psi_{\text{sym}i}$  uzyskanych w trakcie poszczególnych symulacji.



## 9. Ocena jakości zbiorów przybliżających wygenerowanych w trakcie symulacji komputerowych

### 9.1. Plan oceny jakości zbiorów przybliżających

W rezultacie przeprowadzonych i omówionych w poprzednim rozdziale symulacji komputerowych otrzymano zbiory  $\Psi_f$  przybliżające zbiory  $\Psi_P$  ocen rozwiązań optymalnych Pareto, zawierające w przypadku poszczególnych symulacji od kilku do kilkunastu ocen nie-zdominowanych wariantów KKS. Otrzymane rezultaty, czyli zbiory przybliżające  $\Psi_f$ , powinny być poddane ocenie, która może być także założeniem umożliwiającym wnioskowanie o przewadze którejś ze zbadanych strategii ewolucyjnej optymalizacji wielokryterialnej.


Metody oceny jakości zbiorów przybliżających  $\Psi_f$ , a w związku z tym pośrednio także skuteczności ewolucyjnych algorytmów optymalizacji wielokryterialnej przedstawiono i przedyskutowano w rozdziale 5. Na tej podstawie w rozdziale tym przedstawiono wyniki badań jakości zbiorów przybliżających  $\Psi_f$ , stosując trzy deterministyczne strategie oceny jakości rezultatów ewolucyjnych algorytmów optymalizacji wielokryterialnej: (1) metodę oceny wizualnej (VAM), (2) metodę relacji dominacji (DRM), (3) metodę wskaźników jakości (QIM).

Ze względu na trudności, długi czas obliczeń i wysokie koszty, związane z uzyskaniem statystycznie istotnej próby zbiorów przybliżających, w przypadku zadania optymalizacji wielokryterialnej KKS pominięto badanie jakości zbiorów przybliżających metodami statystycznymi, w tym metodę funkcji osiągnięcia (AFM).

Ocena jakości zbiorów przybliżających zostanie szczegółowo przeprowadzona w przypadku pierwszej serii symulacji, natomiast w przypadku pozostałych serii przedstawione zostaną jedynie wyniki najważniejsze.


### 9.2. Wizualna ocena zbiorów przybliżających

Uzyskane w trakcie symulacji zbiory przybliżające  $\Psi_f$  rozmieszczone są w przybliżeniu w zakresie od 1000 do 2800 kN w przypadku pierwszego kryterium optymalizacji  $f_1$  (ciężar konstrukcji) i od 6800 do 7800 m<sup>2</sup> w przypadku drugiego kryterium  $f_2$  (pole powierzchni zewnętrznej elementów konstrukcyjnych do malowania i konserwacji). Można przypuszczać, że wszystkie zbiory przybliżające  $\Psi_f$  rozmieszczone są w przybliżeniu wzdłuż wypukłego zbioru ocen wariantów optymalnych Pareto  $\Psi_P$  (rysunki 9.1, 9.2, 9.3 i 9.4). Na podstawie kształtów zbiorów przybliżających  $\Psi_f$  można wyciągnąć wniosek, że sformułowane zadanie optymalizacji jest zadaniem wypukłym, co znacznie ułatwia odwzorowanie frontu optymalnego Pareto  $\Psi_P$ . W części symulacji odwzorowanie frontu ocen wariantów optymalnych Pareto  $\Psi_P$  można uznać za zadowalające, np. w sym1–2, sym2–1, sym2–2, sym2–3, sym1–2–50000, sym12–50000 i sym9–50000.




Rys. 9.1. Struktura zbiorów  $\Psi_{symi}$  przybliżających front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , uzyskanych w poszczególnych symulacjach: sym1-1 (a, b), sym1-2 (c, d) i sym1-3 (e, f), a także wartości przyjętych skalarnych wskaźników jakości:  $QI_{AD}$ ,  $QI_B$ ,  $QI_D$ ,  $QI_H$ ; okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej





Rys. 9.2. Struktura zbiorów  $\Psi_{\text{sym}i}$  przybliżających front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , uzyskanych w poszczególnych symulacjach: sym2-1 (a, b), sym2-2 (c, d) i sym2-3 (e, f), a także wartości przyjętych skalnych wskaźników jakości:  $QI_{AD}$ ,  $QI_B$ ,  $QI_D$ ,  $QI_H$ ; okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej



Rys. 9.3. Struktura zbioru  $\Psi_{\text{sym3}-i}$  przybliżającego front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , uzyskanego w serii dziesięciu symulacji, sym3-[1-10] oraz wartości przyjętych skalnych wskaźników jakości:  $QI_H$  (a) i  $QI_{AD}$ ,  $QI_B$ ,  $QI_D$  (b); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają ocenę najbliższą ocenie asymptotycznej


W pozostałych przypadkach (sym1-1 i sym1-3), zbiory przybliżające  $\Psi_f$  odwzorowują front optymalny Pareto  $\Psi_P$  nieco gorzej. Uzyskane oceny wariantów niezdominowanych wykazują tendencję do większego skupiania się w obszarach mniejszych wartości ciężaru konstrukcji  $f_1(\mathbf{x})$ . Wydaje się to uzasadnione, ponieważ jest to wymuszane naciskiem selekcyjnym wywieranym przez ograniczenia związane z wymiarami elementów konstrukcyjnych, bezpośrednio wpływających na ciężar konstrukcji; nie ma takiego bezpośredniego oddziaływania na pole powierzchni elementów, a wartości tego kryterium są wyliczane jedynie dla wygenerowanych wariantów.

### 9.3. Ocena zbiorów przybliżających za pomocą relacji dominacji

W rozdziale 5 uzasadniono, że relacja dominacji Pareto nie rozstrzyga o ocenie uzyskanej w trakcie symulacji komputerowych zbiorów przybliżających  $\Psi_f$ . Jak widać na rysunku J.1, w większości przypadków osiągnięte w trakcie poszczególnych symulacji zbiory przybliżające  $\Psi_{\text{sym}i}$  przenikają się wzajemnie, w związku z czym oceniając zbiory przybliżające  $\Psi_f$  pod względem relacji dominacji, nie można wskazać, który z nich jest najlepszy. Na podstawie relacji dominacji większość zbiorów przybliżających jest nieporównywalna ze sobą – w takich przypadkach można wnioskować o względnej przewadze którejś z realizowanych strategii algorytmu ewolucyjnego.

W niektórych przypadkach porównywania dwóch zbiorów przybliżających stosowanie tej metody pozwala wnioskować o względnie wyższej jakości jednego z porównywanych zbiorów przybliżających (rysunki 9.1, 9.2, 9.3, 9.4), np.:

(a) zbiór przybliżający  $\Psi_{\text{sym12-50000}}$ , uzyskany w symulacji sym12-50000, dominuje nad zbiorem przybliżającym  $\Psi_{\text{sym1-3}}$ , uzyskanym w symulacji sym1-3;



Rys. 9.4. Struktura zbiorów  $\Psi_{\text{sym}i}$  przybliżających front ocen rozwiązań optymalnych Pareto  $\Psi_P$ , uzyskanych w poszczególnych symulacjach: sym1-2-50000 (a, b), sym12-50000 (c, d) i sym9-50000 (e, f), a także wartości przyjętych skalarnych wskaźników jakości:  $QI_{AD}$ ,  $QI_B$ ,  $QI_D$ ,  $QI_H$ ; okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej

(b) zbiór przybliżający  $\Psi_{\text{sym}3-i}$ , uzyskany w serii symulacji od sym3–1 do sym3–10 (sym3–[1–10]), dominuje nad zbiorami przybliżającymi  $\Psi_{\text{sym}1-1}$ ,  $\Psi_{\text{sym}1-2}$ ,  $\Psi_{\text{sym}1-3}$ ,  $\Psi_{\text{sym}2-1}$ ,  $\Psi_{\text{sym}2-2}$  i  $\Psi_{\text{sym}2-3}$ , uzyskanymi w symulacjach sym1–1, sym1–2, sym1–3, sym2–1, sym2–2, sym2–3; można wyciągnąć stąd oczekiwany wniosek, że zwiększenie wysiłku obliczeniowego, związanego z uruchomieniem każdej kolejnej symulacji z serii symulacji, z których każda ma tę samą wielkość, może w rezultacie umożliwić uzyskanie zbioru przybliżającego o wyższej jakości;

(c) jeśli pominie się jedno rozwiązanie należące do zbioru przybliżającego  $\Psi_{\text{sym}2-1}$ , zbiór przybliżający  $\Psi_{\text{sym}9-50000}$ , otrzymany w trakcie symulacji sym9–50000 będzie dominował nad zbiorem przybliżającym  $\Psi_{\text{sym}2-1}$  uzyskanym w symulacji sym2–1.

## 9.4. Ocena zbiorów przybliżających za pomocą wskaźników jakości

### 9.4.1. Seria 1.

Do ilościowej oceny jakości zbiorów przybliżających (a także skuteczności wybranej strategii algorytmu ewolucyjnego), otrzymanych metodą agregacji funkcji celu, bez uwzględniania w procesie selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego, zaproponowano wyspecyfikowanych w podrozdziale 6.1.10 pięć jednoargumentowych skalarnych wskaźników jakości – zależności (6.14)–(6.18), które można potraktować jako składowe pięciowymiarowego wektorowego wskaźnika jakości (6.19).

W tablicy 9.1 i na rysunku 9.1 zestawiono wartości przyjętych skalarnych wskaźników jakości dla poszczególnych symulacji serii 1.

W przypadku skalarnego wskaźnika jakości  $QI_{AD}$ , reprezentującego mierzoną w unormowanej przestrzeni ocen odległość zbioru przybliżającego  $\Psi_{\text{sym}i}$ , wygenerowanego w danej symulacji  $\text{sym}i$ , od oceny asymptotycznej  $\mathbf{f}^*$  – zależność (6.14) – uzyskane wyniki są następujące (patrz rysunki 9.1 (b), (d) i (f) oraz tablica 9.1):

$$QI_{AD}(\text{sym}1-1) = 1,028, QI_{AD}(\text{sym}1-2) = 1,024 \text{ oraz } QI_{AD}(\text{sym}1-3) = 1,032$$

Porównując powyższe wartości, można to zapisać w postaci:

$$QI_{AD}(\text{sym}1-2) = 1,024 < QI_{AD}(\text{sym}1-1) = 1,028 < QI_{AD}(\text{sym}1-3) = 1,032$$

Na podstawie tego wskaźnika jakości najlepszy rezultat otrzymano w wyniku symulacji sym1–2. Nieco gorszy rezultat otrzymano w wyniku symulacji sym1–1. W wyniku symulacji sym1–3 otrzymano rezultat wyraźnie gorszy od pozostałych. Porównując parami zbiory przybliżające  $\Psi_{\text{sym}i}$  pod względem kryterium odległości zbioru przybliżającego od oceny asymptotycznej  $\mathbf{f}^*$  w unormowanej przestrzeni ocen, otrzymano:

$$QI_{AD}(\text{sym}1-2) (= 1,024) < QI_{AD}(\text{sym}1-1) (= 1,028) \Rightarrow \downarrow QI_{AD} \Rightarrow \text{sym}1-2 \blacktriangleright \text{sym}1-1$$

$$QI_{AD}(\text{sym}1-1) (= 1,028) < QI_{AD}(\text{sym}1-3) (= 1,032) \Rightarrow \downarrow QI_{AD} \Rightarrow \text{sym}1-1 \blacktriangleright \text{sym}1-3$$

$$QI_{AD}(\text{sym}1-2) (= 1,024) < QI_{AD}(\text{sym}1-3) (= 1,032) \Rightarrow \downarrow QI_{AD} \Rightarrow \text{sym}1-2 \blacktriangleright \text{sym}1-3$$

Wniosek o jakości trzech porównywanych zbiorów przybliżających można więc sformułować w sposób następujący: Jeśli mierzona w unormowanej przestrzeni ocen odległość uzyskanego w danej symulacji zbioru przybliżającego  $\Psi_{\text{sym}i}$  od oceny asymptotycznej  $\mathbf{f}^*$  poprawnie reprezentuje preferencje decydenta w ten sposób, że mniejsze wartości wskaźnika  $QI_{AD}$  są bar-

dziej preferowane, to można przyjąć, że zbiory przybliżające  $\Psi_{\text{sym}1-1}$  i  $\Psi_{\text{sym}1-2}$ , uzyskane w wyniku symulacji sym1–1 i sym1–2, charakteryzują się podobną jakością, natomiast zbiór przybliżający  $\Psi_{\text{sym}1-3}$ , uzyskany w wyniku symulacji sym1–3, jest gorszej jakości od obu pozostałych.

Tablica 9.1. Wartości skalnych wskaźników jakości  $QI_q(\Psi_{\text{sym}i})$ ,  $q = 1, 2, \dots, Q = 5$ , dla zbiorów przybliżających  $\Psi_{\text{sym}i}$  otrzymanych w poszczególnych symulacjach komputerowych symi

| Symulacja symi | Skalarne wskaźniki jakości $QI_q$          |                                         |                                         |                                           |                                                 |
|----------------|--------------------------------------------|-----------------------------------------|-----------------------------------------|-------------------------------------------|-------------------------------------------------|
|                | odległość zbioru przybliżającego $QI_{AD}$ | szerokość zbioru przybliżającego $QI_B$ | głębokość zbioru przybliżającego $QI_D$ | zdominowana część przestrzeni ocen $QI_H$ | wkład do zbioru ocen niezdominowanych $QI_{NF}$ |
| Seria 1.       |                                            |                                         |                                         |                                           |                                                 |
| sym1–1         | ↓1,028                                     | ↑18,885°                                | ↑0,144                                  | ↑60,0%                                    | ↑6 / 40%                                        |
| sym1–2         | ↓1,024                                     | ↑21,210°                                | ↑0,183                                  | ↑64,5%                                    | ↑6 / 40%                                        |
| sym1–3         | ↓1,032                                     | ↑18,053°                                | ↑0,125                                  | ↑60,1%                                    | ↑3 / 20%                                        |
| Seria 2.       |                                            |                                         |                                         |                                           |                                                 |
| sym2–1         | ↓1,021                                     | ↑20,751°                                | ↑0,184                                  | ↑59,6%                                    | ↑2 / 16%                                        |
| sym2–2         | ↓1,030                                     | ↑25,098°                                | ↑0,266                                  | ↑60,7%                                    | ↑5 / 42%                                        |
| sym2–3         | ↓1,032                                     | ↑23,931°                                | ↑0,231                                  | ↑62,5%                                    | ↑5 / 42%                                        |
| Seria 3.       |                                            |                                         |                                         |                                           |                                                 |
| sym3–i         | ↓1,005                                     | ↑17,027                                 | ↑0,125                                  | ↑71,9%                                    | –                                               |
| Seria 4.       |                                            |                                         |                                         |                                           |                                                 |
| sym1–2–50000   | ↓1,016                                     | ↑21,932°                                | ↑0,191                                  | ↑67,7%                                    | ↑3 / 15%                                        |
| sym12–50000    | ↓1,011                                     | ↑20,010°                                | ↑0,157                                  | ↑69,9%                                    | ↑9 / 45%                                        |
| sym9–50000     | ↓1,016                                     | ↑19,854°                                | ↑0,128                                  | ↑73,0%                                    | ↑8 / 40%                                        |

Można również sformułować następujący wniosek o skuteczności trzech porównywalnych strategii algorytmu: Jeśli mierzona w unormowanej przestrzeni ocen odległość uzyskanego w wyniku danej symulacji zbioru przybliżającego  $\Psi_{\text{sym}i}$  od oceny asymptotycznej  $\mathbf{f}^*$  poprawnie reprezentuje preferencje decydenta w ten sposób, że mniejsze wartości wskaźnika  $QI_{AD}$  są bardziej preferowane, to można przyjąć, że strategie uwzględniania kryteriów optymalizacji w procesie selekcji, realizowane w symulacjach sym1–1 i sym1–2, są skuteczne w podobnym stopniu, natomiast strategia realizowana w symulacji sym1–3 jest mniej skuteczna od obu pozostałych.

W przypadku składowego wskaźnika jakości  $QI_B$  (6.15), reprezentującego mierzona w unormowanej przestrzeni ocen szerokość (rozpiętość) zbioru przybliżającego  $\Psi_{\text{sym}i}$ , uzyskanego w danej symulacji symi, otrzymane wyniki są następujące (patrz rysunek 9.1 (b), (d), (f) oraz tablica 9.1):

$$QI_B(\text{sym}1-1) = 18,885^\circ, QI_B(\text{sym}1-2) = 21,210^\circ \text{ oraz } QI_B(\text{sym}1-3) = 18,053^\circ$$

Porównując powyższe wartości, można to zapisać w postaci:

$$QI_B(\text{sym}1-3) = 18,053^\circ < QI_B(\text{sym}1-1) = 18,885^\circ < QI_B(\text{sym}1-2) = 21,210^\circ$$

Na podstawie tego wskaźnika jakości najlepszy rezultat otrzymano w symulacji sym1-2. Nieco gorszy rezultat otrzymano w wyniku symulacji sym1-1 i sym1-3. Porównując parami uzyskane zbiory przybliżające ze względu na kryterium szerokości (rozpiętości) zbioru przybliżającego w unormowanej przestrzeni ocen, otrzymano:

$$QI_B(\text{sym1-2}) (= 21,210^\circ) > QI_B(\text{sym1-1}) (= 18,885^\circ) \Rightarrow \uparrow QI_B \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-1}$$

$$QI_B(\text{sym1-1}) (= 18,885^\circ) > QI_B(\text{sym1-3}) (= 18,053^\circ) \Rightarrow \uparrow QI_B \Rightarrow \text{sym1-1} \blacktriangleright \text{sym1-3}$$

$$QI_B(\text{sym1-2}) (= 21,210^\circ) > QI_B(\text{sym1-3}) (= 18,053^\circ) \Rightarrow \uparrow QI_B \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-3}$$

Wniosek o jakości trzech zbiorów przybliżających można więc sformułować w sposób następujący: Jeśli mierzona w unormowanej przestrzeni ocen szerokość (rozpiętość) uzyskanego w danej symulacji zbioru przybliżającego  $\Psi_{\text{symi}}$  poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_B$  są bardziej preferowane, to można przyjąć, że zbiór przybliżający najwyższej jakości uzyskano w wyniku symulacji sym1-2 ( $\Psi_{\text{sym1-2}}$ ); w przypadku pozostałych symulacji (sym1-1 i sym1-3) zbiory przybliżające ( $\Psi_{\text{sym1-1}}$  i  $\Psi_{\text{sym1-3}}$ ) są znacznie gorszej jakości.

Można również sformułować wniosek o skuteczności trzech zastosowanych strategii: Jeśli mierzona w unormowanej przestrzeni ocen szerokość (rozpiętość) zbioru przybliżającego  $\Psi_{\text{symi}}$ , uzyskanego w danej symulacji, poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_B$  są bardziej preferowane, to można przyjąć, że strategia uwzględniania kryteriów optymalizacji w procesie selekcji, realizowana w symulacji sym1-2, jest znacznie skuteczniejsza od strategii realizowanych w pozostałych symulacjach (sym1-1 i sym1-3).

W przypadku skalarnego wskaźnika jakości  $QI_D$ , reprezentującego mierzoną w unormowanej przestrzeni ocen głębokość zbioru przybliżającego  $\Psi_{\text{symi}}$ , otrzymanego w danej symulacji symi (6.16) wyniki są następujące (patrz rysunek 9.1 (b), (d), (f) oraz tablica 9.1):

$$QI_D(\text{sym1-1}) = 0,144, QI_D(\text{sym1-2}) = 0,183 \text{ oraz } QI_D(\text{sym1-3}) = 0,125$$

Porównując powyższe wartości, można to zapisać w postaci:

$$QI_D(\text{sym1-2}) = 0,183 > QI_D(\text{sym1-1}) = 0,144 > QI_D(\text{sym1-3}) = 0,125$$

Na podstawie tego wskaźnika jakości najlepszy rezultat otrzymano w wyniku symulacji sym1-2. Nieco gorszy rezultat otrzymano w wyniku symulacji sym1-1 i symulacji sym1-3. Porównując parami otrzymane zbiory przybliżające  $\Psi_{\text{symi}}$ , ze względu na kryterium głębokości zbioru przybliżającego w unormowanej przestrzeni ocen, otrzymano:

$$QI_D(\text{sym1-2}) (= 0,183) > QI_D(\text{sym1-1}) (= 0,144) \Rightarrow \uparrow QI_D \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-1}$$

$$QI_D(\text{sym1-1}) (= 0,144) > QI_D(\text{sym1-3}) (= 0,125) \Rightarrow \uparrow QI_D \Rightarrow \text{sym1-1} \blacktriangleright \text{sym1-3}$$

$$QI_D(\text{sym1-2}) (= 0,183) > QI_D(\text{sym1-3}) (= 0,125) \Rightarrow \uparrow QI_D \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-3}$$

Wniosek o jakości trzech zbiorów przybliżających można więc sformułować w sposób następujący: Jeśli mierzona w unormowanej przestrzeni ocen głębokość zbioru przybliżającego, otrzymanego w danej symulacji  $\Psi_{\text{symi}}$ , poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_D$  są bardziej preferowane, to można przyjąć, że zbiór przybliżający ( $\Psi_{\text{sym1-2}}$ ), otrzymany w wyniku symulacji sym1-2, charakte-

ryzuje się znacznie wyższą jakością od zbiorów przybliżających otrzymanych w pozostałych symulacjach sym1–1 i sym1–3 ( $\Psi_{\text{sym1-1}}$  i  $\Psi_{\text{sym1-3}}$ ).

Można także sformułować następujący wniosek o skuteczności trzech porównywalnych strategii algorytmu ewolucyjnego: Jeśli mierzona w unormowanej przestrzeni ocen głębokość zbioru przybliżającego, otrzymanego w danej symulacji  $\Psi_{\text{symi}}$ , poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_D$  są bardziej preferowane, to można przyjąć, że strategia uwzględniania kryteriów optymalizacji w procesie selekcji, realizowana w symulacji sym1–2, jest znacznie skuteczniejsza od strategii realizowanych w pozostałych symulacjach (sym1–1 i sym1–3).

Reprezentowana przez skalarny wskaźnik jakości  $QI_H$  (6.17) wielkość części przestrzeni ocen zdominowanej w poszczególnych symulacjach  $\text{symi}$  przez uzyskany zbiór przybliżający  $\Psi_{\text{symi}}$  wynosi odpowiednio (patrz rysunek 9.1 (a), (c), (e) oraz tablica 9.1):

$$QI_H(\text{sym1-1}) = 60,0\%, QI_H(\text{sym1-2}) = 64,5\% \text{ i } QI_H(\text{sym1-3}) = 60,1\%$$

Porównując powyższe wartości, można to zapisać w postaci:

$$QI_H(\text{sym1-2}) = 64,5\% > QI_H(\text{sym1-3}) = 60,1\% > QI_H(\text{sym1-1}) = 60,0\%$$

Na podstawie tego wskaźnika jakości najlepszy rezultat otrzymano w symulacji sym1–2. Nieco gorsze wyniki otrzymano w przypadku obu pozostałych symulacji sym1–1 i sym1–3. Porównując parami zbiory przybliżające  $\Psi_{\text{symi}}$ , ze względu na kryterium największej części fizycznej przestrzeni ocen zdominowanej przez zbiór ocen rozwiązań niezdominowanych, otrzymano:

$$QI_H(\text{sym1-2}) (= 64,5\%) > QI_H(\text{sym1-1}) (= 60,0\%) \Rightarrow \uparrow QI_H \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-1}$$

$$QI_H(\text{sym1-3}) (= 60,1\%) > QI_H(\text{sym1-1}) (= 60,0\%) \Rightarrow \uparrow QI_H \Rightarrow \text{sym1-3} \blacktriangleright \text{sym1-1}$$

$$QI_H(\text{sym1-2}) (= 60,4\%) > QI_H(\text{sym1-3}) (= 60,1\%) \Rightarrow \uparrow QI_H \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-3}$$

Wniosek można sformułować w sposób następujący: Jeśli wielkość fizycznej przestrzeni ocen zdominowana przez zbiory przybliżające, uzyskane w poszczególnych symulacjach  $\Psi_{\text{symi}}$ , poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_H$  są bardziej preferowane, to można przyjąć, że najwyższej jakości zbiór przybliżający uzyskano w symulacji sym1–2 ( $\Psi_{\text{sym1-2}}$ ); zbiory przybliżające uzyskane w symulacjach sym1–1 i sym1–3 ( $\Psi_{\text{sym1-1}}$  i  $\Psi_{\text{sym1-3}}$ ) są nieco gorszej jakości.

Można także sformułować następujący wniosek dotyczący skuteczności zrealizowanych strategii algorytmu ewolucyjnego: Jeśli wielkość fizycznej przestrzeni ocen zdominowana przez zbiory przybliżające, uzyskane w poszczególnych symulacjach  $\Psi_{\text{symi}}$ , poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_H$  są bardziej preferowane, to można przyjąć, że najbardziej skuteczna jest strategia uwzględniania kryteriów optymalizacji w procesie selekcji realizowana w symulacji sym1–2; strategie realizowane w symulacjach sym1–1 i sym1–3 są nieco mniej skuteczne.

Rozważmy skalarny wskaźnik jakości  $QI_{NF}$  (6.18) reprezentujący liczbę  $n_{\text{symi}}$  rozwiązań wygenerowanych w danej symulacji  $\text{symi}$ , zaliczonych do zbioru rozwiązań niezdominowanych (o liczności  $n_{ov}$ ), zbudowanego po zsumowaniu zbiorów przybliżających  $\Psi_{\text{symi}}$  otrzymanych we wszystkich symulacjach przeprowadzonych w serii. Liczba rozwiązań w poszczególnych zbiorach ocen rozwiązań niezdominowanych  $n_{ov} = 15$ ,  $n_{\text{sym1-1}} = 6$ ,  $n_{\text{sym1-2}} = 6$ ,  $n_{\text{sym1-3}} = 3$ , ( $6 + 6 + 3 = 15$ ) – patrz rysunek 8.11 (b). Względna liczba rozwiązań to (tablica 9.1):

$$QI_{NF}(\text{sym1-1}) = 40\%, QI_{NF}(\text{sym1-2}) = 40\% \text{ i } QI_{NF}(\text{sym1-3}) = 20\%$$

Na podstawie tego wskaźnika jakości najlepsze, jednakowe, rezultaty otrzymano w sym1-1 i sym1-2; wniosły one do zbioru rozwiązań niezdominowanych po 40% rozwiązań. Symulacja sym1-3 okazała się najmniej skuteczna, wnosząc jedynie 20% rozwiązań.

Porównując parami zbiory przybliżające  $\Psi_{\text{sym}i}$ , pod względem kryterium największej liczby rozwiązań z danej symulacji  $n_{\text{sym}i}$ , zaliczonej do zbioru rozwiązań niezdominowanych, wybranych ze wszystkich symulacji poddanych badaniom (symbol  $\blacktriangleright$  oznacza, że nie można rozstrzygnąć o wyższości zbiorów przybliżających), otrzymano:

$$QI_{NF}(\text{sym1-1}) (= 40\%) = QI_{NF}(\text{sym1-2}) (= 40\%) \Rightarrow \uparrow QI_{NF} \Rightarrow \text{sym1-1} \blacktriangleright \text{sym1-2}$$

$$QI_{NF}(\text{sym1-1}) (= 40\%) > QI_{NF}(\text{sym1-3}) (= 20\%) \Rightarrow \uparrow QI_{NF} \Rightarrow \text{sym1-1} \blacktriangleright \text{sym1-3}$$

$$QI_{NF}(\text{sym1-2}) (= 40\%) > QI_{NF}(\text{sym1-3}) (= 20\%) \Rightarrow \uparrow QI_{NF} \Rightarrow \text{sym1-2} \blacktriangleright \text{sym1-3}$$

Wniosek można sformułować w następujący sposób: Jeśli liczba rozwiązań z danej symulacji  $\text{sym}i$ , zaliczona do zbioru rozwiązań niezdominowanych, wybranych spośród wszystkich symulacji poddanych badaniom, poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_{NF}$  są bardziej preferowane, to można przyjąć, że zbiory przybliżające uzyskane w symulacjach sym1-1 i sym1-2 ( $\Psi_{\text{sym1-1}}$  i  $\Psi_{\text{sym1-2}}$ ) charakteryzują się zbliżoną jakością, jednak nie można rozstrzygnąć o przewadze któregoś z nich; natomiast zbiór przybliżający uzyskany w symulacji sym1-3 ( $\Psi_{\text{sym1-3}}$ ) jest znacznie gorszej jakości od zbiorów uzyskanych w obu pozostałych symulacjach.

Można również sformułować następujący wniosek dotyczący skuteczności strategii realizowanej w algorytmie optymalizacyjnym: Jeśli liczba rozwiązań z danej symulacji, zaliczona do zbioru rozwiązań niezdominowanych, wybranych spośród wszystkich symulacji poddanych badaniom, poprawnie reprezentuje preferencje decydenta w ten sposób, że większe wartości wskaźnika  $QI_{NF}$  są bardziej preferowane, to można przyjąć, że strategie realizowane w symulacjach sym1-1 i sym1-2 są skuteczne w podobnym stopniu, jednak nie można rozstrzygnąć o przewadze którejś z nich; natomiast strategia realizowana w symulacji sym1-3 jest znacznie mniej skuteczna od obu pozostałych.

Dla poszczególnych symulacji komputerowych  $\text{sym}i$  pięciowymiarowe ( $Q = 5$ ) wektorowe wskaźniki jakości **QI** mają postać:

$$\begin{aligned} \mathbf{QI}(\text{sym1-1}) &= \\ &= [QI_{AD}(\text{sym1-1}) \quad QI_B(\text{sym1-1}) \quad QI_D(\text{sym1-1}) \quad QI_H(\text{sym1-1}) \quad QI_{NF}(\text{sym1-1})]^T = \\ &= [1,028 \quad 18,885^\circ \quad 0,144 \quad 60,0\% \quad 40\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym1-2}) &= \\ &= [QI_{AD}(\text{sym1-2}) \quad QI_B(\text{sym1-2}) \quad QI_D(\text{sym1-2}) \quad QI_H(\text{sym1-2}) \quad QI_{NF}(\text{sym1-2})]^T = \\ &= [1,024 \quad 21,210^\circ \quad 0,183 \quad 64,5\% \quad 40\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym1-3}) &= \\ &= [QI_{AD}(\text{sym1-3}) \quad QI_B(\text{sym1-3}) \quad QI_D(\text{sym1-3}) \quad QI_H(\text{sym1-3}) \quad QI_{NF}(\text{sym1-3})]^T = \\ &= [1,032 \quad 18,053^\circ \quad 0,125 \quad 60,1\% \quad 20\%]^T \end{aligned}$$

Analiza sformułowanego wektorowego wskaźnika jakości zbiorów przybliżających  $\Psi_{\text{sym}i}$ , uzyskanych za pomocą ewolucyjnego algorytmu optymalizacji wielokryterialnej w poszczególnych symulacjach serii 1., wskazuje zdaniem autora, że zbiór przybliżający



$\Psi_{\text{sym1-2}}$  jest najlepszej jakości: jest najbliższy oceny asymptotycznej, ma największą szerokość i głębokość, co zapewnia duże zróżnicowanie rozwiązań w zbiorze, dominuje nad największą częścią przestrzeni ocen oraz wnosi najwięcej ocen do zbioru ocen rozwiązań niezdominowanych, zbudowanego po zsumowaniu zbiorów przybliżających. Zbiór przybliżający  $\Psi_{\text{sym1-1}}$  okazał się tylko nieco gorszy: jest nieco bardziej odległy od oceny asymptotycznej, dominuje nad nieco mniejszą częścią przestrzeni ocen oraz wnosi tyle samo ocen do zbioru ocen rozwiązań niezdominowanych, zbudowanego po zsumowaniu zbiorów przybliżających. Zbiór przybliżający  $\Psi_{\text{sym1-3}}$  jest znacznie gorszej jakości od pozostałych ze względu na wszystkie przyjęte składowe wektorowego wskaźnika jakości **QI**.

W odniesieniu do badanych strategii ewolucyjnego algorytmu optymalizacji wielokryterialnej można sformułować wniosek, że strategia polegająca na losowym wyborze wartości współczynników wagowych  $w_s$  skalarnych kryteriów optymalizacji z przedziału  $[0, 1]$  jest najbardziej skuteczna. Strategia polegająca na przyjęciu ustalonych wartości współczynników wagowych  $w_s$  okazała się tylko nieco mniej skuteczna. Strategia polegająca na losowym wyborze pojedynczych kryteriów optymalizacji w każdej operacji selekcji jest znacznie mniej skuteczna od pozostałych.

Końcowy wniosek może być sformułowany w następującej postaci: Jeśli (1) minimalizacja odległości od oceny asymptotycznej, (2) maksymalizacja rozpiętości i (3) głębokości zbioru przybliżającego, (4) maksymalizacja części przestrzeni ocen zdominowanej przez zbiór przybliżający oraz (5) maksymalizacja udziału w sumie ocen niezdominowanych poprawnie reprezentują preferencje decydenta, to na podstawie rezultatów uzyskanych w trzech przeprowadzonych symulacjach komputerowych (sym1-1, sym1-2 i sym1-3) można stwierdzić, że: (1) najbardziej skuteczna jest strategia skalaryzacji funkcji celu, polegająca na losowym wyborze wartości współczynników wagowych kryteriów optymalizacji; (2) w nieco mniejszym stopniu skuteczna jest strategia, polegająca na przyjęciu ustalonych wartości współczynników wagowych kryteriów optymalizacji; (3) wyraźnie mniej skuteczna jest strategia, polegająca na losowym wyborze jednego kryterium optymalizacji w przypadku każdorazowego obliczania funkcji przystosowania.

#### 9.4.2. Seria 2.

Do ilościowej oceny jakości zbiorów przybliżających  $\Psi_{\text{sym}i}$ , otrzymanych w serii symulacji uwzględniających podczas selekcji osobników atrybuty dominacji oraz odległość od rozwiązania asymptotycznego, zastosowano – podobnie jak w przypadku serii 1. – pięć jednoargumentowych skalarnych wskaźników jakości (6.14)–(6.18), które można traktować jako składowe pięciowymiarowego wektorowego wskaźnika jakości (6.19). Osiągnięte w poszczególnych symulacjach serii 2. wartości przyjętych skalarnych wskaźników jakości zestawiono w tablicy 9.1 i przedstawiono na rysunku 9.2.

Dla poszczególnych symulacji w serii 2. (sym2-1, sym2-2 i sym2-3) pięciowymiarowe wektorowe wskaźniki jakości **QI** mają postać:

$$\begin{aligned} \mathbf{QI}(\text{sym2-1}) &= \\ &= [QI_{AD}(\text{sym2-1}) \quad QI_B(\text{sym2-1}) \quad QI_D(\text{sym2-1}) \quad QI_H(\text{sym2-1}) \quad QI_{NF}(\text{sym2-1})]^T = \\ &= [1,021 \quad 20,751^\circ \quad 0,184 \quad 59,6\% \quad 16\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym2-2}) &= \\ &= [QI_{AD}(\text{sym2-2}) \quad QI_B(\text{sym2-2}) \quad QI_D(\text{sym2-2}) \quad QI_H(\text{sym2-2}) \quad QI_{NF}(\text{sym2-2})]^T = \\ &= [1,030 \quad 25,0988^\circ \quad 0,266 \quad 60,7\% \quad 42\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym2-3}) &= \\ &= [QI_{AD}(\text{sym2-3}) \quad QI_B(\text{sym2-3}) \quad QI_D(\text{sym2-3}) \quad QI_H(\text{sym2-3}) \quad QI_{NF}(\text{sym2-3})]^T = \\ &= [1,032 \quad 23,931^\circ \quad 0,231 \quad 62,5\% \quad 42\%]^T \end{aligned}$$

Analiza, sformułowanych wyżej trzech wektorowych wskaźników jakości ewolucyjnych algorytmów optymalizacji wielokryterialnej konstrukcji kadłuba statku, wskazuje zdaniem autora, że zbiór przybliżający, uzyskany w symulacji sym2-2, realizującej strategię polegającą na włączeniu do procesu selekcji licznika dominacji oraz na wyłączeniu kryteriów oceny, szeregowania i odległości od oceny rozwiązania asymptotycznego, okazał się najlepszy – najbliższy oceny asymptotycznej, ma największą szerokość i głębokość, co zapewnia duże zróżnicowanie rozwiązań niezdominowanych. Jednocześnie dominuje nad nieco mniejszą częścią przestrzeni ocen niż zbiór uzyskany w sym2-3 oraz nad nieco większą niż zbiór uzyskany w sym2-1. Uzyskany w tej symulacji zbiór przybliżający, podobnie jak zbiór uzyskany w sym2-3, wniósł największy wkład do agregowanego zbioru przybliżającego.

Zbiór przybliżający, uzyskany w symulacji sym2-3 realizującej strategię włączenia do procesu selekcji tylko odległości od oceny rozwiązania asymptotycznego oraz wyłączenia szeregowania i licznika dominacji, jest nieco gorszej jakości – jest najbardziej (w serii 2.) odległy od rozwiązania asymptotycznego, ma nieco mniejszą szerokość oraz najmniejszą głębokość. Dominuje jednak nad największą częścią przestrzeni ocen oraz, podobnie jak zbiór uzyskany w symulacji sym2-2, wniósł największy wkład do agregowanego zbioru przybliżającego.

Jakość zbioru przybliżającego uzyskanego w symulacji sym2-1 realizującej strategię selekcji jedynie pod względem szeregowania, z wyłączeniem odległości od rozwiązania asymptotycznego oraz licznika dominacji, można ocenić najniżej. Odległość zbioru od oceny rozwiązania asymptotycznego jest wprawdzie najmniejsza wśród wszystkich zbiorów uzyskanych w serii 2., ale szerokość zbioru jest najmniejsza, a głębokość – pośrednia, natomiast zbiór ten dominuje nad najmniejszą częścią przestrzeni ocen oraz wniósł najmniejszy wkład do agregowanego zbioru przybliżającego.

Końcowy wniosek można sformułować w sposób następujący: Jeśli (1) minimalizacja odległości od oceny asymptotycznej, (2) maksymalizacja rozpiętości i (3) głębokości zbioru przybliżającego, (4) maksymalizacja części przestrzeni ocen zdominowanej przez zbiór przybliżający oraz (5) maksymalizacja wkładu do zbioru ocen niezdominowanych poprawnie reprezentują preferencje decydenta, to na podstawie rezultatów uzyskanych w trzech przeprowadzonych symulacjach (sym2-1, sym2-2 i sym2-3) najwyżej oceniono zbiór przybliżający z symulacji sym2-2 realizującej strategię selekcji pod względem licznika dominacji, najniżej zaś oceniono jakość zbioru przybliżającego z symulacji sym2-1 realizującej strategię selekcji pod względem szeregowania, a jako pośrednią uznano jakość zbioru przybliżającego z symulacji sym2-3 realizującej strategię selekcji pod względem odległości od oceny rozwiązania asymptotycznego.

### 9.4.3. Seria 3.

Do ilościowej oceny jakości zbioru przybliżającego, otrzymanego w wyniku serii dziesięciu symulacji (sym3- $i$ ,  $i = 1, 2, \dots, 10$ ), zastosowano cztery jednoargumentowe skalar-

ne wskaźniki jakości (6.14) – (6.17)<sup>1</sup>, które można traktować jako składowe czterowymiarowego wektorowego wskaźnika jakości:

$$\mathbf{QI} = [QI_{AD} \quad QI_B \quad QI_D \quad QI_H]^T \quad (9.1)$$

Dla zbioru przybliżającego, otrzymanego w wyniku symulacji sym3–i, czterowymiarowy wektorowy wskaźnik jakości  $\mathbf{QI}$  ma postać (patrz tablica 9.1 i rysunek 9.3):

$$\begin{aligned} \mathbf{QI}(\text{sym3}–i) &= [QI_{AD}(\text{sym3}–i) \quad QI_B(\text{sym3}–i) \quad QI_D(\text{sym3}–i) \quad QI_H(\text{sym3}–i)]^T = \\ &= [1,005 \quad 17,027^\circ \quad 0,125 \quad 71,9\%]^T \end{aligned}$$

Analiza sformułowanego wektorowego wskaźnika jakości zbioru przybliżającego wskazuje, że jeśli (1) minimalizacja odległości od oceny asymptotycznej, (2) maksymalizacja rozpiętości i (3) głębokości zbioru przybliżającego oraz (4) maksymalizacja części przeszerzenia ocen zdominowanej przez zbiór przybliżający poprawnie reprezentują preferencje decydenta, to zbiór przybliżający, uzyskany w wyniku serii dziesięciu symulacji sym3–i, nie odbiega znacznie pod względem jakości od zbiorów przybliżających uzyskanych w pozostałych pojedynczych symulacjach przeprowadzonych w 1. i 2. serii symulacji.

#### 9.4.4. Seria 4.

Do ilościowej oceny jakości zbiorów przybliżających, otrzymanych w serii trzech symulacji (sym1–2–50000, sym12–50000 oraz sym9–50000), zastosowano – podobnie jak w przypadku serii 1. i 2. – pięć jednoargumentowych skalarnych wskaźników jakości (6.14) – (6.18), które można traktować jako składowe pięciowymiarowego wektorowego wskaźnika jakości (6.19). Osiągnięte dla zbiorów przybliżających, otrzymanych w poszczególnych symulacjach, wartości skalarnych wskaźników jakości zestawiono w tablicy 9.1 i na rysunku 9.4.

Pięciowymiarowe wektorowe wskaźniki jakości  $\mathbf{QI}$  dla poszczególnych symulacji w serii 4. (sym1–2–50000, sym12–50000 oraz sym9–50000) mają postać:

$$\begin{aligned} \mathbf{QI}(\text{sym1}–2–50000) &= \\ &= [QI_{AD}(\text{sym1}–2–50000) \quad QI_B(\text{sym1}–2–50000) \quad QI_D(\text{sym1}–2–50000) \\ &\quad QI_H(\text{sym1}–2–50000) \quad QI_{NF}(\text{sym1}–2–50000)]^T = \\ &= [1,016 \quad 21,932^\circ \quad 0,191 \quad 67,7\% \quad 15\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym12}–50000) &= \\ &= [QI_{AD}(\text{sym12}–50000) \quad QI_B(\text{sym12}–50000) \quad QI_D(\text{sym12}–50000) \\ &\quad QI_H(\text{sym12}–50000) \quad QI_{NF}(\text{sym12}–50000)]^T = \\ &= [1,011 \quad 20,010^\circ \quad 0,157 \quad 69,9\% \quad 45\%]^T \end{aligned}$$

$$\begin{aligned} \mathbf{QI}(\text{sym9}–50000) &= \\ &= [QI_{AD}(\text{sym9}–50000) \quad QI_B(\text{sym9}–50000) \quad QI_D(\text{sym9}–50000) \\ &\quad QI_H(\text{sym9}–50000) \quad QI_{NF}(\text{sym9}–50000)]^T = \\ &= [1,016 \quad 19,854^\circ \quad 0,128 \quad 73,0\% \quad 40\%]^T \end{aligned}$$

---

<sup>1</sup> Nie porównywano poszczególnych symulacji pod względem wkładu do zsumowanego zbioru ocen niezdominowanych, mierzonego wskaźnikiem  $\mathbf{QI}_{NF}$ .

Analiza wektorowych wskaźników jakości zbiorów przybliżających  $\Psi_{\text{sym}i}$ , uzyskanych w trakcie trzech symulacji, wskazuje, że zbiór przybliżający otrzymany w trakcie symulacji sym9–50000, realizującej strategię polegającą na bardzo silnym wpływie na proces selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego, można ocenić, zdaniem autora, najwyżej – ma wprawdzie najmniejsze rozmiary (szerokość i głębokość) i jest najbardziej odległy od oceny rozwiązania asymptotycznego (podobnie jak w przypadku symulacji sym1–2–50000), dominuje jednak nad największą częścią przestrzeni ocen oraz wnosi znaczny wkład do agregowanego zbioru przybliżającego, będącego zbiorem rozwiązań niezdominowanych wyłonionym ze zbiorów przybliżających uzyskanych w poszczególnych symulacjach serii. Jeśli preferencje decydenta reprezentowane są tylko przez wielkość zdominowanej części przestrzeni ocen rozwiązań, to zbiór ten można uznać za najlepszy zbiór przybliżający wśród zbiorów przybliżających uzyskanych we wszystkich symulacjach.

Jakość zbioru przybliżającego uzyskanego w symulacji sym12–50000, realizującej strategię polegającą na umiarkowanym wpływie na proces selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego, można ocenić jako pośrednią – poza odległością od oceny asymptotycznej, której wartość jest najmniejsza wśród wszystkich symulacji serii oraz wkładem do zbioru ocen niezdominowanych, którego wartość jest największa; wartości wszystkich skalarnych wskaźników jakości przyjmują wartości pośrednie. Jeśli chodzi o wkład do zbioru ocen rozwiązań niezdominowanych, to zbiór ten jest najlepszy wśród zbiorów uzyskanych w serii.

W przypadku symulacji sym1–2–50000, realizującej strategię polegającą na wyłączeniu wpływu na proces selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego, jakość uzyskanego zbioru przybliżającego można ocenić najniżej<sup>2</sup> – zbiór przybliżający ma wprawdzie największe rozmiary (szerokość i głębokość), jest jednak najbardziej odległy od oceny rozwiązania asymptotycznego (podobnie jak w przypadku symulacji sym9–50000), dominuje nad najmniejszą częścią przestrzeni ocen oraz wnosi najmniejszy wkład do agregowanego zbioru przybliżającego.

Przedstawiona dyskusja jakości zbiorów przybliżających uzyskanych w serii trzech dużych symulacji może wskazywać na to, że wykorzystanie w procesie selekcji wariantów atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego może pozwolić na uzyskanie lepszych zbiorów przybliżających od zbiorów wygenerowanych przy wykorzystanie kryteriów optymalizacji. Może to wskazywać na korzyści wynikające z zastosowania zaproponowanej kombinowanej funkcji przystosowania. Bardziej zdecydowane stwierdzenie w tej sprawie powinno być poprzedzone bardziej obszernymi i szczegółowymi badaniami obejmującymi także analizę statystyczną uzyskanych wyników.

Porównując zbiory przybliżające wygenerowane w dwóch symulacjach – sym1–2 i sym1–2–50000 ( $\Psi_{\text{sym}1-2}$  i  $\Psi_{\text{sym}1-2-50000}$ ) – patrz rysunek K.1, uzyskane w dwóch symulacjach różniących się jedynie liczbą pokoleń, czyli długością trwania symulacji, można potwierdzić, zgodnie z oczekiwaniami, że wydłużenie czasu symulacji pozwala uzyskać zbiór przybliżający lepszej jakości. Zbiór przybliżający  $\Psi_{\text{sym}1-2-50000}$  dominuje nad zbiorem

---

<sup>2</sup> Pamiętać jednak należy, że w przypadku tej symulacji przy tej samej liczbie pokoleń liczba osobników jest najmniejsza w porównaniu z pozostałymi symulacjami z tej serii (patrz tablica 8.1).

$\Psi_{\text{sym}1-2}$  ( $\Psi_{\text{sym}1-2-50000} \succ \Psi_{\text{sym}1-2}$ ), poza tym charakteryzują go lepsze wartości wszystkich skalarnych wskaźników jakości – tablica 9.1.

Porównując zbiory przybliżające  $\Psi_{\text{sym}12-50000}$  i  $\Psi_{\text{sym}9-50000}$  (patrz rysunek L.1) uzyskane w trakcie dwóch symulacji (sym12–50000 i sym9–50000) różniących się zwiększeniem, w przypadku symulacji sym9–50000, wpływu atrybutów dominacji i odległości od oceny rozwiązania asymptotycznego na proces selekcji wariantów, można stwierdzić, że różnica w jakości zbiorów przybliżających nie jest już tak oczywista. Relacja dominacji, zastosowana w przypadku zbiorów przybliżających, nie pozwala na ocenę względnej jakości zbiorów. Poza wyraźnym zwiększeniem zdominowanej części przestrzeni ocen wartości pozostałych składowych także nie pozwalają określić względnej jakości zbiorów.

Końcowy wniosek można sformułować w następujący sposób: Jeśli (1) minimalizacja odległości od oceny asymptotycznej, (2) maksymalizacja rozpiętości i (3) głębokości zbioru przybliżającego, (5) maksymalizacja części przestrzeni ocen zdominowanej przez zbiór przybliżający oraz (5) maksymalizacja wkładu do zbioru ocen niezdominowanych poprawnie reprezentują preferencje decydenta, to na podstawie rezultatów uzyskanych w wyniku trzech symulacji (sym1–2–50000, sym12–50000 i sym9–50000) najwyżej oceniono zbiór przybliżający uzyskany w trakcie symulacji sym9–50000 realizującej strategię polegającą na bardzo dużym wkładzie do procesu selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego; najniżej oceniono jakość zbioru przybliżającego uzyskanego w trakcie symulacji sym1–2–50000 realizującej strategię polegającą na wyłączeniu z procesu selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego. Jako pośrednią oceniono jakość zbioru przybliżającego uzyskanego w trakcie symulacji sym12–50000 realizującej strategię polegającą na umiarkowanym wkładzie do procesu selekcji atrybutów dominacji oraz odległości od oceny rozwiązania asymptotycznego.

## 9.5. Podsumowanie i wnioski

Uzyskane w trakcie poszczególnych symulacji komputerowych zbiory przybliżające  $\Psi_{\text{sym}i}$  poddano krytycznej ocenie za pomocą metody oceny wizualnej, metody relacji dominacji oraz metody wskaźników jakości. Wyniki oceny wskazują na różną jakość zbiorów, mogącą także wskazywać na różną skuteczność badanych strategii ewolucyjnego algorytmu optymalizacji wielokryterialnej możliwych do realizacji dzięki wykorzystaniu zaproponowanej kombinowanej funkcji przystosowania. Niestety, w przypadku algorytmów ewolucyjnych, realizujących ukierunkowaną, lecz losową ewolucję rozwiązań, ocena jakości zbiorów przybliżających, wygenerowanych przez algorytmy optymalizacji wielokryterialnej, jest również zadaniem, które powinno być rozwiązane pod względem wielu kryteriów oceny, na przykład ujętych w skalarnym wskaźniku jakości. A w takim przypadku, jak wiadomo, nie ma jednoznacznego rozwiązania. Niemniej jednak osiągnięte rezultaty mogą wskazywać na to, że uwzględnienie w procesie selekcji wariantów atrybutów dominacji i odległości od oceny rozwiązania asymptotycznego może być atrakcyjną propozycją ze względu na jakość uzyskanych rozwiązań i skuteczność algorytmu. Wyniki te mogą stanowić także punkt wyjścia bardziej obszernych i szczegółowych badań obejmujących także analizę statystyczną uzyskanych wyników.

Wnioski, sformułowane podczas oceny jakości rozwiązań oraz rozszerzone na ocenę skuteczności algorytmów optymalizacyjnych, nie mogą być przyjęte jako generalne w przypadku badanych metod i zadań optymalizacji, są jednak praktyczną prezentacją zaproponowanej metody zmierzającej do bardziej obiektywnej i krytycznej oceny zbiorów przybliżających, wygenerowanych przez różne algorytmy optymalizacyjne lub wygenerowanych przez te same algorytmy, lecz uruchamiane przy różnych wartościach parametrów sterujących. Mogą również stanowić przesłankę do oceny skuteczności alternatywnych strategii/algorytmów ewolucyjnej optymalizacji wielokryterialnej.

## 10. Zakończenie

Dzięki coraz większym możliwościom ogólnie dostępnych komputerów oraz rozwojowi algorytmów obliczeniowych wielokryterialna optymalizacja konstrukcji kadłuba statków morskich rozwija się stale od prawie 50 lat. Odzwierciedla się to w publikacjach powstających, niestety, prawie wyłącznie w środowiskach akademickich lub centrach badawczych współpracujących z uczelniami. Pomimo stałego postępu w opracowywaniu algorytmów oraz narzędzi obliczeniowych przykładów zastosowania metod optymalizacyjnych do realizacji rzeczywistych projektów jest bardzo mało.

Powszechnie akceptowanym rozwiązaniem zadania z wieloma sprzecznymi względem siebie kryteriami oceny jest zbiór rozwiązań niezdominowanych w sensie Pareto. Ponieważ w praktycznych zagadnieniach pełen zbiór rozwiązań optymalnych Pareto, zawierający wszystkie rozwiązania niezdominowane, nie może być otrzymany, jako rezultat optymalizacji wielokryterialnej przyjęto jego przybliżenie, to znaczy skończony zbiór rozwiązań niezdominowanych, których oceny pokrywają front ocen optymalnych Pareto z akceptowalną rozdzielczością. Taki front Pareto (a dokładniej: jego przybliżenie) może być użyty przez projektanta jako źródło intuicji o charakterze konfliktu i możliwych kompromisach pomiędzy różnymi kryteriami. Na tej podstawie może on podjąć decyzję o wyborze najbardziej zadowalającego kompromisu.

Dokonany przegląd najważniejszych prac badawczych i aplikacyjnych, dotyczących wielokryterialnej optymalizacji konstrukcji kadłuba statków morskich, uzasadnia stwierdzenie, że skuteczne poszukiwanie zbioru rozwiązań niezdominowanych stało się w praktyce projektowej możliwe dopiero dzięki zastosowaniu ewolucyjnych algorytmów optymalizacji wielokryterialnej w 90. latach XX wieku. Badania podjęte i opisane w niniejszej pracy są względnie nowym i bardzo interesującym obszarem aktywności naukowej również dlatego, że wiele problemów nadal jest nierozwiązanych. Propozycje rozwiązania niektórych przedstawiono w tym opracowaniu.

Z punktu widzenia metodyki projektowania statków morskich za obiecujący temat prac badawczych można uznać rozwój platform optymalizacji współbieżnej, które mogą być krokiem pośrednim pomiędzy serią/sekwencją następujących po sobie optymalizacji lokalnych a całkowicie globalną optymalizacją, która – jak się wydaje – nie będzie jeszcze możliwa przez długi czas. Optymalizacja globalna wymaga sformułowania i rozwiązania zunifikowanych zadań optymalizacji obejmujących w jednej formie cząstkowe zadania optymalizacji rozwiązywane w procesach optymalizacji lokalnej. Praca ta przedstawia wizję autora dotyczącą ograniczonego obszaru, którym jest optymalizacja konstrukcji kadłuba statku, będąca częścią współbieżnej i wielodyscyplinarnej optymalizacji statku.

Autor opracował, szczegółowo opisał oraz zweryfikował metodę umożliwiającą realizację ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku morskiego (i podobnych konstrukcji inżynierskich) na etapie projektu wstępnego.

Przedstawiona w pracy metoda formułowania i rozwiązywania zunifikowanego częściowo zadania wielokryterialnej optymalizacji wymiarów i topologii elementów konstrukcji kadłuba statku morskiego obejmuje: (1) identyfikację przedmiotu optymalizacji – konstrukcji kadłuba statku morskiego, ze szczególnym uwzględnieniem cech statku wpływających na przestrzenne rozmieszczenie i wymiarowanie elementów konstrukcyjnych; (2) formułowanie założeń projektowania konstrukcji kadłuba, np. dotyczących rodzaju i charakterystyki materiału konstrukcyjnego, warunków eksploatacji, sposobów załadowania statku i wynikających z tego obciążeń konstrukcji; (3) sformułowanie odpowiedniego modelu konstrukcji kadłuba – od modelu konstrukcyjnego, poprzez model optymalizacyjny, do modelu genetycznego nadającego się do zastosowania algorytmu genetycznego; (4) wykonanie obliczeń testowych w celu ustalenia wartości parametrów sterujących; (5) zaplanowanie oraz przeprowadzenie symulacji komputerowych według opracowanego ewolucyjnego algorytmu optymalizacji wielokryterialnej z kombinowaną funkcją przystosowania; (6) analizę wyników symulacji komputerowych; (7) ocenę jakości uzyskanych zbiorów przybliżających, z wykorzystaniem zaproponowanych wektorowych wskaźników jakości; (8) ocenę skuteczności algorytmów optymalizacyjnych, z wykorzystaniem zaproponowanych wektorowych wskaźników jakości; (9) sformułowanie wniosków z wykonanych obliczeń optymalizacyjnych; (10) sporządzenie sprawozdania i przekazanie wyników zamawiającemu obliczenia optymalizacyjne.

Do symulacji komputerowych, weryfikujących skuteczność opracowanej metody, przyjęto zlokalizowaną na śródkręciu sekcję przestrzenną konstrukcji kadłuba szybkiego promu pasażersko-samochodowego, zbudowanego w układzie katamarana. Na podstawie dostępnych informacji o projekcie wybranego statku opracowano niezbędne modele konstrukcji. Na modelach tych przeprowadzono wiele symulacji komputerowych, a uzyskane rezultaty szczegółowo przedyskutowano.

Zwrócono uwagę na trudny do rozwiązania problemem weryfikacji obliczeń optymalizacyjnych z rzeczywistymi konstrukcjami statków. Informacje o zaprojektowanej konstrukcji dostępne są przede wszystkim w formie dokumentacji rysunkowej, opracowanej na podstawie wymagań towarzystw klasyfikacyjnych oraz wielu analiz obliczeniowych. Na wymiary konstrukcji mają także wpływ dotychczasowe doświadczenie i wiedza konstruktora, będące źródłem wprowadzenia do projektu dodatkowych korekt, które są bardzo trudne lub wręcz niemożliwe do zapisania w algorytmie optymalizacyjnym. Z oczywistych względów nie ma także możliwości wyizolowania takiego heurystycznego wkładu w dostępnej informacji o projekcie konstrukcji. Algorytm optymalizacyjny, realizowany w formie programu komputerowego, uwzględnia jednak tylko procedury i wymagania przyjęte i zapisane przez autora w kodzie programu komputerowego. Jeśli „tradycyjny” projektant i autor systemu obliczeniowego nie współpracują ze sobą ściśle i jeżeli nie uzgodnią szczegółowo wszystkich procedur, to wyniki będą niemożliwe do porównania. Oczywiście dodatkowo trzeba pamiętać, że konstrukcja kadłuba statku morskiego jest systemem bardzo złożonym, w związku z czym dzisiaj jeszcze nie może on być zoptymalizowany dokładnie w takiej formie, w jakiej został zaprojektowany. Liczba i stopień dokonanych uproszczeń jest tak duża, że osiągnięte wyniki analiz optymalizacyjnych powinny być traktowane z ostrożnością. Z tego względu podjęte przez autora badania uznać można za badania przede wszystkim na poziomie podstawowym. Zatem opracowanie wielu szczegółowych procedur oraz zbadanie możliwości



zastosowania opracowanych algorytmów do optymalizacji konstrukcji kadłuba statków można uznać za zadowalający rezultat podjętej pracy.

Zdaniem autora najistotniejszymi oryginalnymi elementami przedstawionej pracy są: (1) sformułowanie i rozwiązanie częściowo zunifikowanego problemu optymalizacji konstrukcji kadłuba statku – optymalizacji topologii i optymalizacji wymiarów elementów konstrukcyjnych; (2) opracowanie metody i narzędzia obliczeniowego umożliwiającego skuteczne odszukanie zadowalającego przybliżenia rzeczywistego<sup>1</sup> zbioru optymalnych w sensie Pareto wariantów konstrukcji kadłuba statku; (3) opracowanie, opartej na wektorowych wskaźnikach jakości, metody analizy jakości zbiorów przybliżających oraz skuteczności algorytmu optymalizacyjnego.

Za istotne autor uważa także: (4) szczegółowe przedstawienie procesu formułowania kolejnych modeli konstrukcji kadłuba statku – modelu konstrukcji, matematycznego modelu optymalizacyjnego oraz genetycznego modelu optymalizacyjnego; (5) szczegółową dyskusję wyników symulacji komputerowych realizujących ewolucyjną optymalizację wielokryterialną; (6) szczegółową dyskusję dotyczącą jakości zbiorów przybliżających oraz dyskusję nad skutecznością strategii optymalizacyjnych wykorzystujących metody oceny wizualnej, metody relacji dominacji oraz metodę wskaźników jakości.

W sposób oryginalny i właściwy do zastosowania w programach obliczeniowych, realizujących ewolucyjną optymalizację wielokryterialną konstrukcji kadłuba statków morskich, zaproponowano przede wszystkim: (1) sformułowanie funkcji użyteczności kryteriów optymalizacji; (2) sformułowanie funkcji kar za naruszenie ograniczeń; (3) sformułowanie wskaźników dopuszczalności wariantów; (4) opracowanie procedur określania rang wariantów dopuszczalnych (atrybutu dominacji); (5) opracowanie procedur określania licznika dominacji wariantów dopuszczalnych (atrybutu dominacji); (6) określenie oceny rozwiązania asymptotycznego oraz wykorzystanie jej jako (6 a) miary zbieżności algorytmu (kontrola zbieżności algorytmu), (6 b) miary jakości rozwiązania niezdominowanego, (6 c) miary odległości zbioru przybliżającego od oceny rozwiązania asymptotycznego oraz (6 d) miary skuteczności algorytmu optymalizacyjnego; (7) określenie szerokości zbioru ocen rozwiązań niezdominowanych oraz wykorzystanie tego pojęcia jako (7 a) miary zbieżności algorytmu (kontrola zbieżności algorytmu), (7 b) miary jakości zbioru przybliżającego oraz (7 c) miary skuteczności algorytmu optymalizacyjnego; (8) określenie głębokości zbioru ocen rozwiązań niezdominowanych oraz wykorzystanie jej jako (8 a) miary zbieżności algorytmu (kontrola zbieżności algorytmu), (8 b) miary jakości zbioru przybliżającego oraz (8 c) miary skuteczności algorytmu optymalizacyjnego; (9) skalarne i wektorowe wskaźniki jakości oraz metodę ich praktycznego wykorzystania do oceny jakości wygenerowanych zbiorów rozwiązań niezdominowanych, których oceny przybliżają front ocen rozwiązań optymalnych Pareto oraz do oceny skuteczności algorytmów optymalizacyjnych; (10) włączenie atrybutów dominacji oraz odległości ocen rozwiązań niezdominowanych od oceny rozwiązania asymptotycznego do funkcji przystosowania kierującej selekcją rozwiązań, formując w ten sposób oryginalną metodę kombinowanej funkcji przystosowania.

W pracy uzasadniono potrzebę unifikacji zadań optymalizacyjnych konstrukcji kadłuba statku i opracowano metodę umożliwiającą rozwiązanie takiego zadania w pierwszym

---

<sup>1</sup> W tym sensie, że rozwiązuje się oryginalne zadanie optymalizacji, nie zaś zadanie przekształcone do postaci prostszej, łatwiejszej do rozwiązania, np. do postaci zadania zlinearyzowanego.

kroku unifikacji topologii i wymiarów elementów konstrukcyjnych. Na podstawie serii symulacji komputerowych, przeprowadzonych na modelu szybkiego promu pasażersko-samochodowego, wykazano skuteczność opracowanej metody w rozwiązywaniu takich zadań. Zaproponowano kombinowaną funkcję przystosowania, która powinna umożliwić skuteczną optymalizację także przy większej liczbie kryteriów. Zaobserwowano, w jaki sposób budowany jest zbiór przybliżający w toku symulowanej ewolucji rozwiązań. Wykazano, że ograniczenia zacierają różnice pomiędzy strategiami optymalizacji wielokryterialnej. Zaproponowano prześledzenie ewolucji pokoleń za pomocą miar: funkcji przystosowania, szerokości zbioru przybliżającego, głębokości zbioru przybliżającego i odległości zbioru przybliżającego od oceny rozwiązania asymptotycznego. Zaproponowano też wektorowe wskaźniki jakości do pomiaru jakości zbiorów przybliżających i skuteczności algorytmów.

Deskryptywnymi walorami przygotowanej pracy są szczegółowe opisy: (1) zadań optymalizacji konstrukcji kadłuba statku morskiego pod kątem wymagań stawianych metodom rozwiązywania takich zadań; (2) podstaw teoretycznych optymalizacji wielokryterialnej, a w szczególności ewolucyjnej optymalizacji wielokryterialnej; (3) relacji preferencji, wykorzystywanych do zdefiniowania wzajemnych relacji pomiędzy pojedynczymi rozwiązaniami niezdominowanymi oraz zbiorami przybliżającymi zawierającymi oceny rozwiązań niezdominowanych przybliżające front ocen rozwiązań optymalnych Pareto; (4) mierzalnych wielkości pozwalających prześledzić ewolucję zbiorów przybliżających podczas symulacji komputerowych; (5) metody oceny jakości zbiorów przybliżających i skuteczności algorytmów ewolucyjnych; (6) procedur obliczeniowych opracowanego systemu programów komputerowych.

Za eksplanacyjny walor pracy uznać można wyjaśnienie, w jaki sposób ewolucyjny algorytm optymalizacji wielokryterialnej buduje zbiór przybliżający front ocen rozwiązań optymalnych Pareto. W serii symulacji komputerowych wykazano, że zbiór przybliżający jest oddzielną częścią zbioru ocen dopuszczalnych, którego zasadnicza część zajmuje w przybliżeniu stałe miejsce w przestrzeni ocen. Zbiór przybliżający zajmuje obszar znacznie bliższy ocenie rozwiązania asymptotycznego i co jakiś czas jest zasilany przez oceny nowych rozwiązań niezdominowanych pojawiające się dzięki korzystnym mutacjom generowanych wariantów.

Walory prognostyczne pracy polegają na opracowaniu i zweryfikowaniu w serii symulacji komputerowych metody pozwalającej przewidywać na etapie projektu wstępnego charakterystyki konstrukcji kadłuba statku morskiego, a w konsekwencji także charakterystyki statku jako całości.

W pracy przeprowadzono symulację dotyczącą jednego wybranego statku, traktując go jako demonstrator dla opracowanej metody. Zdaniem autora możliwości wykorzystania wyników pracy, czyli opracowanej metody, wykraczają poza optymalizację konstrukcji kadłuba statków morskich i mogą być zastosowane do wielokryterialnej optymalizacji innych obiektów inżynierskich po zaimplementowaniu odpowiednich procedur obliczeniowych specyficznych dla rozwiązywanego problemu.

Dążąc do zmniejszenia trudności związanych z porównywaniem wyników symulacji komputerowych z charakterystykami konstrukcji rzeczywistych, wyniki symulacji komputerowych zweryfikowano, porównując je z wynikami tradycyjnego projektowania ręcznego prowadzonego w kontrolowanych warunkach. Porównanie to umożliwiło pozytywną weryfikację opracowanej metody oraz osiągnięcie ok. 10% oszczędności ciężarowych dzięki jej zastosowaniu do wielokryterialnej optymalizacji wymiarów i topologii konstrukcji kadłuba statku.

Wyniki przeprowadzonych symulacji komputerowych wskazują, że opracowane narzędzie obliczeniowe zachowuje dużą rozpiętość zbioru przybliżającego. Oznacza to duże zróżnicowane ocen rozwiązań w zbiorze przybliżającym oraz istotną rolę decydenta w procesie wyboru jednego rozwiązania lub większej liczby rozwiązań do dalszych prac projektowych.

Z praktycznego punktu widzenia interesujące jest spostrzeżenie, że tylko niektóre sformułowane w modelu optymalizacyjnym ograniczenia są aktywne w procesie optymalizacji. W ich przypadku uzasadnione są nawet duże nakłady obliczeniowe niezbędne do ich skontrolowania. W przypadku ograniczeń nieaktywnych poniesione nakłady obliczeniowe mogą okazać się zbędne z punktu widzenia skuteczności procesu optymalizacji, a w niektórych przypadkach można nawet zaniechać ich kontrolowania. W przyjętym w pracy modelu optymalizacyjnym aktywne okazały się ograniczenia dotyczące zgodnej z przepisami wartości wskaźnika na zginanie przekroju ram poprzecznych w trzech rejonach konstrukcyjnych: burty zewnętrznej, dna oraz pokładu „mokrego”. Pozostałe ograniczenia, dotyczące przede wszystkim wymaganych grubości płyt poszycia oraz wymiarów usztywnień znacznie przekraczają dopuszczalne wartości.

W przygotowywaniu symulacji komputerowych dużą rolę odgrywają trudne do systematycznego dokumentowania obliczenia testowe (próbne) przeprowadzane w celu ustalenia wartości parametrów modelu optymalizacyjnego i wartości parametrów sterujących. Przy braku uznanych analitycznych metod oceny zbieżności algorytmów optymalizacyjnych jest to podstawowa, a jednocześnie trudna do algorytmicznego sformułowania metoda rozwiązania tego problemu. Pozostaje więc postępowanie heurystyczne, w którym bardzo istotną rolę odgrywają wiedza i doświadczenie użytkownika.

Przedstawione wyniki badań optymalizacyjnych są przykładem badania wrażliwości zbioru przybliżającego i ocen rozwiązań najbliższych ocenie rozwiązania asymptotycznego (rekomendowanych kompromisów) na zmiany strategii ewolucyjnej optymalizacji wielokryterialnej. Badania wrażliwości rozwiązań na zmiany właściwości konstrukcji, np. na zmiany materiału konstrukcyjnego oraz na zmiany parametrów symulacji, np. prawdopodobieństw operacji genetycznych, będą tematem następnych badań.

Przedstawiona w pracy dyskusja nad jakością wyników uzyskanych w wyniku symulacji komputerowych wskazuje na to, że zastosowanie zaproponowanej kombinowanej funkcji przystosowania może zwiększyć skuteczność ewolucyjnych algorytmów optymalizacji wielokryterialnej. Wyrażenie bardziej zdecydowanej opinii na ten temat powinno być poprzedzone bardziej obszernymi i szczegółowymi badaniami obejmującymi także analizę statystyczną uzyskanych wyników.

Propozycje autora i wyniki badań, przeprowadzonych za pomocą opracowanych własnych programów komputerowych, uzyskały pozytywne recenzje i zostały opublikowane (Sekulski 2009, 2010, 2011 a, b, c).

W środowiskach naukowych oraz coraz częściej w środowiskach praktyków docenia się rolę optymalizacji, co odzwierciedla się w znacznym już dorobku naukowym w tym zakresie. Notuje się stale nowe publikacje w czasopismach naukowych oraz publikacje książkowe. Właśnie mija 30 lat istnienia krajowej konferencji, poświęconej optymalizacji i optymalizacji wielokryterialnej, pt. „Polioptrymalizacja i komputerowe wspomaganie projekto-

wanie”, dokumentującej znaczny już dorobek środowiska skupionego wokół niej. Niestety, rosnące oczekiwania i znaczne już osiągnięcia teoretyczne nie doczekały się istotnych zastosowań praktycznych, szczególnie w przypadku optymalizacji wielokryterialnej konstrukcji kadłuba statków morskich. Wydaje się, że najważniejszymi przyczynami są: (1) brak dostatecznej znajomości metod optymalizacji, a w szczególności optymalizacji wielokryterialnej; (2) brak zaufania do ewolucyjnych metod optymalizacji wielokryterialnej, mimo ich potwierdzonej skuteczności, spowodowany brakiem odpowiedniej teorii matematycznej (brak potwierdzonej teoretycznie zbieżności algorytmów); (3) nieadekwatne kryteria optymalizacji (w tym przede wszystkim nieuwzględnianie losowych i rozmytych właściwości optymalizowanych obiektów); (4) brak odpowiednich modeli matematycznych kryteriów optymalizacji i ograniczeń; (5) niechęć niektórych praktyków do rezultatów optymalizacji wielokryterialnej przedstawianej w postaci zbiorów równocennych rozwiązań zamiast wskazania pojedynczego rozwiązania; (6) ograniczenia czasowe procesu projektowania utrudniające lub uniemożliwiające opracowanie odpowiednich modeli obliczeniowych i przeprowadzenie obliczeń komputerowych; (7) trudności w prezentowaniu rozwiązań zadań optymalizacji wielokryterialnej (graficzne prezentowanie wielowymiarowych przestrzeni ocen).

Konstruktorzy kadłuba statków morskich, podobnie jak inżynierowie innych specjalności, często mają do czynienia z problemami, które są dobrze znane, lecz trudności z nimi związane są zbyt złożone, by można je było rozwiązać w sposób dokładny. Badania naukowe skupiają się więc na znalezieniu metod rozwiązywania tych problemów w sposób przybliżony, a przy tym jak najbardziej dokładny. Przedstawiona w pracy metoda ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku morskiego oraz jej implementacja w postaci systemu programów komputerowych jest propozycją rozwiązania wielokryterialnego zadania projektowego, które w projektowaniu znane jest od dawna, lecz w sposób systematyczny i zracjonalizowany nie było rozwiązywane.

Prowadzone od prawie 20 lat prace doprowadziły do opracowania wielu ewolucyjnych algorytmów optymalizacji wielokryterialnej opartych przede wszystkim na relacji dominacji w sensie Pareto. Po wykazaniu skuteczności tych metod w rozwiązywaniu wielu problemów testowych i zadań praktycznych używane wcześniej metody wykorzystujące skalaryzację funkcji celu zostały uznane za zbyt proste i mało skuteczne oraz nierokujące nadziei na dalszy rozwój. W ciągu ostatnich kilku lat opublikowano jednak wyniki badań, które sugerują, że oparte na relacji dominacji algorytmy ewolucyjne mogą być nieskuteczne w rozwiązywaniu zagadnień opisywanych za pomocą modelu zawierającego więcej niż trzy kryteria optymalizacji. Niektórzy badacze uważają, że w takich przypadkach skuteczne mogą okazać się właśnie zaniechane algorytmy skalaryzujące. W pracy tej autor przedstawia własną propozycję ewolucyjnego algorytmu optymalizacji wielokryterialnej konstrukcji kadłuba statku łączącej zalety obu wymiennych grup metod optymalizacji.

W pracy wskazano, że optymalizacja wielokryterialna nie stała się dotychczas powszechnie używanym narzędziem wspomagania projektowania konstrukcji kadłuba statku morskiego oraz że istnieje potrzeba formułowania zunifikowanych zadań wielokryterialnej optymalizacji konstrukcji kadłuba statku i opracowania skutecznych metod ich rozwiązywania. Przedyskutowano podstawowe elementy teoretyczne optymalizacji wielokryterialnej, ze szczególnym uwzględnieniem ewolucyjnej optymalizacji wielokryterialnej oraz zapropono-

wano własne, oryginalne, rozwiązania niektórych problemów. Wykorzystując sformułowane propozycje, opracowano metodę ewolucyjnej optymalizacji wielokryterialnej oraz zbudowano narzędzie obliczeniowe, które jest jej komputerową realizacją. Wstępne wyniki obliczeń uzasadniły przewidywanie, że opracowana metoda oraz zbudowane narzędzie obliczeniowe będą skutecznym narzędziem do wielokryterialnej optymalizacji konstrukcji kadłuba statku morskiego. W celu weryfikacji tego przewidywania przeprowadzono serie symulacji komputerowych, a otrzymane rezultaty potwierdziły skuteczność opracowanej metody.

Istotnym i nierozwiązanym do końca problemem pozostaje ilościowa ocena jakości uzyskanych zbiorów przybliżających oraz ocena skuteczności algorytmów optymalizacyjnych. Opracowane dotychczas metody oceny nie pozwalają skutecznie rozstrzygnąć o jakości otrzymanych rezultatów. Ponieważ zaakceptowano fakt, że nie można wybrać jedynego obiektywnie najlepszego rozwiązania zadania optymalizacji wielokryterialnej, należy pogodzić się z faktem, że także na wyższym poziomie zbiorów przybliżających lub algorytmów optymalizacji nie można obiektywnie wskazać najlepszego rozwiązania, ponieważ jest to również wielokryterialnym zadaniem wyboru. Jeśli zatem istnieje swoboda wyboru jednego rozwiązania, którego ocena należy do zbioru przybliżającego, to istnieje również swoboda wyboru zbioru przybliżającego oraz swoboda wyboru narzędzia do rozwiązania zadania optymalizacji wielokryterialnej. Poza oczywistymi przypadkami błędnych algorytmów użytkownik może wybrać dowolny algorytm dostosowany do jego potrzeb i jeśli na podstawie obliczeń testowych uzna go za skuteczny, to wybór ten można zaakceptować.

Zdaniem autora zastosowanie opracowanej metody do optymalizacji wielokryterialnej we wstępnym projektowaniu konstrukcji kadłuba statku morskiego może przynieść następujące korzyści: (1) może stanowić skuteczne wspomaganie procesu decyzyjnego; (2) może pozwolić odkrywać nowe obszary rozwiązań nieeksplorowane wcześniej podczas klasycznego projektowania konstrukcji kadłuba statku; (3) zastosowanie opracowanej metody może stymulować projektantów do krytycznej analizy i rewizji własnych celów i preferencji, a także do formułowania ich w kategoriach formalnych modelu optymalizacyjnego; (4) może stanowić środek integrujący narzędzia obliczeniowe do analizy konstrukcji kadłuba statków; (5) może być podstawą dyskusji podczas negocjacji kontraktowych oraz prac projektowych; (6) może umożliwić ilościowe zdefiniowanie kompromisu pod względem przyjętych kryteriów oceny; (7) może być narzędziem do formułowania i formalizowania osobistych preferencji projektanta (w postaci systemu wartości); (8) może ułatwić, a w niektórych przypadkach wręcz umożliwić konstruktorowi zorientowanie się w wieloaspektowej sytuacji projektowej.

We wstępnym projektowaniu konstrukcji kadłuba statków morskich przygotowana praca może zaspokoić następujące potrzeby: (1) wspomaganie wstępnego projektowania konstrukcji kadłuba statków, ponieważ umożliwia zwiększenie stopnia sformalizowania procesu decyzyjnego; (2) przybliżenia momentu wprowadzenia optymalizacji wielokryterialnej do powszechnego użycia w badaniach naukowych, a przede wszystkim w pracach projektowych; (3) kształcenia studentów oraz projektantów w zakresie inżynierskiego zastosowania metod optymalizacji wielokryterialnej; (4) uzyskania w akceptowanym czasie zadowalających rozwiązań wielokryterialnego zadania optymalizacji konstrukcji kadłuba statku dzięki wskazaniu metody do zbudowania szybkiego narzędzia obliczeniowego oraz odpowiedniego sformułowania zadania optymalizacyjnego (modelu optymalizacyjnego); (5) inicjowania

prac zmierzających do opracowania skutecznych i szybkich modeli matematycznych oraz metod obliczeniowych umożliwiających uwzględnienie w ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statków także kosztów, wytrzymałości, niezawodności, aby można było zastosować adekwatne miary jakości wariantów konstrukcyjnych, w tym także do opracowania ujęcia stochastycznego i opisu rozmytego.

W pracy przedstawiono oryginalną metodę ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku morskiego. Większość zaproponowanych rozwiązań jest oryginalna, część z nich stanowi oryginalne rozszerzenie koncepcji innych autorów, część zaś opracowanych niezależnie ma swoje odpowiedniki w propozycjach innych autorów. Szczególnie istotnym oryginalnym dorobkiem autora są: koncepcja kombinowanej funkcji przystosowania, obserwacja procesu budowy zbiorów przybliżających, matematyczne sformułowanie składowych funkcji kar za naruszenie ograniczeń oraz metoda oceny jakości zbiorów przybliżających za pomocą wektorowych wskaźników jakości. Ocena jakości zbiorów przybliżających zwraca szczególną uwagę, ponieważ jest oryginalną propozycją autora metody oceny jakości uzyskanych rozwiązań, która może być zastosowana w praktycznych problemach optymalizacji wielokryterialnej.

Rezultatem badań opisanych w pracy jest także uzupełnienie bazy teoretycznej wielokryterialnej optymalizacji konstrukcji kadłuba statku poprzez wprowadzenie, wraz z uzasadnieniem, pojęć: (1) unifikacja zadań optymalizacyjnych konstrukcji kadłuba statku; (2) kombinowana funkcja celu integrująca kryteria optymalizacji, atrybuty dominacji, odległość od rozwiązania asymptotycznego, składowe funkcje kary za naruszenie ograniczeń; (3) szerokość zbioru przybliżającego; (4) głębokość zbioru przybliżającego; (5) rozwiązanie asymptotyczne; (6) odległość od rozwiązania asymptotycznego; (7) wektorowy wskaźnik jakości zbiorów przybliżających. Przedstawiono sposób budowy zbioru przybliżającego. Rozszerzono zbiór pojęć związanych z optymalizacją wielokryterialną. Potwierdzono, że można skutecznie połączyć w jednej funkcji celu kryteria optymalizacji, atrybuty dominacji, odległość od rozwiązania asymptotycznego oraz składowe funkcje kary za naruszenie ograniczeń.

Przedstawiona praca dokumentuje także osiągnięcie celu metodycznego w postaci opracowania nowej metody ewolucyjnej optymalizacji wielokryterialnej umożliwiającej rozwiązanie sformułowanego, częściowo zunifikowanego, zadania wielokryterialnej optymalizacji konstrukcji kadłuba statku. Metoda ta ulepsza znane metody poprzez zwiększenie ich skuteczności dzięki możliwości śledzenia ewolucji populacji generowanych rozwiązań oraz ocenę jakości uzyskanych zbiorów przybliżających.

W pracy tej obmyślono, uzasadniono i wypróbowano w trakcie badań nową metodę ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku. Opracowano metodę roboczą zastosowaną do konstrukcji kadłuba statków morskich. O jej uniwersalności decydują przede wszystkim: (1) koncepcja kombinowanej funkcji celu ujmującej w jednym wyrażeniu kryteria oceny, składowe funkcje kar za naruszenie ograniczeń, atrybuty dominacji oraz odległość od rozwiązania asymptotycznego; (2) szczegółowe procedury obliczeniowe; (3) zastosowanie wektorowego wskaźnika jakości do oceny jakości zbiorów przybliżających oraz do oceny skuteczności algorytmów obliczeniowych.

Można także sformułować hipotezę, że opracowany algorytm z kombinowaną funkcją przystosowania będzie skuteczny także w przypadku rozwiązywania zadań z wieloma kryteriami oceny – powyżej trzech. Weryfikację tej hipotezy autor umieścił w planie dalszych badań.

W pracy przedstawiono rezultaty symulacji komputerowych przeprowadzonych dla jednego statku w celu zademonstrowania opracowanej metody. Jednak zdaniem autora możliwości wykorzystania wyników pracy (opracowanej metody) wykraczają poza optymalizację konstrukcji kadłuba statków morskich i mogą być z powodzeniem stosowane do wielokryterialnej optymalizacji innych obiektów inżynierskich.

W planowaniu przeprowadzenia optymalizacji wielokryterialnej trzeba brać pod uwagę to, że liczba kryteriów optymalizacji większa niż dwa powoduje istotne trudności w analizie wyników. W większości omówionych w publikacjach przypadków wielokryterialnej optymalizacji konstrukcji kadłuba statków morskich przyjęto dwa kryteria optymalizacji – ciężar i koszt wykonania konstrukcji.

Przeprowadzone symulacje komputerowe potwierdziły skuteczność opracowanej metody oraz zbudowanego narzędzia obliczeniowego w rozwiązywaniu sformułowanego zadania wielokryterialnej optymalizacji, problemu optymalizacyjnego unifikującego zadanie optymalizacji topologii i wymiarów elementów konstrukcyjnych kadłuba statku morskiego. Poszczególne symulacje komputerowe pozwoliły odszukać rozwiązania niezdominowane, których oceny stanowią zbiory przybliżające front ocen wariantów optymalnych Pareto. Spośród odszukanych wariantów decydent może wybrać wariant lub warianty do dalszego etapu projektowania. Opracowana metoda pozwala również wskazać w każdej symulacji jeden wariant, którego ocena jest najbliższa ocenie asymptotycznej, który może być rekomendowany jako jedno rozwiązanie sformułowanego zadania optymalizacji wielokryterialnej.

Sukces w rozwiązaniu zadania optymalizacji wielokryterialnej z użyciem algorytmu ewolucyjnego zależy od gromadzonego przez długi czas i trudnego do udokumentowania doświadczenia specjalisty formułującego modele do obliczeń optymalizacyjnych oraz użytkownika ustalającego wartości parametrów sterujących symulacjami komputerowymi. To właśnie ma autor na myśli, pisząc w wielu miejscach pracy o obliczeniach testowych.

Osiągnięte wyniki są udokumentowane częściowo w publikacjach w renomowanych czasopismach. Autor przygotowuje kolejne publikacje dokumentujące osiągnięte rezultaty.





## 11. Plany badawcze

Autor zdaje sobie sprawę, że omówiony w pracy problem wielokryterialnej optymalizacji konstrukcji kadłuba statku oraz unifikacji podstawowych obszarów optymalizacji tej konstrukcji został rozwiązany tylko częściowo i że wiele problemów wymaga kontynuowania lub nawet podjęcia od podstaw. Głównymi celami kolejnych prac badawczych i aplikacyjnych powinny być: (1) opracowanie modeli konstrukcji innych typów statków i zweryfikowanie skuteczności opracowanego algorytmu na takich modelach; (2) opracowanie procedur obliczeniowych zgodnych z innymi przepisami klasyfikacyjnymi; (3) opracowane procedur obliczeniowych bezpośredniej analizy wytrzymałości konstrukcji, w tym także pozwalających uwzględnić inne ograniczenia wytrzymałościowe, np. nośność graniczną, odporność kolizyjną, odporność zmęczeniową; (4) porównanie skuteczności opracowanego algorytmu ze skutecznością innych algorytmów, np. NSGA-II, SPEA-2; (5) opracowanie procedur statystycznej oceny jakości zbiorów przybliżających oraz dalsze badania skuteczności opracowanych algorytmów, w szczególności z wykorzystaniem metod statystycznych; (6) opracowane procedur wnioskowania rozmytego w optymalizacji wielokryterialnej; (7) sformułowanie liczniejszego zbioru kryteriów optymalizacji (kryteriów oceny) oraz ocena skuteczności (zbieżności) algorytmu dla przypadków z dużą ( $> 3$ ) liczbą kryteriów; (8) opracowanie metod wizualizacji wyników obliczeń optymalizacyjnych dla przypadków z dużą, powyżej trzech ( $> 3$ ), liczbą kryteriów optymalizacji; (9) włączenie do unifikacji pozostałych obszarów optymalizacji konstrukcji kadłuba statków, to znaczy optymalizacji materiału i optymalizacji kształtu; (10) badanie wrażliwości zbioru przybliżającego i rozwiązań najbliższych rozwiązaniu asymptotycznemu (rekomendowanych kompromisów) na zmiany cech konstrukcyjnych, np. materiału konstrukcyjnego, liczby ram poprzecznych; (11) badanie wpływu parametrów modelu optymalizacyjnego i parametrów sterujących optymalizacją na jakość rozwiązań i skuteczność algorytmu.



## **Załączniki**



## Załącznik A

Tablica A.1. Relacje preferencji pomiędzy wektorami ocen (ocenami)

| Relacja                                                  | Interpretacja w przestrzeni ocen      |                                                                                                                                                             |
|----------------------------------------------------------|---------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Silnie dominowana<br>(ang. <i>strictly dominates</i> )   | $\mathbf{f}_1 \gg \mathbf{f}_2$       | ocena $\mathbf{f}_1$ jest lepsza od oceny $\mathbf{f}_2$ ze względu na wszystkie kryteria oceny                                                             |
| Dominująca<br>(ang. <i>dominates</i> )                   | $\mathbf{f}_1 \succ \mathbf{f}_2$     | ocena $\mathbf{f}_1$ nie jest gorsza od oceny $\mathbf{f}_2$ ze względu na wszystkie kryteria oceny i jest lepsza ze względu na co najmniej jedno kryterium |
| Słabo dominująca<br>(ang. <i>weakly dominates</i> )      | $\mathbf{f}_1 \succeq \mathbf{f}_2$   | ocena $\mathbf{f}_1$ nie jest gorsza od oceny $\mathbf{f}_2$ ze względu na wszystkie kryteria oceny                                                         |
| Nieporównywalne wzajemnie<br>(ang. <i>incomparable</i> ) | $\mathbf{f}_1 \parallel \mathbf{f}_2$ | ocena $\mathbf{f}_1$ nie dominuje słabo nad oceną $\mathbf{f}_2$ ani ocena $\mathbf{f}_2$ nie dominuje słabo nad oceną $\mathbf{f}_1$                       |
| Obojętne<br>(ang. <i>indifferent</i> )                   | $\mathbf{f}_1 \sim \mathbf{f}_2$      | ocena $\mathbf{f}_1$ ma te same wartości wszystkich kryteriów oceny jak ocena $\mathbf{f}_2$                                                                |

Źródło: opracowanie własne na podstawie: Zitzler i in. (2002 d), Knowles i in. (2006).

Tablica A.2. Relacje preferencji pomiędzy przybliżeniami  $\Psi_A$  i  $\Psi_B$  frontu Pareto

| Relacja                                                  | Interpretacja w przestrzeni ocen |                                                                                                                                                                                          |
|----------------------------------------------------------|----------------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Silnie dominujący<br>(ang. <i>strictly dominates</i> )   | $\Psi_A \gg \Psi_B$              | każda ocena $\mathbf{f}_2 \in \Psi_B$ jest silnie zdominowana przynajmniej przez jedną ocenę $\mathbf{f}_1 \in \Psi_A$                                                                   |
| Dominujący<br>(ang. <i>dominates</i> )                   | $\Psi_A \succ \Psi_B$            | każda ocena $\mathbf{f}_2 \in \Psi_B$ jest zdominowana przynajmniej przez jedną ocenę $\mathbf{f}_1 \in \Psi_A$                                                                          |
| Lepszy                                                   | $\Psi_A \triangleright \Psi_B$   | każda ocena $\mathbf{f}_2 \in \Psi_B$ jest słabo zdominowana przez przynajmniej jedną ocenę $\mathbf{f}_1 \in \Psi_A$ i jednocześnie $\Psi_A \not\sim \Psi_B$ (zbiory nie są identyczne) |
| Słabo dominujący<br>(ang. <i>weakly dominates</i> )      | $\Psi_A \succeq \Psi_B$          | każda ocena $\mathbf{f}_2 \in \Psi_B$ jest słabo zdominowana przez przynajmniej jedną ocenę $\mathbf{f}_1 \in \Psi_A$                                                                    |
| Nieporównywalne wzajemnie<br>(ang. <i>incomparable</i> ) | $\Psi_A \parallel \Psi_B$        | zbiór $\Psi_A$ nie dominuje słabo nad zbiorem $\Psi_B$ ani zbiór $\Psi_B$ nie dominuje słabo nad zbiorem $\Psi_A$ : $\Psi_A \not\succeq \Psi_B \wedge \Psi_B \not\succeq \Psi_A$         |
| Obojętne<br>(ang. <i>indifferent</i> )                   | $\Psi_A \sim \Psi_B$             | zbiór $\Psi_A$ dominuje słabo nad zbiorem $\Psi_B$ i zbiór $\Psi_B$ dominuje słabo nad zbiorem $\Psi_A$ : $\Psi_A \succeq \Psi_B \wedge \Psi_B \succeq \Psi_A$                           |

Źródło: opracowanie własne na podstawie: Zitzler i in. (2002 c), Knowles i in. (2006).




## Załącznik B


# AUTO EXPRESS 82

Vessel type: 82m High Speed Vehicle-Passanger Catamaran


PROFILE



BRIDGE DECK




UPPER DECK



MEZZANINE DECK



MAIN DECK



Rys. B.1. Plan ogólny szybkiego promu pasażersko-samochodowego projektu Auto Express 82: Boomerang

Źródło: <http://www.austal.com/files/delivery/datasheet-boomerang.pdf>, dostęp dn. 07.04.2009 r.





# Załącznik C

Przyjęte w pracy katalogi wyrobów hutniczych:

## 1. Katalog blach okrętowych

|     |       |
|-----|-------|
| 1   | 0.3   |
| 2   | 0.4   |
| 3   | 0.5   |
| 4   | 0.6   |
| 5   | 0.7   |
| 6   | 0.8   |
| 7   | 1.0   |
| 8   | 1.2   |
| 9   | 1.5   |
| 10  | 2.0   |
| 11  | 3.0   |
| 12  | 4.0   |
| 13  | 5.0   |
| 14  | 6.0   |
| No. | t, cm |

## 2. Katalog kształtowników łebkowych

|     |         |       |       |       |        |        |                     |                     |                     |
|-----|---------|-------|-------|-------|--------|--------|---------------------|---------------------|---------------------|
| 1   | Bulb    | 8.00  | 1.90  | 0.5   | 0.75   | 4.75   | 5.05                | 28.21               | 5.93                |
| 2   | Bulb    | 10.00 | 2.05  | 0.5   | 0.75   | 5.87   | 6.16                | 55.84               | 9.51                |
| 3   | Bulb    | 12.00 | 2.50  | 0.8   | 1.20   | 6.95   | 11.64               | 144.88              | 20.86               |
| 4   | Bulb    | 14.00 | 2.70  | 0.8   | 1.20   | 8.08   | 13.48               | 234.20              | 28.98               |
| 5   | Bulb    | 15.00 | 2.50  | 0.6   | 0.90   | 8.63   | 10.71               | 223.15              | 25.87               |
| 6   | Bulb    | 16.00 | 2.90  | 0.7   | 1.05   | 9.28   | 13.51               | 318.06              | 34.28               |
| 7   | Bulb    | 20.00 | 3.80  | 1.0   | 1.50   | 11.61  | 24.20               | 875.35              | 75.43               |
| No. | Section | h, cm | b, cm | s, cm | sl, cm | yx, cm | A0, cm <sup>2</sup> | Ix, cm <sup>4</sup> | Wx, cm <sup>3</sup> |

## 3. Katalog kształtowników teowych


|    |        |       |       |      |      |       |       |         |        |
|----|--------|-------|-------|------|------|-------|-------|---------|--------|
| 1  | T-bulb | 10.20 | 102.0 | 6.5  | 6.5  | 7.41  | 12.84 | 112.16  | 15.14  |
| 2  | T-bulb | 12.00 | 80.0  | 8.0  | 8.0  | 8.10  | 15.36 | 198.30  | 24.48  |
| 3  | T-bulb | 12.00 | 60.0  | 6.0  | 8.0  | 8.10  | 11.52 | 148.72  | 18.36  |
| 4  | T-bulb | 12.50 | 90.0  | 4.0  | 7.0  | 9.47  | 11.02 | 139.13  | 14.69  |
| 5  | T-bulb | 12.50 | 100.0 | 7.0  | 10.0 | 9.21  | 18.05 | 216.07  | 23.45  |
| 6  | T-bulb | 12.70 | 64.0  | 6.1  | 15.0 | 9.31  | 16.43 | 173.50  | 18.64  |
| 7  | T-bulb | 12.70 | 64.0  | 5.6  | 12.0 | 9.20  | 14.12 | 169.03  | 18.36  |
| 8  | T-bulb | 14.00 | 76.0  | 5.8  | 12.0 | 10.26 | 16.54 | 244.93  | 23.87  |
| 9  | T-bulb | 15.00 | 68.0  | 10.0 | 6.0  | 8.86  | 18.48 | 404.36  | 45.66  |
| 10 | T-bulb | 15.20 | 76.0  | 6.1  | 15.0 | 11.24 | 19.76 | 320.23  | 28.50  |
| 11 | T-bulb | 16.60 | 75.0  | 8.0  | 16.0 | 11.65 | 24.00 | 512.26  | 43.97  |
| 12 | T-bulb | 17.50 | 110.0 | 8.0  | 8.0  | 11.82 | 22.16 | 651.44  | 55.09  |
| 13 | T-bulb | 17.80 | 114.0 | 7.6  | 14.0 | 13.20 | 28.42 | 686.34  | 52.01  |
| 14 | T-bulb | 17.80 | 102.0 | 6.6  | 15.0 | 13.38 | 26.06 | 596.95  | 44.63  |
| 15 | T-bulb | 17.80 | 121.0 | 5.7  | 7.9  | 12.92 | 19.25 | 553.91  | 42.86  |
| 16 | T-bulb | 18.00 | 60.0  | 5.0  | 8.0  | 11.82 | 13.40 | 422.95  | 35.77  |
| 17 | T-bulb | 18.00 | 100.0 | 6.0  | 10.0 | 12.96 | 20.20 | 574.80  | 44.37  |
| 18 | T-bulb | 18.50 | 50.0  | 5.0  | 9.5  | 12.02 | 13.53 | 443.03  | 36.85  |
| 19 | T-bulb | 18.50 | 90.0  | 4.0  | 7.0  | 13.24 | 13.42 | 434.44  | 32.81  |
| 20 | T-bulb | 20.00 | 100.0 | 8.0  | 15.0 | 14.28 | 29.80 | 979.70  | 68.59  |
| 21 | T-bulb | 20.00 | 140.0 | 8.0  | 15.0 | 15.12 | 35.80 | 1067.06 | 70.59  |
| 22 | T-bulb | 20.00 | 60.0  | 10.0 | 5.0  | 11.08 | 22.50 | 856.84  | 77.31  |
| 23 | T-bulb | 20.00 | 50.0  | 8.0  | 12.0 | 12.25 | 21.04 | 791.32  | 64.59  |
| 24 | T-bulb | 21.00 | 50.0  | 5.0  | 9.5  | 13.40 | 14.78 | 636.27  | 47.48  |
| 25 | T-bulb | 21.60 | 140.0 | 7.6  | 16.0 | 16.43 | 37.60 | 1293.62 | 78.72  |
| 26 | T-bulb | 22.00 | 80.0  | 5.0  | 8.0  | 14.74 | 17.00 | 816.76  | 55.41  |
| 27 | T-bulb | 23.00 | 80.0  | 10.0 | 8.0  | 13.67 | 28.60 | 1491.89 | 109.11 |
| 28 | T-bulb | 23.00 | 80.0  | 5.8  | 8.0  | 14.92 | 19.28 | 1024.12 | 68.65  |
| 29 | T-bulb | 23.50 | 170.0 | 8.0  | 10.0 | 16.96 | 35.00 | 1780.40 | 104.99 |
| 30 | T-bulb | 24.00 | 140.0 | 6.0  | 10.0 | 17.54 | 27.80 | 1457.27 | 83.07  |
| 31 | T-bulb | 26.00 | 90.0  | 5.0  | 9.5  | 17.80 | 21.08 | 1400.14 | 78.66  |
| 32 | T-bulb | 27.50 | 150.0 | 9.0  | 12.0 | 19.09 | 41.67 | 2996.28 | 156.96 |
| 33 | T-bulb | 28.00 | 100.0 | 5.0  | 8.0  | 18.79 | 21.60 | 1722.05 | 91.67  |
| 34 | T-bulb | 28.00 | 100.0 | 8.0  | 10.0 | 17.93 | 31.60 | 2482.99 | 138.48 |

|             |        |       |       |       |        |        |                     |                     |                     |
|-------------|--------|-------|-------|-------|--------|--------|---------------------|---------------------|---------------------|
| 35          | T-bulb | 30.00 | 60.0  | 15.0  | 15.0   | 16.86  | 51.75               | 4329.78             | 256.83              |
| 36          | T-bulb | 31.00 | 100.0 | 7.0   | 16.0   | 21.48  | 36.58               | 3254.64             | 151.52              |
| 37          | T-bulb | 31.00 | 123.0 | 5.0   | 8.0    | 21.22  | 24.94               | 2441.42             | 115.08              |
| 38          | T-bulb | 35.00 | 100.0 | 8.0   | 10.0   | 21.70  | 37.20               | 4631.63             | 213.40              |
| 39          | T-bulb | 35.00 | 100.0 | 5.0   | 8.0    | 22.68  | 25.10               | 3194.63             | 140.87              |
| 40          | T-bulb | 39.00 | 150.0 | 6.0   | 8.0    | 25.80  | 34.92               | 5551.68             | 215.17              |
| 41          | T-bulb | 39.00 | 150.0 | 6.0   | 12.0   | 27.53  | 40.68               | 6081.63             | 220.92              |
| 42          | T-bulb | 40.00 | 140.0 | 5.0   | 8.0    | 26.87  | 30.80               | 5145.82             | 191.49              |
| 43          | T-bulb | 41.00 | 100.0 | 6.0   | 8.0    | 25.21  | 32.12               | 5591.70             | 221.84              |
| 44          | T-bulb | 42.00 | 150.0 | 5.0   | 10.0   | 29.37  | 35.50               | 6349.59             | 216.17              |
| 45          | T-bulb | 42.00 | 150.0 | 8.0   | 10.0   | 27.09  | 47.80               | 8735.65             | 322.47              |
| 46          | T-bulb | 45.00 | 100.0 | 9.0   | 10.0   | 26.54  | 49.60               | 10111.79            | 381.06              |
| 47          | T-bulb | 45.00 | 150.0 | 10.0  | 12.0   | 28.45  | 61.80               | 12837.02            | 451.16              |
| 48          | T-bulb | 50.00 | 100.0 | 10.0  | 12.0   | 29.96  | 62.00               | 16760.00            | 559.40              |
| 49          | T-bulb | 50.00 | 150.0 | 10.0  | 12.0   | 31.78  | 68.00               | 19092.71            | 600.78              |
| 50          | T-bulb | 50.00 | 200.0 | 12.0  | 14.0   | 33.18  | 88.00               | 25113.93            | 756.90              |
| 51          | T-bulb | 50.00 | 250.0 | 12.0  | 14.0   | 34.47  | 95.00               | 27106.02            | 786.37              |
| 52          | T-bulb | 55.00 | 250.0 | 14.0  | 16.0   | 37.18  | 117.00              | 40502.21            | 1089.36             |
| No. Section |        | h, cm | b, mm | s, mm | sl, mm | yx, cm | A0, cm <sup>2</sup> | Ix, cm <sup>4</sup> | Wx, cm <sup>3</sup> |


Źródło: opracowanie własne na podstawie: *Aluminium and the Sea* (1993).

## Załącznik D


(a)




(b)




(c)



Rys. D.1. Ewolucja makroskopowych wielkości charakteryzujących populacje wariantów w serii symulacji: (a) sym1-1, (b) sym1-2 i (c) sym1-3




Rys. D.2. Ewolucja makroskopowych wielkości charakteryzujących populacje wariantów w serii symulacji: (a) sym2-1, (b) sym2-2 i (c) sym2-3




Rys. D.3. Ewolucja makroskopowych wielkości charakteryzujących populacje wariantów w serii symulacji: (a) sym1-2-50000, (b) sym12-50000 i (c) sym9-50000



## Załącznik E




Rys. E.1. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym1-1 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. E.2. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym1-2 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej







Rys. E.3. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym1-3 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej



Rys. E.4. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym2-1 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. E.5. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym2-2 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. E.6. Ewolucja zbioru przybliżającego  $\Psi_f$  w trakcie symulacji sym2-3 przedstawiona w sześciu wybranych pokoleniach 1., 2000., 4000., 6000., 8000. i 10 000. odpowiednio na rysunkach (a), (b), (c), (d), (e) i (f); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej

## Załącznik F




Rys. F.1. Zbiory przybliżające  $\Psi_f$  uzyskane w symulacjach od sym3-1 do sym3-4 z serii symulacji sym3-*i* przedstawione odpowiednio na rysunkach od (a) do (d); okręgi oznaczają oceny wariantów niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. F.2. Zbiory przybliżające  $\Psi_f$  uzyskane w symulacjach od sym3-5 do sym3-10 z serii symulacji sym3- $i$  przedstawione odpowiednio na rysunkach od (a) do (f); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej

## Załącznik G




Rys. G.1. Przedstawiona w fizycznej i unormowanej przestrzeni ocen szczegółowa specyfikacja zbiorów przybliżających  $\Psi_{\text{sym1-1}}$  i  $\Psi_{\text{sym1-2}}$  uzyskanych odpowiednio w symulacjach sym1-1 (a) i (b) oraz sym1-2 (c) i (d); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. G.2. Przedstawiona w fizycznej i unormowanej przestrzeni ocen szczegółowa specyfikacja zbiorów przybliżających  $\Psi_{\text{sym1-3}}$  i  $\Psi_{\text{sym2-1}}$  uzyskanych odpowiednio w symulacjach sym1-3 (a) i (b) oraz sym2-1 (c) i (d); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej






Rys. G.3. Przedstawiona w fizycznej i unormowanej przestrzeni ocen szczegółowa specyfikacja zbiorów przybliżających  $\Psi_{\text{sym2-2}}$  i  $\Psi_{\text{sym2-3}}$  uzyskanych odpowiednio w symulacjach sym2-2 (a) i (b) oraz sym2-3 (c) i (d); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




Rys. G.4. Przedstawiona w fizycznej i unormowanej przestrzeni ocen szczegółowa specyfikacja zbiorów przybliżających  $\Psi_{\text{sym3}}$  i  $\Psi_{\text{sym1-2-50000}}$  uzyskanych odpowiednio w serii dziesięciu symulacji sym3-[1-10] (a) i (b) oraz w symulacji sym1-2-50000 (c) i (d); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptycznej




Rys. G.5. Przedstawiona w fizycznej i unormowanej przestrzeni ocen szczegółowa specyfikacja zbiorów przybliżających  $\Psi_{\text{sym12-50000}}$  i  $\Psi_{\text{sym9-50000}}$  uzyskanych odpowiednio w symulacjach sym12-50000 (a) i (b) oraz sym9-50000 (c) i (d); okręgi oznaczają oceny rozwiązań niezdominowanych, koła oznaczają oceny najbliższe ocenie asymptotycznej




## Załącznik H



Rys. H.1. Wybór jednego rekomendowanego rozwiązania zadania optymalizacji wielokryterialnej na podstawie zbiorów przybliżających zbudowanych w serii 2. trzech symulacji komputerowych sym2-1, sym2-2 i sym2-3: (a) tymczasowy zbiór utworzony z ocen rozwiązań niezdominowanych uzyskanych w poszczególnych symulacjach, (b) wybór ocen rozwiązań niezdominowanych w zbiorze tymczasowym i zbudowanie nowego zbioru przybliżającego  $\mathcal{P}_{\text{sym2}}$ , (c) wyznaczenie odległości ocen rozwiązań niezdominowanych względem oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  w unormowanej przestrzeni ocen, (d) wartości kryteriów optymalizacji dla rozwiązania najbliższego  $\mathbf{f}_{\text{sym2-1}}^*$ :  $f_1(\mathbf{x}) = 1105,95$  kN i  $f_2(\mathbf{x}) = 7345,11$  m<sup>2</sup>



Rys. H.2. Wybór jednego rekomendowanego rozwiązania zadania optymalizacji wielokryterialnej na podstawie zbiorów przybliżających uzyskanych w serii 3. dziesięciu symulacji komputerowych od sym3-1 do sym3-10: (a) tymczasowy zbiór utworzony z ocen rozwiązań niezdominowanych uzyskanych w poszczególnych symulacjach sym3- $i$ , (b) wybór ocen rozwiązań niezdominowanych w zbiorze tymczasowym i zbudowanie nowego zbioru przybliżającego  $\Psi_{\text{sym3}}$ , (c) wyznaczenie odległości ocen rozwiązań niezdominowanych względem oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  w unormowanej przestrzeni ocen, (d) wartości kryteriów optymalizacji dla rozwiązania najbliższego  $\mathbf{f}^*_{\text{sym3-5}}$ :  $f_1(\mathbf{x}) = 1019,80$  kN i  $f_2(\mathbf{x}) = 7305,15$  m<sup>2</sup>



Rys. H.3. Wybór jednego rekomendowanego rozwiązania zadania optymalizacji wielokryterialnej na podstawie zbiorów przybliżających uzyskanych w serii 4. trzech symulacji komputerowych, sym1-2-50000, sym12-50000 i sym9-50000: (a) tymczasowy zbiór utworzony z ocen rozwiązań niezdominowanych uzyskanych w poszczególnych symulacjach, (b) wybór ocen rozwiązań niezdominowanych w zbiorze tymczasowym i zbudowanie nowego zbioru przybliżającego  $\Psi_{\text{sym4}}$ , (c) wyznaczenie odległości ocen rozwiązań niezdominowanych względem oceny rozwiązania asymptotycznego  $\mathbf{f}^*$  w unormowanej przestrzeni ocen, (d) wartości kryteriów optymalizacji dla rozwiązania najbliższego  $\mathbf{f}^*_{\text{sym12-50000}}$ :  $f_1(\mathbf{x}) = 1128,18 \text{ kN}$  i  $f_2(\mathbf{x}) = 7229,02 \text{ m}^2$






## Załącznik I

W załączniku podano dane i rezultaty ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku względem ciężaru konstrukcji  $f_1$  i pola powierzchni do malowania i konserwacji  $f_2$  przeprowadzonej w symulacji sym2-1: (1) rozplanowanie ogólne i podstawowe wymiary statku wzorcowego; (2) przyjętą postać kombinowanej funkcji przystosowania; (3) kryteria optymalizacji; (4) podstawowe parametry sterujące symulacji; (5) wartości kryteriów optymalizacji dla odszukanych wariantów niezdominowanych należących do zbioru przybliżającego  $\Psi_{\text{sym2-1}}$ ; (6) wartości kryteriów optymalizacji dla wariantu, którego ocena jest najbliższa ocenie asymptotycznej  $\mathbf{f}^*$  oraz wymiary wiązań kadłuba statku dla tego wariantu; (7) ewolucję makroskopowych wielkości opisujących populację rozwiązań w toku symulacji; (8) zbiór przybliżający  $\Psi_{\text{sym2-1}}$  ze wskazaniem rozwiązania, którego ocena jest najbliższa ocenie rozwiązania asymptotycznego  $\mathbf{f}^*$  w fizycznej przestrzeni ocen; (9) numer pokolenia, w którym uzyskano poszczególne rozwiązania w zbiorze przybliżającym  $\Psi_{\text{sym2-1}}$ ; (10) wartości kryteriów optymalizacji dla wszystkich rozwiązań w zbiorze przybliżającym  $\Psi_{\text{sym2-1}}$  oraz (11) odległości  $d_{f_i}$  ocen rozwiązań w zbiorze przybliżającym  $\Psi_{\text{sym2-1}}$  od oceny rozwiązania asymptotycznego  $\mathbf{f}^*$ .

## High speed vehicle-passenger catamaran, Austal Auto Express 82 type



### Main particulars:

- length overall,  $L = 90.0$  m,
- breadth,  $B = 23.0$  m,
- maximum depth,  $H = 11.7$  m,
- length of midship block-section subject to optimisation, 17.5 m.

### Properties of structural material:

- aluminum alloys,
- 5083-H111 alloy for plates ( $R_{0.2} = 125$  N/mm<sup>2</sup>),
- 6082-T6 alloy for bulb extrusions ( $R_{0.2} = 250$  N/mm<sup>2</sup>).

### Classification society rules for ship structural design:

- Bureau Veritas, *Rules for the Construction and Classification of High Speed Craft*, 1995.

## Multi-objective topology and size optimisation of ship structure by evolutionary algorithm with combined fitness function, CFMOEA, based on genetic algorithm

Combined fitness function:

$$f(\mathbf{x}) = w_1 f_1(\mathbf{x}) + w_2 f_2(\mathbf{x}) + w_{rank} rank(\mathbf{x}) + w_{count} count(\mathbf{x}) + w_{distance} distance(\mathbf{x}) + \sum_{k=1}^{n_2} (w_k \cdot penalty_k(\mathbf{x}))$$

Optimization criteria:

- structural weight  $f_1(\mathbf{x})$ , kN,
- surface area for cleaning and painting  $f_2(\mathbf{x})$ , m<sup>2</sup>.

Parameters of CFMOEA simulation:

- sym2-1,
- number of individuals  $n_i = 5,000$ ,
- number of generations  $n_g = 10,000$ ,
- $w_1 = w_2 = 0.0$ ,
- $w_{rank} = 3.0$ ,  $w_{count} = 0.0$ ,  $w_{distance} = 0.0$ .


The best (recommended) solution:

- structural weight  $f_1(\mathbf{x}_4) = 1106$  kN,
- surface area  $f_2(\mathbf{x}_4) = 7345$  m<sup>2</sup>.

Non-dominated solutions:

- (1)  $f_1(\mathbf{x}_1) = 1069$  kN,  $f_2(\mathbf{x}_1) = 7790$  m<sup>2</sup>,
- (2)  $f_1(\mathbf{x}_2) = 1077$  kN,  $f_2(\mathbf{x}_2) = 7742$  m<sup>2</sup>,
- (3)  $f_1(\mathbf{x}_3) = 1085$  kN,  $f_2(\mathbf{x}_3) = 7518$  m<sup>2</sup>,
- (4)  $f_1(\mathbf{x}_4) = 1106$  kN,  $f_2(\mathbf{x}_4) = 7345$  m<sup>2</sup>,
- (5)  $f_1(\mathbf{x}_5) = 1316$  kN,  $f_2(\mathbf{x}_5) = 7231$  m<sup>2</sup>,
- (6)  $f_1(\mathbf{x}_6) = 1391$  kN,  $f_2(\mathbf{x}_6) = 7130$  m<sup>2</sup>,
- (7)  $f_1(\mathbf{x}_7) = 1607$  kN,  $f_2(\mathbf{x}_7) = 7074$  m<sup>2</sup>,
- (8)  $f_1(\mathbf{x}_8) = 1767$  kN,  $f_2(\mathbf{x}_8) = 7074$  m<sup>2</sup>,
- (9)  $f_1(\mathbf{x}_9) = 1968$  kN,  $f_2(\mathbf{x}_9) = 7044$  m<sup>2</sup>,
- (10)  $f_1(\mathbf{x}_{10}) = 2244$  kN,  $f_2(\mathbf{x}_{10}) = 7022$  m<sup>2</sup>.


## Midship section structural arrangements and scantlings of the best solution




1 of 2

by Zbigniew Sekulski, West Pomeranian University of Technology, Szczecin (Poland) - Faculty of Maritime Technology and Transport

### History of evolutionary optimisation in sym2-1 simulation



### Specification of final set of non-dominated solutions



2 of 2


by Zbigniew Sekulski, West Pomeranian University of Technology, Szczecin (Poland) - Faculty of Maritime Technology and Transport

Rys. I.1. Wybrane wyniki wielokryterialnej optymalizacji i konstrukcji kadłuba statku

Źródło: opracowanie własne, materiał pomocniczy do wykładu *Ship structural optimization* realizowanego dla studentów na Wydziale Techniki Morskiej i Transportu ZUT w Szczecinie w ramach programu UE LPP Erasmus.




## Załącznik J



Rys. J.1. Wykres punktowy zbiorów przybliżających  $\Psi_{\text{sym}i}$  uzyskanych w poszczególnych symulacjach ewolucyjnej optymalizacji wielokryterialnej konstrukcji kadłuba statku



## Załącznik K




Rys. K.1. Struktura zbiorów przybliżających  $\Psi_{symi}$  uzyskanych w dwóch symulacjach, sym1-2 i sym1-2-50000, różniących się jedynie liczbą pokoleń, czyli długością trwania symulacji





## Załącznik L



Rys. L.1. Struktura zbiorów przybliżających  $\Psi_{symi}$  uzyskanych w dwóch symulacjach, sym12-50000 i sym9-50000, różniących się wzmocnieniem, w przypadku symulacji sym9-50000, wpływu atrybutów dominacji i odległości od oceny rozwiązania asymptotycznego na selekcję wariantów



## Literatura

- Adeli H., Cheng N.T., 1994, Augmented Lagrangian Genetic Algorithm for Structural Optimization, *Journal of Aerospace Engineering*, Vol. 7, No. 1, s. 104–118.
- Ahuja G., Ulfvarson A. 2006. Weight Optimization of a Sandwich Superstructure of a High-Speed Ferry, *Ship Technology Research*, Vol. 53, s. 88–93.
- Aluminium and the Sea*, 1993, Paris, Pichiney-Rhenalu.
- Arabas J., 2001, *Wykłady z algorytmów ewolucyjnych*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-2970-6.
- Augusto O.B., Kawano A., 1998, A Mixed Continuous and Discrete Nonlinear Constrained Algorithm for Optimizing Ship Hull Structural Design, *Ocean Engineering*, Vol. 25, No. 9, s. 793–811.
- Babbage R., Armstrong T., Toman R., Blansjaar J., 1997, Military Fast Vessels for Australia, in: *Proceedings of the FAST 1997. Fourth International Conference on Fast Sea Transportation*, eds. N. Baird, A. Jeffs, Sydney, Australia, July 21–23, 1997, Baird Publications, Ltd., s. 11–20, ISBN 0958701326.
- Bai Y., 2003, *Marine structural design*, Oxford, UK, Elsevier Science Ltd., ISBN 0-08-043921-7.
- Bäck T., 1991, Extended Selection Mechanisms in Genetic Algorithms, in: *Proceedings of the ICGA 1991. Fourth International Conference on Genetic Algorithms*, eds. R.K. Belew, L.B. Booker, San Diego, University of California, July 13–16, 1991, San Mateo, Morgan Kaufmann Publishers, s. 92–99, ISBN 1558602089.
- Bäck T., 1994, Selective pressure in evolutionary algorithms: A characterization of selection mechanisms, in: *Proceedings of the 1-st IEEE Conference on Evolutionary Computation*, [b.w.], s. 57–62, ISBN 0780318994.
- Bäck T., 1995, Generalized Convergence Models for Tournament – and  $(\mu, \lambda)$  – Selection, in: *Proceedings of the ICGA 1995. Sixth International Conference on Genetic Algorithms*, ed. L.J. Eshelman, University of Pittsburgh, July 15–19, 1995, San Francisco, Morgan Kaufmann Publishers, s. 2–8, ISBN 1-55860-370-0.
- Bäck T., 1996, *Evolutionary Algorithms in Theory and Practice*, New York, Oxford University Press, ISBN 978-0-19-509971-3.
- Bäck T., Fogel D.B., Michalewicz Z., 2000 a, *Evolutionary Computation 1. Basic Algorithms and Operators*, Bristol, Institute of Physics Publishing, ISBN 0-7503-0664-5.
- Bäck T., Fogel D.B., Michalewicz Z., 2000 b, *Evolutionary Computation 2. Advanced Algorithms and Operators*, Bristol, Institute of Physics Publishing, ISBN 0-7503-0665-3.
- Beckers P., 1991, Recent developments in shape sensitivity analysis: the physical approach, *Engineering Optimization*, Vol. 18, s. 67–78.
- Bendsoe M.P., Kikuchi N., 1988, Generating Optimal Topologies in Structural Design Using a Homogenization Method, *Computer Methods in Applied Mechanics and Engineering*, Vol. 71, s. 197–224.
- Bentley P., 1999, *Evolutionary design by computers*, [b.m.], Morgan Kaufmann, ISBN 155860605X.
- Bieliński J., Doktor M., Sadkowski Z., Szejnrowski E., 1988, *Zarys techniki wytwarzania statku*, Gdańsk, Uniwersytet Gdański.

- Bieliński J., Piechnik Z., Sadkowski Z., Szejnrowski E., 1973, *Podstawowe wiadomości o statku i jego budowie*, Gdańsk, Uniwersytet Gdański.
- Binh T.T., Korn U., 1997, MOBES: A Multiobjective Evolution Strategy for Constrained Optimization Problems, in: *Proceedings of the MENDEL 1997. Third International Conference on Genetic Algorithms*, Brno, Czech Republic, [b.w.], s. 176–182, ISBN 80-214-0884-7.
- Birk L., Clauss G.F., Lee J.Y., 2004, Practical Application of Global Optimization to the Design of Offshore Structures, in: *Proceedings of the OMAE04. 23rd International Conference on Offshore Mechanics and Arctic Engineering*, Vancouver, British Columbia, Canada, June 20–25, 2004, American Society of Mechanical Engineers, s. 1–13, ISBN 0791837386.
- Birmingham R.W., Smith T.A.G., 1998, Automatic hull form generation: a practical tool for design and research, in: *Proceedings of the PRADS 1998. Seventh International Symposium on Practical Design of Ships and Mobile*, eds. M.W.C. Oosterveld, S.G. Tan, The Hague, The Netherlands, September 20–25, 1998, [b.w.], s. 281–287, ISBN 0-444-82918-0.
- Boomerang: catamaran ferry for Baltic Service, 1997, *Significant Ships of 1997*, s. 20–21.
- Bowden J.O., Embry G.D., 1989, SFS – The 55 Knot Sealift Ship, *Naval Engineers Journal*, Vol. 101, No. 3, s. 144–155.
- Brandt A.M., Dzieniszewski W., Jendo S., Marks W., Owczarek S., Wasiutyński Z., 1984, *Criteria and Methods of Structural Optimization*, Warszawa, PWN, ISBN 83-04625-2.
- Brockhoff D., 2009, *Theoretical Aspects of Evolutionary Multiobjective Optimization – A Review*, Rapport de recherche No. 7030, INRIA Saclay, Île-de-France, Institut National de Recherche en Informatique et en Automatique, Centre de recherche INRIA.
- Bronskij A., Glozman M., Kozljakov V., 1974, *Osnovy vybora konstrukcij korpusa sudna*, Leningrad, „Sudostrojenie”.
- Bujniewicz Z., Cudny, K., Wincza M., 1971, *Stopy aluminium w budownictwie okrętowym*, Gdańsk, Wydawnictwo Morskie.
- BV, 1995, *Rules for the Construction and Classification of High Speed Craft*, Paris, Bureau Veritas.
- Butnicki S., 1971, *Stale i żeliwa dla przemysłu okrętowego*, Gdańsk, Wydawnictwo Morskie.
- Buxton I.L., 1976, *Engineering Economics and Ship Design*, Wallsend, Northumberland, England, The British Ship Research Association, ISBN 0950276820.
- Caldwell J.B., Hewitt A.D., 1976, Cost effective design of ship structures, *Metal Construction and British Welding Journal*, Vol. 8, No. 2, s. 64–67.
- Callahan K.J., Weeks G.E., 1992, Optimum Design of Composite Laminates Using Genetic Algorithms. *Composites Engineering*, Vol. 2, No. 3, s. 149–160.
- Caprace J.D., Bair F., Rigo P., 2010, Scantling multi-objective optimisation of a LNG carrier, *Marine Structures*, Vol. 23, s. 288–302.
- Catley D., Lehmann E., Maniar N., Baret B., Homma Y., Trafalski W., 1990, Design Optimization: State-of-the-Art Review, *Marine Structures*, Vol. 3, s. 343–390.
- Chen P.H., Huang C.H., 2002, An Inverse Hell Design Problem in Optimizing the Desired Wake of a Ship, *Journal of Ship Research*, Vol. 46, No. 2, s. 138–148.
- Chung J., Jung T.C., 2004, Optimization of an air cushion vehicle bag and finger skirt using genetic algorithms, *Aerospace Science and Technology*, Vol. 8, s. 219–229.
- Coello Coello C.A., 1998, *An Updated Survey of GA-Based Multiobjective Optimization Techniques*, Technical Report Lania-RD-98-08, Xalapa, Veracruz, México, Laboratorio Nacional de Informática Avanzada (LANIA).
- Coello Coello C.A., 1999 a, A Comprehensive Survey of Evolutionary-Based Multiobjective Optimization Techniques, *Knowledge and Information Systems*, Vol. 1, No. 3, s. 269–308.

- Coello Coello C.A., 1999 b, An Updated Survey of Evolutionary Multiobjective Optimization Techniques: State of the Art and Future Trends, in: *Proceedings of the CEC99. 1999 Congress on Evolutionary Computation*, Mayflower Hotel Washington, D.C. USA, July 6–9, 1999, Vol. 1, Institute of Electrical & Electronics Engineer, s. 3–13, ISBN: 0-7803-5536-9.
- Coello Coello C.A., 2001, A Short Tutorial on Evolutionary Multiobjective Optimization, in: *First International Conference on Evolutionary Multi-Criterion Optimization*, eds. E. Zitzler, K. Deb, L. Thiele, C.A. Coello Coello, D. Corne, Zurich, Switzerland, March 7–9, 2001, Berlin, Springer-Verlag, s. 21–40, ISBN-10 3540417451, ISBN-13 978-3540417453.
- Coello Coello C.A., 2006, Evolutionary Multi-Objective Optimization: A Historical View of the Field, *IEEE Computational Intelligence Magazine*, Vol. 1, No. 1, s. 28–36.
- Coello Coello C.A., 2011, Fundamentals of Evolutionary Multi-Objective Optimization, in: *Industrial Electronics Handbook. Intelligent Systems*, eds. B.M. Wilamowski, J.D. Irwin, Boca Raton, Florida, USA, CRC Press, s. 1–11, ISBN 978-1-4398-0283-0.
- Coello Coello C.A., Lamont G.B., 2004, An introduction to multi-objective evolutionary algorithms and their applications, in: *Applications of multi-objective evolutionary algorithms*, eds. C.A Coello Coello, G.B. Lamont, [b.m.], World Scientific, s. 1–28, ISBN 978-981-256-106-0, 981-256-106-4.
- Coello Coello C.A., Lamont G.B., Van Veldhuizen D.A., 2007, *Evolutionary Algorithms for Solving Multi-Objective Problems*, New York, NY, USA Springer Science+Business Media, LLC, ISBN 978-0-387-33254-3.
- Cohon J.L., 1978, *Multiobjective Programming and Planning*, New York, Academic Press, ISBN 0486432637.
- Coley D.A., 1999, *An Introduction to Genetic Algorithms for Scientists and Engineers*, Singapore, World Scientific Publishing Co. Pte. Ltd, ISBN 9810236026.
- Cudny K., 1996, *Technologia konstrukcji okrętowych ze stopów aluminium*, Gdańsk, Politechnika Gdańska, ISBN 83-86537-26-4.
- Cudny K., Puchaczewski N., 1995, *Stopy metali na kadłuby okrętowe i obiekty oceanotechniczne*, Gdańsk, Politechnika Gdańska, ISBN 83-86537-02-7.
- Cydejko J., Puchalski J., Rutkowski G., 2011, *Statki i technologie off-shore w zarysie*, Gdynia, Trademar, ISBN 978-83-62227-24-2.
- Cytowski J., 1996, *Algorytmy genetyczne. Podstawy i zastosowania*, Warszawa, Akademicka Oficyna Wydawnicza PLJ, ISBN 83-7101-255-7.
- Czimmek D.W., Schaub B.H., 1991, Concept of a Large Surface Effect Ship for Fast Ocean Transport, in: *Proceedings of the FAST 1991. First International Conference on Fast Sea Transportation*, ed. K.O. Holden, Trondheim, [b.w.], s. 91–105, ISBN 8251909627.
- Daidola J.C., Basar N.S., 1980, *Probabilistic Structural Analysis of Ship Hull Longitudinal Strength*, Ship Structure Committee, Report No. SSC-301, Washington, DC, U.S. Coast Guard.
- Das P.K., Zanic V., Faulkner D., 1993, Reliability – Based Design Procedure of Stiffened Cylinder Using Multiple Criteria Optimisation Techniques, in: *Proceedings of the OTC 1993. Offshore Technology Conference*, Houston, Texas, USA, May 3–6, 1993, [b.w.], Vol. 3, s. 297–313, ISBN-10 9993013560, ISBN-13 978-9993013563.
- Davis L.P., 1991, *Handbook of Genetic Algorithms*, New York, Van Nostrand, ISBN-10 0442001738, ISBN-13 978-0442001735.
- Davis L.D., De Jong K., Vose M.D., Whitley L.D., 1999, *Evolutionary Algorithms*, Berlin, Springer-Verlag, ISBN 0-387-98826-2.

- Day A.H., Doctors L.J., 1996, *Minimal-resistance hullforms for high-speed craft*, Transactions of the Royal Institution of Naval Architects, Vol. 138, s. 194–210.
- Day A.H., Doctors L.J., 1997, Design of Fast Ships for Minimal Motions, in: *Proceedings of the Seventh International Offshore and Polar Engineering Conference*, Honolulu, USA, May 25–30, 1997, The International Society of Offshore and Polar Engineers, s. 677–683, ISBN 1-880653-28-1.
- De Jong K., 1995, On Decentralizing Selection Algorithms, in: *Proceedings of the ICGA 1995. Sixth International Conference on Genetic Algorithms*, ed. L.J. Eshelman, University of Pittsburgh, San Francisco, July 15–19, 1995, Morgan Kaufmann Publishers, s. 17–23, ISBN 1-55860-370-0.
- Deb K., 1995, Evolutionary algorithms for multi-criterion optimization in engineering design, in: *Evolutionary Algorithms in Engineering and Computer Science*, eds. K. Miettinen, P. Niittaanmäki, M.M. Mäkelä, J. Périaux, Chichester, UK, John Wiley & Sons, s. 135–161, ISBN 0471999024.
- Deb K., 2001, *Multi-Objective Optimization using Evolutionary Algorithms*, Chichester, England, John Wiley & Sons, ISBN 0-471-87339-X.
- Deb K., 2005, *On Finding Multiple Pareto-Optimal Solutions Using Classical and Evolutionary Generating Methods*, Report No. 2005006, Kanpur, India, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology.
- Deb K., 2011, *Multi-Objective Optimization Using Evolutionary Algorithms: An Introduction*, Report No. 2011003, Kanpur, India, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology.
- Deb K., Agrawal S., Pratab A., Meyarivan T., 2000, *A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II*, Report No. 200001, Kanpur, India, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology.
- Deb K., Jain S., 2002, Running Performance Metrics for Evolutionary Multi-Objective Optimization, Report No. 2002004, Kanpur, India, Kanpur Genetic Algorithms Laboratory (KanGAL), Indian Institute of Technology.
- Deb K., Pratap A., Agarwal S., Meyarivan T., 2002, A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II, *IEEE Transactions on Evolutionary Computation*, Vol. 6, No. 2, s. 182–197.
- Dejhalla R., Mrsa Z., Vukovic S., 2001, Application of Genetic Algorithm for Ship Hull Form Optimization, *International Shipbuilding Progress*, Vol. 48, No. 2, s. 117–134.
- Dejhalla R., Mrsa Z., Vukovic S., 2002, A Genetic Algorithm Approach to the Problem of Minimum Ship Wave Resistance, *Marine Technology and SNAME News*, Vol. 39, No. 3, s. 187–196.
- Dias A.H.F., Vasconcelos J.A. de, 2002, Multiobjective Genetic Algorithms Applied to Solve Optimization Problems, *IEEE Transactions on Magnetics*, Vol. 38, No. 2, s. 1133–1136.
- Doctors L.J., Day A.H., 1995, Hydrodynamically Optimal Hull Forms for River Ferries, in: *Proceedings of the International Symposium on High Speed Vessels for Transport and Defence*, London, November 23–24, 1995, Paper No. 5, [b.m.], The Royal Institution of Naval Architects.
- Doi K., Yamauchi S., Tezuka K., 1997, Automatic nesting system by use of genetic algorithm, in: *Proceedings of the ICCAS 1997. 9th International Conference on Computer Applications in Shipbuilding*, Yokohama, Japan, October 13–17, 1997, Society of Naval Architects of Japan, Vol. 1, s. 247–258, ISBN 4-930966-02-07.
- Driankov D., Hellendroon H., Reinfrank M., 1996, *Wprowadzenie do sterowania rozmytego*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-2030-X.
- Dudziak J., 1980, *Okręt na fali*, Gdańsk, Wydawnictwo Morskie, ISBN 83-215-0097-8.
- Edgeworth F.Y., 1881, *Mathematical Physics: An Essay on the Application of Mathematics to the Moral Sciences*, London, England, Paul Keagan.
- Ehrgott M., Gandibleux X., 2004, Approximative Solution Methods for Multiobjective Combinatorial Optimization, *TOP*, Vol. 12, No. 1, s. 1–89.

- Emero D.H., Spunt L., 1965, Wing Box Optimisation under Combined Shear and Bending, *Journal of Aircraft*, Vol. 3, No. 2, s. 130–141.
- Evans J.H., 1975, *Ship Structural Design Concepts*, Cambridge, Maryland, USA, Cornell Maritime Press, Inc., ISBN-10 0870332090, ISBN-13 978-0870332098.
- Evans J.H., Khoushy D., 1963, Optimized Design of Midship Section Structure, *Transactions of SNAME*, Vol. 71, s. 144–191.
- Evolutionary Multiobjective Optimization*, 2005, eds. A. Abraham, L. Jain, R. Goldberg, London, Springer-Verlag, ISBN 1-85233-787-7.
- Eyres D.J., 2007, *Ship Construction*, Woburn, Massachusetts, USA, Butterworth-Heinemann, ISBN 0750680709.
- Farina M., Amato P., 2002, On the Optimal solution definition for many-criteria optimization problems, in: *Proceedings of the NAFIPS-FLINT International Conference*, eds. J. Keller, O. Nasraoui, New Orleans, USA, June, 2002, Piscataway NJ, IEEE Press, s. 233–238, ISBN 0-7803-7461-4.
- Findeisen W., Szymanowski J., Wierzbicki A., 1980, *Teoria i metody obliczeniowe optymalizacji*, Warszawa, PWN, ISBN 83-01-00976-4.
- Fletcher R., 1987, *Practical Methods of Optimization*, Chichester, John Wiley & Sons, ISBN-10 0471494631, ISBN-13 978-0471494638.
- Fleury C., 1989, CONLIN, an efficient dual optimizer based on convex approximation concepts, *Structural Optimization*, Vol. 1, s. 81–89.
- Fleury C., 1993, Mathematical programming methods for constrained optimization: dual methods, *Progress in Astronautics and Aeronautics*, Vol. 150, s. 123–150.
- Fonseca C.M., Fleming P.J., 1993, Genetic Algorithms for Multiobjective Optimization: Formulation, Discussion and Generalization, in: *Proceedings of the ICGA 1993. 5th International Conference on Genetic Algorithms*, ed. S. Forrest, Urbana-Champaign, IL, USA, June, 1993, San Francisco, Morgan Kaufmann Publishers Inc., s. 416–423, ISBN 1-55860-299-2.
- Fonseca C.M., Fleming P.J., 1995, On Overview of Evolutionary Algorithms in Multiobjective Optimization, *Evolutionary Computation*, Vol. 3, No. 1, s. 165–180.
- Fonseca C.M., Fleming P.J., 1996, On the Performance Assessment and Comparison of Stochastic Multiobjective Optimizers, in: *Proceedings of the PPSN IV. International Conference on Parallel Problem Solving from Nature*, eds. H.M. Voigt, W. Ebeling, I. Rechenberg, H.P. Schwefel, Berlin, Germany, September 22–26, 1996, Berlin, Germany, Springer-Verlag, s. 585–593, ISBN 354061723X.
- Fonseca C.M., Knowles J.D., Thiele L., Zitzler E., 2005, A Tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers, in: *An invited talk at the Evolutionary Multi-Criterion Optimization Conference*, Guanajuato, Mexico, March 9–11, 2005, <http://www.tik.ee.ethz.ch/pisa/publications/emo-tutorial-2up.pdf>, dostep dn. 16.06.2010 r.
- Fox R.L., 1971, *Optimization Methods for Engineering Design*, Reading, Massachusetts, USA, Addison-Wesley Publishing Company, Inc., ISBN 0201020785.
- Gallagher R.H., Zienkiewicz O.C., 1973, *Optimum Structural Design*, London, John Wiley & Sons, ISBN 0471290505, 9780471290506.
- Gen M., Cheng R., 1997, *Genetic Algorithms and Engineering Design*, New York, John Wiley & Sons, Inc., ISBN 0471127418, 9780471127413.
- Ghiassi H., Pasini D., Lessard L., 2011, A non-dominated sorting hybrid algorithm for multi-objective optimization of engineering problems, *Engineering Optimization*, Vol. 43, No. 1, s. 39–59.

- Ghosh A., Dehuri S., 2004, Evolutionary Algorithms for Multi-Criterion Optimization: A Survey, *International Journal of Computing & Information Sciences*, Vol. 2, No. 1, s. 38–57.
- Giuglea S., Chirica I., Giuglea V., Rigo P., 2008, IMPROVE – Design of Improved and Competitive Products, in: *Proceedings of the DBlaS'2008. I&CT International Conference*, Istanbul, Turkey, June 16–18, 2008, [b.w.], s. 66–80, ISBN 978-973-8937-46-8.
- Goldberg D.E., 1989, *Genetic Algorithms in Search, Optimization and Machine Learning*, Boston, Massachusetts, USA, Addison-Wesley Longman Publishing Co., Inc., ISBN 0201157675.
- Goldberg D.E., Deb K., 1991, A Comparative Analysis of Selection Schemes Used in Genetic Algorithms, in: *Proceedings of the FOGA 1990. 1st International Workshop on Foundations of Genetic Algorithms*, ed. G.J.E. Rawlins, Bloomington Campus, Indiana, USA, July 15–18, 1990, San Mateo, Morgan Kaufmann Publishers, s. 69–93, ISBN 1-55860-170-8.
- Goliński J., 1974, *Metody optymalizacyjne w projektowaniu technicznym*, Warszawa, Wydawnictwa Naukowo-Techniczne.
- Grunert da Fonseca V., Fonseca C.M., Hall A.O., 2001, Inferential performance assessment of stochastic optimizers and the attainment function, in: *Proceedings of the EMO 2001. First International Conference on Evolutionary Multi-Criterion Optimization*, eds. E. Zitzler, K. Deb, L. Thiele, C.A. Coello Coello, D. Corne, Zurich, Switzerland, March 7–9, 2001, Berlin, Springer-Verlag, s. 213–225, ISBN 978-3-540-41745-3.
- Grzybowski L., Łączyński B., Narodzonek A., Puchalski J., 1997, *Kontenery w transporcie morskim*, Gdynia, Trademar, ISBN 83-905412-2-X.
- Grzymkowski R., Kaczmarek K., Kiełtyka S., Nowak I., 2008, *Wybrane algorytmy optymalizacji. Algorytmy genetyczne. Algorytmy mrówkowe*, Gliwice, Wydawnictwo Pracowni Komputerowej Jacka Skalmierskiego, ISBN 978-83-60716-42-7.
- Gutenbaum J., 1992, *Modelowanie matematyczne systemów*, Warszawa, Omnitech Press, ISBN 83-900412-9-4.
- Gwiazda T.D., 2007 a, *Algorytmy genetyczne. Kompendium. Tom I. Operator krzyżowania dla problemów numerycznych*, Warszawa, Wydawnictwo Naukowe PWN S.A., ISBN 978-83-01-15168-3.
- Gwiazda T.D., 2007 b, *Algorytmy genetyczne. Kompendium. Tom II. Operator mutacji dla problemów numerycznych*, Warszawa, Wydawnictwo Naukowe PWN S.A., ISBN 978-83-01-15381-6.
- Haftka R.T., Kamat M.P., 1985, *Elements of Structural Optimization*, [b.m.], Martinus Nijhoff Publishers, ISBN 10 9024729505, ISBN 13 9789024729500.
- Hajela P., Lee E., Lin C.Y., 1993, Genetic Algorithms in Structural Topology Optimization, in: *Topology Design of Structures*, eds. M.P. Bendsoe, C.A. Mota Soares, [b.m.], Kluwer Academic Publishers, s. 117-133, ISBN 0792320557.
- Hajela P., Lin C.Y., 1992, Genetic Search Strategies in Multicriterion Optimal Design, *Structural Optimization*, Vol. 4, s. 99–107.
- Hamada K., Takezawa A., Kitamura M., Kanaikari K., 2009, A Multi-Step Design Optimization Method for Mid-Ship Sections, *Ship Technology Research*, Vol. 56, s. 110–120.
- Handbook of Evolutionary Computation*, 1997, eds. T. Bäck, D.B. Fogel, Z. Michalewicz, Oxford, Taylor & Francis, ISBN 978-0-7503-0895-3.
- Hansen M.P., Jaskiewicz A., 1998, *Evaluating the quality of approximations of the non-dominated set*, IMM Technical Report IMM-REP-1998-7, Lyngby, Institute of Mathematical Modeling, Technical University of Denmark.
- Harik G.R., 1995, Finding Multimodal Solutions Using Restricted Tournament Selection, in: *Proceedings of the ICGA 1995. Sixth International Conference on Genetic Algorithms*, ed. L.J. Eshelman, University of Pittsburgh, July 15–19, 1995, San Francisco, Morgan Kaufmann Publishers, s. 24–30, ISBN 1-55860-370-0.



- Harlander L., 1960, Optimum Plate-Stiffener Arrangement for Various Types of Loading, *Journal of Ship Research*, Vol. 20, No. 4, s. 49–65.
- Hatzidakis N., Bernitsas M., 1994, Comparative Design of Ortoagonally Stiffened Plates for Production, and Structural Integrity. Part 1, 2, *Journal of Ship Production*, Vol. 10, No. 3, s. 146–155, 156–163.
- Haupt R.L., Haupt S.E., 1998, *Practical Genetic Algorithms*, New York, John Wiley & Sons, Inc., ISBN 0471188735, 9780471188735.
- Hearn G.E., Wright P.N.H., 1997, Seakeeping for design: optimisation of motion responses and wave making resistance of catamarans via the application of a genetic algorithm, in: *Proceedings of the FAST 1997. 4th International Conference on Fast Sea Transportation*, eds. N. Baird, A. Jeffs, Sydney, Australia, July 21–23, 1997, Vol. 1, [b.w.], s. 231–240, ISBN 0958701334.
- Hearn G.E., Wright P.N.H., Yaakob O.B., 1995, Seakeeping for design: identification of hydrodynamically optimal hull forms for large high speed catamarans, in: *Proceedings of International Symposium On High Speed Vessels for Transport and Defence*, London, UK, November 23–24, 1995, Paper No. 4, [b.m.], RINA, s. 1–15.
- Horn J., 1997 a, *The nature of niching: Genetic Algorithms and the evolution of Optimal, Cooperative Population*, PhD Thesis, Champaign, Urbana, Illinois, University of Illinois at Urbana.
- Horn J., 1997 b, F1.9 Multicriteria Decision Making, in: *Handbook of Evolutionary Computation*, eds. T. Back, D.B. Fogel, Z. Michalewicz, Bristol, Institute of Physics Publishing, ISBN 0750308958, 9780750308953.
- Horn J., Nafpliotis N., 1993, *Multiobjective Optimization Using The Niche Pareto Genetic Algorithm*, Illinois Genetic Algorithms Laboratory (IlligAL) Report No. 93005, Champaign, Urbana, Illinois, University of Illinois at Urbana.
- Hughes E.J., 2003, Multiple Single Objective Sampling, in: *Proceedings of the CEC 2003. Congress on Evolutionary Computation*, Canberra, Australia, December 8–12, 2003, Piscataway, NJ, USA, IEEE, s. 2678–2684, ISBN 0-7803-7804-0.
- Hughes E.J., 2005, Evolutionary Many-Objective Optimization: Many Once or One Many?, in: *Proceedings of the CEC 2005. Congress of Evolutionary Computation*, Edinburgh, Scotland, UK, September 2–4, 2005, [b.m.], IEEE Press, s. 222–227, ISBN 0-7803-9363-5.
- Hughes E.J., 2007, MSOPS-II General-Purpose Many-Objective Optimizer, in: *Proceedings of the CEC 2007. Congress of Evolutionary Computation*, Singapore, September 25–28, 2007, [b.m.], IEEE Press, s. 3944–3951, ISBN 1-4244-1340-0.
- Hughes O.F., 1985, A general method for computer aided optimum structural design of ocean structures, in: *Proceedings of the Computer Applications in the Automation of Shipyard Operation and Ship design, IFIP/IFAC International Conference*, eds. P. Banda, C. Kuo, G. Di Filippo, Trieste, Italy, September 16–20, 1985, [b.w.], Vol. 1, s. 13–26, ISBN 0444878203.
- Hughes O.F., 1987, A Practical Method for the Optimum Structural Design of Mobile Units, in: *Proceedings of the PRADS 1987. The Third International Symposium on Practical Design of Ships and Mobile Units*, ed. O.M. Faltison, Trondheim, Norway, June 22–26, 1987, [b.w.], s. 1106–1115.
- Hughes O.F., 1988, *Ship Structural Design: A Rationally-Based, Computer-Aided Optimization Approach*, Jersey City, New Jersey (USA), Society of Naval Architects and Marine Engineers (SNAME), ISBN 0939773090.
- Hughes O.F., Mistree F., 1977, A Comprehensive Method for the Automated Optimization of Ship Structures, in: *Proceedings of the PRADS 1977. International Symposium on Practical Design in Shipbuilding*, Tokyo, 1977, [b.w.], s. 35–44.

- Hughes O.F., Mistree F., Žanić V., 1980, A Practical Method for the Rational Design of Ship Structures, *Journal of Ship Research*, Vol. 24, No. 2, s. 101–113.
- Hughes O.F., Paik J.K., 2010, *Ship Structural Design and Analysis*, Jersey City, New Jersey (USA), Society of Naval Architects and Marine Engineers (SNAME), ISBN 978-0-939773-78-3.
- Hung C.F., 1987, Computer Aided Design of Complex Ship Structure Based on Finite Element and Multilevel Optimization Methods, in: *Proceedings of the PRADS 1987. 3rd International Symposium on Practical Design of Ships and Mobile Units*, ed. O.M. Faltison, Trondheim, June 22–26, 1987, [b.w.], s. 845–860.
- Hutchinson K.W., Sen P., Buxton I.L., Hills W., 1998, Multiple Criteria Design Optimisation of Ro-Ro Passenger Ferries with Consideration of recently proposed Probabilistic Stability Standards, in: *Proceedings of the PRADS 1998. Seventh International Symposium on Practical Design of Ships and Mobile*, eds. M.W.C. Oosterveld, S.G. Tan, The Hague, The Netherlands, September 20–25, 1998, [b.w.], s. 303–312, ISBN 0-444-82918-0.
- Hwang C.L., Masud S.M., 1979, *Multiple objective decision making, methods and applications: A state-of-the-art survey*, Berlin, Springer-Verlag, ISBN 0387091114.
- Hwang C.L., Yoon K., 1981, *Multiple attribute decision making: Methods and applications: a state-of-art survey*, Berlin, Springer-Verlag, ISBN 0387105581.
- IACS, 1999, *General Cargo Ships. Guidelines for Surveys, Assessment and Repair of Hull Structure*, London, Wtherbys Publishing, ISBN 1-85609-189-9.
- IACS, 2002 a, *Bulk Carriers. Guidelines for Surveys, Assessment and Repair of Hull Structures*, London, Wtherbys Publishing, ISBN 978-1-85609-223-4.
- IACS, 2002 b, *Container Ships. Guidelines for Surveys, Assessment and Repair of Hull Structures*, London, Wtherbys Publishing, ISBN 1-85609-296-8.
- IACS, 2005, *Container Ships. Guidelines for Surveys, Assessment and Repair of Hull Structures*, London, Wtherbys Publishing, ISBN 1-85609-296-8.
- Ishibuchi H., Murata T., 1996, Multi-objective genetic local search algorithm, in: *Proceedings of the ICEC 1996. IEEE International Conference on Evolutionary Computation*, Nagoya University, Japan, May 20–22, 1996, [b.m.], IEEE Press, s. 119–124, ISBN-10 0780329031, ISBN-13 978-0780329034.
- Ishibuchi H., Murata T., 1998, A Multi-Objective genetic local search algorithm and Its Application to Flowshop Scheduling, *IEEE Transactions on Systems, Man, and Cybernetics. Part C: Applications and Reviews*, Vol. 28, No. 3, s. 392–403.
- Ishibuchi H., Nojima Y., 2007, Optimization of Scalarizing Functions Through Evolutionary Multi-objective Optimization, in: *Proceedings of the EMO 2007. Evolutionary Multi-Criterion Optimization. 4th International Conference*, eds. S. Obayashi, K. Deb, C. Poloni, T. Hiroyasu, T. Murata, Matsushima, Japan, March 2007, Germany, Springer, s. 51–65, ISBN 3-540-70927-4.
- Ishibuchi H., Tsukamoto N., Hitosuyanagi Y., Nojima Y., 2008, Effectiveness of Scalability Improvement Attempts on the Performance of NSGA-II for Many-Objective Problems, in: *Proceedings of the GECCO 2008. Genetic and Evolutionary Computation Conference*, eds. C. Ryan, M. Keijzer, Atlanta, GA, USA, July 12–16, 2008, s. 649–656, ISBN 978-1-60558-130-9.
- Ishibuchi H., Tsukamoto N., Nojima Y., 2008, Evolutionary Many-Objective Optimization: A Short Review, in: *Proceedings of the CEC 2008. IEEE Congress on Evolutionary Computation*, Hong Kong, China, June 1–6, 2008, [b.w.], s. 2424–2431, ISBN 978-1-4244-1821-3.
- Ishibuchi H., Yoshida T., Murata T., 2003, Balance between Genetic Search and Local Search in Memetic Algorithms for Multiobjective Permutation Flowshop Scheduling, *IEEE Transactions on Evolutionary Computation*, Vol. 7, s. 204–223.

- Islam M.M., Khondoker M.R.H., Rahman C.M., 2001, Application of artificial intelligence techniques in automatic hull form generation, *Ocean Engineering*, Vol. 28, s. 1531–1544.
- ISSC, 1976, Numerical Methods. Structural Optimization. Report of ISSC Committee IV.1, in: *Proceedings of the ISSC 1976. 6th International Ship Structures Congress*, eds. J.H. Evans, N. Jones, Boston 1976, [b.w.], s. 3–17.
- ISSC, 1988, Design Optimisation. Report to Committee V.5 of ISSC, in: *Proceedings of the ISSC 1988. 10th International Ship and Offshore Structures Congress*, eds. P. Terndrup-Pedersen, J.J. Jensen, Lyngby, Denmark 1988, Vol. 2, [b.w.], s. 179–221.
- ISSC, 1991, Report of ISSC Committee IV.1 – Design Philosophy, in: *Proceedings of the ISSC 1991. 11th International Ship and Offshore Structures Congress*, eds. P.H. Hsu, Y. Wu, Wuxi, China 1991. Vol. 1, [b.m.], s. 575–644.
- ISSC, 1994, Report of Committee IV.1 Design Philosophy, in: *Proceedings of the ISSC 1994. 12th International Ship and Offshore Structures Congress*, eds. N.E. Jeffrey, A.M. Kendrick, St. John's, Canada 1994. Vol. 1, [b.m.], Institute for Marine Dynamics, s. 525–592.
- ISSC, 1997, Design Methods. Report of ISSC Committee IV.2, in: *Proceedings of the ISSC 1997. 13th International Ship and Offshore Structures Congress*, eds. T. Moan, S. Berge, Trondheim, Norway 1997. Vol. 1, [b.m.], Pergamon Press – Elsevier Science, s. 407–473, ISBN-10 0080428290, ISBN-13 978-0080428291.
- ISSC, 2000, Design Methods. Report of ISSC Committee IV.2, in: *Proceedings of the ISSC 2000. 14th International Ship and Offshore Structure Congress*, eds. H Ohtsubo, Y Sumi, Nagasaki, Japan, October 2–6, 2000, Amsterdam, Elsevier, ISBN 0080436021.
- ISSC, 2006 a, Report of Committee IV.1 Design Principles and Criteria, in: *Proceedings of the ISSC 2006. 16th International Ship and Offshore Structures Congress*, August 20–25, 2006, Southampton, UK, August 20–25, 2006, Dorchester, Dorset, University of Southampton, s. 529–607, ISBN 0854328556.
- ISSC, 2006 b, Report of ISSC Committee IV.2. Design Methods, in: *Proceedings of the ISSC 2006. 16th International Ship and Offshore Structures Congress*, Southampton, UK, August 20–25, 2006. Vol. 1, Dorchester, Dorset, University of Southampton, s. 609–686, ISBN 085432 8556.
- ISSC, 2009 a, Report of Committee IV.1. Design Principles and Criteria, in: *Proceedings of the ISSC 2009. 17th International Ship and Offshore Structures Congress*, Seul, Korea, August 16–21, 2009, Seul, Korea, Seul National University, s. 587–688, ISBN 9788995473016.
- ISSC, 2009 b, Report of ISSC Committee IV.2. Design Methods, in: *Proceedings of the ISSC 2009. 17th International Ship and Offshore Structures Congress*, Seul, Korea, August 16–21, 2009, Seul, Korea, Seul National University, Vol. 1, s. 689–756, ISBN 9788995473016.
- Jagoda J., 1975, Metoda oceny wielokryterialnych rozwiązań projektowych, *Budownictwo Okrętowe*, maj/czerwiec, s. 222–224.
- Jang B.S., Ko D.E., Suh Y.S., Yang Y.S., 2009, Adaptive approximation in multi-objective optimization for full stochastic fatigue design problem, *Marine Structures*, Vol. 22, s. 610–632.
- Jang C.D., Na S.S., 1987, On the Minimum Structural Weight Design of Oil Tankers by Generalized Slope Deflection Method, in: *Proceedings of the PRADS 1987. 3rd International Symposium on Practical Design of Ships and Mobile Units*, Trondheim, Norway, June 22–26, 1987, [b.w.], s. 1128–1137.
- Jang C.D., Na S.S., 1991, On the Optimum Structural Design of MARPOL Tankers Considering Tank Arrangement, in: *Proceedings of the CADMO 1991. Computer methods in marine and offshore engineering. Third International Conference on Computer Aided Design, Manufacture and Operation in the Marine and Offshore Industries*, ed. T.K.S. Murthy, Key Biscayne, Florida, USA, January 15–17, 1991, Southampton, UK, Computational Mechanics Publications, s. 25–40, ISBN 1853121223.

- Jang C.D., Seo S.I., 1996, A Study on the Optimum Structural Design of Surface Effect Ship, *Marine Structures*, Vol. 9, s. 519–544.
- Jang C.D., Shin S.H., 1997, A Study on the Optimal Structural Design for Oil Tankers Using Multi Objective Optimization, in: *Proceedings of the IMDC 1997. 6th International Marine Design Conference*, eds. P. Sen, R. Birmingham, University of Newcastle, United Kingdom, June 23–25, 1997, Vol. 1, [b.m.], Penshaw Press, s. 217–231, ISBN 0951880691.
- Jastrzębski T., 1991, *Projektowanie konstrukcji okrętowych i oceanotechnicznych. Wstęp do projektowania konstrukcji kadłubów okrętów*, Szczecin, Politechnika Szczecińska.
- Jastrzębski T., 1994, *Wybrane elementy teorii projektowania morskich konstrukcji pływających*, Szczecin, Politechnika Szczecińska.
- Jastrzębski T., Puchaczewski N., 1989, *Projektowanie konstrukcji okrętowych i oceanotechnicznych. Stale do budowy kadłubów okrętów i obiektów oceanotechnicznych*, Szczecin, Politechnika Szczecińska.
- Jastrzębski T., Sekulski Z., 2005, Genetic algorithm application to high speed craft structural optimisation, in: *Proceedings of the IMAM 2005. 12th International Congress of the International Maritime Association of the Mediterranean*, eds. C. Guedes Soares, Y. Garbatov, N. Fonseca, Lisboa, Portugal, September 26–30, 2005, London, Taylor & Francis, s. 859–868, ISBN 978-0-415-39036-1.
- Jastrzębski T., Sekulski Z., Gutowski P., Taczala M., Jazukiewicz A., 2007, Optimisation of the container ship hull structure, in: *Proceedings of the MARSTRUCT 2007. 1st International Conference on Marine Structures*, eds. C. Guedes Soares, P.K. Das, Glasgow, United Kingdom, March 12–14, 2007, London, Taylor & Francis, s. 465–472, ISBN 0415437253, 9780415437257.
- Jaszkiewicz A., 2001, *Multiple Objective Metaheuristic Algorithms for Combinatorial Optimization*, Poznań, Wydawnictwo Politechniki Poznańskiej, ISBN 83-7143-498-7.
- Jaszkiewicz A., 2002, On the Performance of Multiple-Objective Genetic Local Search on the 0/1 Knapsack Problem – A comparative Experiment, *IEEE Transactions on Evolutionary Computation*, Vol. 6, s. 402–412.
- Jaszkiewicz A., 2004, On the Computational Efficiency of Multiple Objective Metaheuristic: The Knapsack Problem Case Study, *European Journal of Operational Research*, Vol. 158, s. 418–433
- Jelovica J., Klanac A., 2009, Multi-objective optimization of ship structures: using guided search vs. conventional concurrent optimization, in: *Proceedings of the MARSTRUCT 2009. 2nd International Conference on Marine Structures*, eds. C. Guedes Soares, P. K. Das, Lisboa, March 16–18, 2009, London, UK, Taylor & Francis Group, s. 447–457, ISBN 978-0-415-54934-9.
- Jendo S., 1979, *Optymalizacja konstrukcji ciągnowych i ramownicowych w zakresie sprężystym według kryterium minimum objętości ciężaru lub kosztu*, Rozprawa habilitacyjna, Warszawa, Instytut Podstawowych Problemów Techniki PAN.
- Jendo S., Niczyj J., 1999, Reliability Assessment of Structural Systems by Fuzzy Sets, in: *Proceedings of the ESREL 1999. The Tenth European Conference on Safety and Reliability*, eds. G.I. Schueller, P. Kafka, Munich-Garching, Germany, September 13–17, 1999, Rotterdam, A.A. Balkema, s. 501–506, ISBN 9058091104 9789058091109.
- Jianguo W., Zuoshui X., 1996, Symmetric Solution of Fuzzy Multi-Objective Optimization for Ship Structure, *Journal of East China Shipbuilding Institute*, Vol. 10, No. 1, s. 1–7.
- Judziński M., 2001, *Podstawy bezpiecznej eksploatacji masowców*, Gdynia, Fundacja Rozwoju WSM w Gdyni, ISBN 83-87438-71-5.
- Katoh A., Li Q., Furuno H., Matsuo A., 1998, Evaluation of strength for double hull structure in initial hull planning and optimization of hull weight with genetic algorithms, *Journal of the Society of Naval Architects of Japan*, Vol. 184, s. 539–549.

- Kavlie D., 1966, Optimization of Plane Elastic Grillages, PhD Thesis, Trondheim, Norway Department of Ship Structures, Technical University of Norway.
- Keane A.J., Price W.G., Schachter R.D., 1991, Optimization techniques in ship concept design, *Transactions of the Royal Institution of Naval Architects (RINA)*, Vol. 133, part A, s. 123–143.
- Khara V., Yao X., Deb K., 2003, Performance Scaling of Multi-objective Evolutionary Algorithms, in: *Proceedings of the EMO 2003. Second International Conference on Evolutionary Multi-criterion Optimization*, eds. C.M. Fonseca, P.J. Fleming, E. Zitzler, K. Deb, L. Thiele, Faro, Portugal, April 8–11, 2003, Heidelberg, Springer-Verlag, s. 376–390, ISBN-10 3540018697, ISBN-13 9783540018698.
- Kicinger R., Arciszewski T., De Jong K., 2005, Evolutionary computation and structural design: A survey of the state-of-the-art, *Computers Structures*, Vol. 83, No. 23–24, s. 1943–1978.
- Kitamura M., Nobukawa H., Yang F., 2000, Application of a genetic algorithm to the optimal structural design of a ship's engine room taking dynamic constraints into consideration, *Journal of Marine Science and Technology*, Vol. 5, No. 3, s. 131–146.
- Klanac A., Ehlers S., Jelovica J., 2009, Optimization of crashworthy marine structures, *Marine Structures*, Vol. 22, s. 670–690.
- Klanac A., Jelovica J., 2007 a, Vectorization in the structural optimization of a fast ferry, *Brodogradnja-Shipbuilding*, Vol. 58, No. 1, s. 11–17.
- Klanac A., Jelovica J., 2007 b, A concept of omni-optimization, for ship structural, design, in: *Proceedings of the MARSTRUCT 2007. 1st MARSTRUCT International Conference*, eds. C. Guedes Soares, P.K. Das, Glasgow, UK, March 12–14, 2007, London, Taylor & Francis, s. 473–481, ISBN 978-0-415-43725-7.
- Klanac A., Jelovica J., 2009, Vectorization and constraint grouping to enhance optimization of marine structures, *Marine Structures*, Vol. 22, s. 225–245.
- Klanac A., Kujala P., 2004, Optimal Design of Steel sandwich panel Applications in Ships, in: *Proceedings of the PRADS 2004. 9th Symposium on Practical Design of Ships and Other Floating Structures*, Lubeck-Travemuende, Germany, September 12–17, 2004, Vol. 2, [b.w.], s. 907–914.
- Klanac A., Niemeläinen M., Jelovica J., Remes H., Domagallo S., 2008, Structural omni-optimization of a tanker, in: *Proceedings of the COMPIT'2008. 7th International Conference on Computer Applications and Information Technology in the Maritime Industries*, eds. P. Rigo, V. Bertram, Bedford Hotel, Liege, Belgium, April 21–23, 2008, [b.w.], s. 537–550, ISBN-10 2-9600785-0-0.
- Knowles J.D., Corne D., 1999, The Pareto Archived Evolution Strategy: a New Baseline Algorithm for Multiobjective Optimisation, in: *Proceedings of the CEC 1999. 1999 Congress on Evolutionary Computation*, Washington, D.C., United States, July 6–9, 1999, [b.m.], IEEE Service Center, s. 98–105, ISBN 0780355369, 9780780355361.
- Knowles J.D., Corne D., 2000, Approximating the Non-dominated Front Using the Pareto Archived Evolution Strategy, *Evolutionary Computation*, Vol. 8, No. 2, s. 149–172.
- Knowles J.D., Thiele L., Zitzler E., 2006, *A tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers*, TIK-Report No. 214, ETH Zurich, Switzerland, Computer Engineering and Networks Laboratory.
- Kogiso N., Watson L.T., Gürdal Z., Haftka R.T., 1994, Genetic algorithms with local improvement for composite laminate design, *Structural Optimization*, Vol. 7, No. 3, s. 207–218.
- Konak A., Coit D.W., Smith A.E., 2006, Multi-objective optimization using genetic algorithms: A tutorial, *Reliability Engineering and System Safety*, Vol. 91, s. 992–1007.
- Konarzewska-Gubała E., 1980, *Programowanie przy wielorakości celów*, Warszawa, Państwowe Wydawnictwo Naukowe, ISBN 8301009977, 9788301009977.

- Kong Y.M., Choi S.H., Song J.D., Yang B.S., 2006, OPTISHIP: a new optimization framework and its application to optimum design of ship structure, *Structural and Multidisciplinary Optimization*, Vol. 32, s. 397–408.
- Konieczny L., Listkowski A., Mykowski R., 1994, Optimum Design of Bulk-Carrier Midship Section with DnV Rule Constraints and Double Bottom Strength Assessment as an Orthotropic Plate, *Polish Maritime Research*, September, 1994, s. 13–16
- Konstrukcje okrętowe ze stopów aluminium, 1976, red. K. Cudny, Gdańsk, Wydawnictwo Morskie.
- Koumousis V.K., Georgiou P.G., 1994, Genetic Algorithms in Discrete Optimization of Steel Truss Roofs, *Journal of Aerospace Engineering*, Vol. 8, No. 3, s. 309–325.
- Kowalski J., 1983, *Modelowanie obiektów konstrukcyjnych w projektowaniu optymalnym*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-0508-4.
- Kozielecki J., 1977, *Psychologiczna teoria decyzji*, Warszawa, Państwowe Wydawnictwo Naukowe.
- Kozłowski J., Wilczopolski M., Wituszyński K., 1982, *Konstrukcje okrętowe z kompozytów polimerowych*, Gdańsk, Wydawnictwo Morskie.
- Köksalan M., Wallenius J., Zionts S., 2011, *Multiple Criteria Decision Making. From Early History to the 21st Century*, Singapore, World Scientific Publishing Company, ISBN 978-981-4335-58-4.
- Kriezis G.A., 1991, Standardization in Ship Structural Design, *Journal of Ship Production*, Vol. 7, No. 1, s. 37–46.
- Krol W.P., 1991, Midship Section Design Using a Bilevel Production Cost Optimization Scheme, *Journal of Ship Production*, Vol. 7, No. 1, s. 29–36.
- Kruisselbrink J.W., Emmerich M.T.M., Back T., Bender A., Ijzerman A.P., Van Der Horst E., 2009, Combining Aggregation with Pareto Optimization: A Case Study in Evolutionary Molecular Design, in: *Proceedings of the EMO 2009. 5th International Conference on Evolutionary Multi-Criterion Optimization*, eds. M. Ehrgott, C.M. Fonseca, X. Gandibleux, J.K. Hao, M. Sevaux, Nantes, France, April 7–10, 2009, Berlin, Springer-Verlag, s. 453–467, ISBN 978-3-642-01019-4.
- Kursawe F., 1991, A variant of evolution strategies for vector optimization, in: *Proceedings of the PPSN I. 1st Workshop on Parallel Problem Solving from Nature*, eds. H.P. Schwefel, R. Manner, Dortmund, Germany, October 1–3, 1990, Berlin, Springer-Verlag, s. 193–197, ISBN 3-540-54148-9.
- Kusiak J., Danielewska-Tulecka A., Oprocha P., 2009, *Optymalizacja. Wybrane metody z przykładami zastosowań*, Warszawa, Wydawnictwo Naukowe PWN, ISBN 978-83-01-15961-0.
- Lamb T., 2004, *Ship Design and Construction*, The Principles of Naval Architecture Series, New York, N.Y., The Society of Naval Architects and Marine Engineers (SNAME), ISBN 0939773406.
- Larsson L., Raven H.C., 2010, *Ship Resistance and Flow*, The Principles of Naval Architecture Series, New York, N.Y., The Society of Naval Architects and Marine Engineers (SNAME), ISBN-10 0939773767, ISBN-13 978-0939773763.
- Laumanns M., Rudolph G., Schwefel H., 1999, *Approximating the Pareto Set: Concepts, Diversity Issues, and Performance Assessment*, Report No. CI-72/99, University of Dortmund, Collaborative Research Center 531, Germany.
- Lee D., 1997, Multiobjective design of a marine vehicle with aid of design knowledge, *International Journal for Numerical Methods in Engineering*, Vol. 40, s. 2665–2677.
- Lee D., Kim S.Y., 1996, Techno-Economic Optimization of an LNG Carrier with Multicriteria in the Preliminary Design Stage, *Journal of Ship Production*, Vol. 12, No. 3, s. 141–152.
- Lee K.Y., Roh M.I., 2001, An Efficient Genetic Algorithm Using Gradient Information for Ship Structural Design Optimization, *Ship Technology Research*, Vol. 48, s. 161–170.
- Lerch A., 2010, *Architektura statków i okrętów. Projektowanie i konstrukcja*, Gdańsk, Akademia Sztuk Pięknych w Gdańsku, ISBN 978-83-929697-7-8.



- Leyland G., 2002, *Multi-objective Optimization Applied to Industrial Energy Problems*, PhD Thesis, Lausanne, Switzerland, École Polytechnique Fédérale de Lausanne.
- Lin C.Y., Hajela P., 1992, Genetic Algorithms in Optimization Problems with Discrete and Integer Design Variables, *Engineering Optimization*, Vol. 19, s. 309–327.
- Liang Ch.Ch., Hsu Ch.Y., Tsai H.R., 1997, Minimum Weight Design of Submersible Pressure Hull under Hydrostatic Pressure, *Computers & Structures*, Vol. 63, No. 2, s. 187–201.
- LRS, 1996 a, *Fatigue Design Assessment procedure, Structural detail design guide*, London, UK, Lloyd's Register of Shipping.
- LRS, 1996 b, *Guidance notes for the Classification of Special Service Craft. Design Details Small Ships*, London, UK, Lloyd's Register of Shipping.
- Lund S., 1970, *Tanker Frame Optimisation by Means of SUMT-Transformation and Behaviour Models*, Trondheim, Norway, Norges Tekniske Høgskole.
- Lyon T., 1982, A Calculator-Based Preliminary Ship Design Procedure, *Marine Technology*, Vol. 19, No. 2, s. 140–158.
- Łachwa A., 2001, *Rozmyty świat zbiorów, liczb, relacji, faktów, reguł i decyzji*, Warszawa, Akademicka Oficyna Wydawnicza EXIT, ISBN 83-87674-21-4.
- Łomniewski K., Mańkowski W., Zaleski J., 1975, *Morze Bałtyckie*, Warszawa, Państwowe Wydawnictwo Naukowe.
- Man K.F., Tang K.S., Kwong S., 1999, *Genetic Algorithms*, London, Springer-Verlag, ISBN 1852330724, 9781852330729.
- Mansour A.E., 1972, Probabilistic Design Concepts in Ship Structural Safety and Reliability, *SNAME Transactions*, Vol. 80.
- Mansour A., Liu D., 2008, *Strength of Ships and Ocean Structures*, The Principles of Naval Architecture Series, New York, N.Y., Society of Naval Architects and Marine Engineers (SNAME), ISBN 978-0-939773-87-9.
- Marler R.T., Arora, J.S., 2004, Survey of multi-objective optimization methods for engineering, *Structural and Multidisciplinary Optimization*, Vol. 26, s. 369–395.
- Michalewicz Z., 1996, *Genetic Algorithms + Data Structures = Evolution Programs*, Berlin, Springer-Verlag, ISBN 3540606769, 9783540606765.
- Miettinen K., 1998, *Nonlinear Multiobjective Optimization*, Boston, USA, Kluwer Academic Publishers, ISBN-10 0792382781, ISBN-13 9780792382782.
- Mitchell M., 1996, *An Introduction to Genetic Algorithms*, Cambridge, Massachusetts, The MIT Press, ISBN 0262631857, 9780262631853.
- Miura H., Kavale D., Moe J., 1973, Interactive Optimum Design of Tanker Structures, in: *Proceedings of the IFIP/IFAC/JSNA Joint Conference, Computer Applications in the Automation of Shipyard Operation and Ship Design*, eds. Y. Fujita, K. Lind, T.J. Williams, Tokyo, Japan, August 28–30, 1973, [b.w.], s. 349–361, ISBN 0720428165.
- Moe J., Lund S., 1968, Cost and Weight Minimization of Structures with Special Emphasis on Longitudinal Strength Members of Tankers, *Transactions of the Royal Institution of Naval Architects (RINA)*, Vol. 110, No. 1, s. 43–70.
- Moe J., 1968, *Optimum Design of statically Indeterminate Frames by Means of Non-Linear Programming*, Trondheim, Norway, Norges Tekniske Høgskole.
- Moore C.S., 2010, *Intact Stability*, The Principles of Naval Architecture Series, New York, N.Y., USA, The Society of Naval Architects and Marine Engineers (SNAME), ISBN-10 0939773740, ISBN-13 978-0939773749.
- Moses F., Onoda S., 1969, Minimum Weight Design of Structure with Application to Elastic Grillage, *International Journal of Numerical Methods in Engineering*, Vol. 1, s. 311–331.

- Multiobjective Optimization in Engineering and in the Sciences*, 1988, ed. W. Stadler, New York, Plenum Press, ISBN 0306427435, 9780306427435.
- Multi-objective Optimization, 2002, in: *Evolutionary Optimization*, eds. R. Sarker, M. Mohammadian, X. Yao, Boston, Kluwer Academic Publishers, s. 117–198, ISBN 978-0-7923-7654-5.
- Murata T., Ishibuchi H., 1995, MOGA: Multi-objective genetic algorithms, in: *Proceedings of the ICEC 1995. Second IEEE International Conference on Evolutionary Computation*, University of Western Australia, Perth, Western Australia, November 29 – December 1, 1995, [b.m.], IEEE Press, s. 289–294.
- Naar H., Varsta P., Kujala P., 2004, A theory of coupled beams for strength assessment of passenger ships, *Marine Structures*, Vol. 17, No. 8, s. 590–611.
- Nagendra S., Haftka R.T., Gurdal Z., 1992, Stacking Sequence Optimization of Simply Supported Laminates with Stability and Strain Constraints, *American Institute of Aeronautics and Astronautics Journal*, Vol. 30, No. 8, s. 2132–2137.
- Neri F., Saitta L., 1995, Analysis of Genetic Algorithms Evolution under Pure Selection, in: *Proceedings of the ICGA 1995. Sixth International Conference on Genetic Algorithms*, ed. L.J. Eshelman, University of Pittsburgh, July 15–19, 1995, San Francisco, Morgan Kaufmann Publishers, s. 32–39, ISBN 1-55860-370-0.
- Netzel J., Marczak E., Jastrzębski T., Stawicka-Wałkowska M., 2009, *Architektura statków a zagadnienia projektowo-konstrukcyjne*, Gdańsk, Wydawnictwo Politechniki Gdańskiej, ISBN 978-83-928905-0-8.
- Niczyj J., 2003, *Wielokryterialna optymalizacja niezawodnościowa oraz szacowanie stanu technicznego konstrukcji prętowych z zastosowaniem teorii zbiorów rozmytych*, Monografia habilitacyjna, Szczecin, Wydawnictwo Uczelniane Politechniki Szczecińskiej.
- Nobukawa H., Kitamura M., Yang F., Zhou G., 1998, Optimization of Engine Room Structure under Static and Dynamic Constraints Using Genetic Algorithms, *Journal of the Society of Naval Architects of Japan*, Vol. 183, s. 315–322.
- Nobukawa H., Zhou G., Kitamura M., Kobayashi S., 1995, Structural Optimisation for Small Containership with Large Hatch Opening, *Journal of the Society of Naval Architects of West Japan*, Vol. 90, s. 181–197.
- Nobukawa H., Zhou G., 1996, Discrete optimization of ship structures with genetic algorithm, *Journal of the Society of Naval Architects of Japan*, Vol. 179, s. 293–301.
- Nowacki H., 2010, Five decades of Computer-Aided Ship Design, *Computer-Aided Design*, Vol. 42, s. 956–969.
- Nowacki H., Brusis F., Swift P.M., 1970, Tanker Preliminary Design – an Optimization Problem With Constraints, *Transactions of SNAME*, Vol. 78, s. 357–390.
- Okada T., Neki I., 1992, Utilization of Genetic Algorithm for Optimizing the Design of Ship Hull Structure, *Journal of the Society of Naval Architect of Japan*, Vol. 171, s. 71–83.
- Okada T., Neki I., 1995, Utilization of genetic algorithm for optimizing the design of ship hull structures, *Recent Progress on Science & Technology IHI*, Vol. 4, s. 43–55.
- Okumoto Y., Takeda Y., Mano M., Okada T., 2009, *Design of Ship Hull Structures. A Practical Guide for Engineers*, Berlin, Springer-Verlag, ISBN 978-3-540-88444-6.
- Optimistic – Optimization in Marine Design, Proceedings of the 39th WEGEMT Summer School*, 2003, eds. L. Birk, S. Harries, Berlin, May 19 – 23, 2003, Berlin, Mensch & Buch Verlag, ISBN 3-89820-514-2.
- Orszulok W., 1983, *Wytrzymałość kadłuba statku w eksploatacji*, Gdańsk, Wydawnictwo Morskie, ISBN 83-215-1122-8.



- Osiński Z., Wróbel J., 1995, *Teoria konstrukcji*, Warszawa, Wydawnictwo Naukowe PWN, ISBN 83-01-11840-7.
- Osyczka A., 2002, *Evolutionary Algorithms for Single and Multicriteria Design Optimization*, Heidelberg, Germany, Physica-Verlag, ISBN 3-7908-1418-01.
- Paczkowski W.M., 1999, *Wybrane problemy dyskretnej optymalizacji ewolucyjnej*, Monografia habilitacyjna, Szczecin, Wydawnictwo Uczelniane Politechniki Szczecińskiej.
- Pałucha K., Puchalski J., Śliwiński A., 1996, *Statki poziomego ladowania*, Gdynia, Trademar, ISBN 83-900731-1-8.
- Pappas M., Allentuch A., 1973, Automated Optimal Design of Frame Reinforced Submersible, *Circular, Cylindrical Shells. Journal of Ship Research*, Vol. 17, s. 208–216.
- Pareto V., 1896, *Cours D'Economie Politique*, Vol. 1. Lausanne, F. Rouge.
- Parsons M.G., Scott R.L., 2004, Formulation of Multicriterion Design Optimization Problems for Solution With Scalar Numerical Optimization Methods, *Journal of Ship Research*, Vol. 48, No. 1, s. 61–76.
- Parsons M.G., Singer D., 2000, A Fuzzy Logic Agent for Design Team Communications and Negotiations, in: *Proceedings of the COMPIT 2000. 1st International Conference on Computer Applications and Information Technology in the Maritime Industries*, ed. V. Bertram, Potsdam–Berlin, March 30–April 4, 2000, [b.w.], s. 350–363.
- Pham D.T., Karaboga D., 2000, *Intelligent Optimisation Techniques. Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks*, London, Springer-Verlag, ISBN 1-85233-028-7.
- Piegat A., 1999, *Modelowanie i sterowanie rozmyte*, Warszawa, Akademicka Oficyna Wydawnicza EXIT, ISBN 83-87674-14-1.
- Podstawy konstrukcji maszyn*, t. 1, 1995, red. M. Dietrich, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-1940-9.
- Polish fast ferry “Boomerang”, 1997, *HANSA – Schiffahrt – Schiffbau – Hafen*, Vol. 134, No. 6, s. 26, 28–29.
- Potyrała A., 1967, *Konstrukcja kadłuba okrętowego*, Gdynia, Wydawnictwo Morskie.
- Projektoznawstwo. Elementy wiedzy o projektowaniu*, 1988, red. W. Gasparski, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-0810-5.
- Puchalski J., 1998, *Drewno, celuloza, papier w transporcie morskim*, Gdynia, Trademar, ISBN 83-905412-7-0.
- Puchalski J., Soliwoda J., 2008, *Eksploracja masowców*, Gdynia, Trademar, ISBN 978-83-924540-5-2.
- Purshouse R.C., Fleming P.J., 2003, Evolutionary Many-Objective Optimization: An Exploratory Analysis, in: *Proceedings of the CEC 2003. 2003 Congress on Evolutionary Computation*, Canberra, Australia, December 8–12, 2003, University of Michigan, IEEE Press, s. 2066–2073, ISBN 0-7803-7804-0.
- Pyrz M., 1998, Optimization of Variable Thickness Plates by Genetic Algorithms, *Engineering Transactions*, Vol. 46, No. 1, s. 115–129.
- Rafiq M.Y., Southcombe C., 1998, Genetic Algorithms in Optimal Design and Detailing of Reinforced Concrete Biaxial Columns Supported by a Declarative Approach for Capacity Checking, *Computers & Structures*, Vol. 69, s. 443–457.
- Rahman M.K., 1992, Structural Design of a Midship Cargo Hold: Rule-Based and rational Procedures, in: *Proceedings of the PRADS'92. 5th International Symposium on the Practical Design of Ships and Mobile Units*, Newcastle upon Tyne, UK, May, 1992, s. 966–980, [b.w.], ISBN 1-85166-861-6.

- Rahman M.K., Caldwell J.B., 1995, Ship Structures: Improvement by Rational Design Optimisation, *International Shipbuilding Progress*, Vol. 429, s. 61–102.
- Ramasamy J.V., Rajasekaran S., 1996, Artificial Neural Network and Genetic Algorithm for the Design Optimization of Industrial Roofs – a Comparison, *Computers and Structures*, Vol. 58, No. 4, s. 747–755.
- Rao S.S., 1996, *Engineering Optimization. Theory and Practice*, New York, John Wiley and Sons, ISBN 0471550345.
- Ray T, Sha O.P., 1994, Multicriteria Optimisation Model for a Containership Design, *Marine Technology*, Vol. 31, No. 4, s. 258–268
- Reklaitis G.V., Ravindran A., Ragsdell K.M., 1983, *Engineering Optimization. Methods and Applications*, New York, John Wiley and Sons, ISBN-10 0471055794, ISBN-13 978-0471055792.
- Riche R., Haftka R.T., 1993, Optimization of Laminate Stacking Sequence for Buckling Load Maximization by Genetic Algorithm, *American Institute of Aeronautics and Astronautics Journal*, Vol. 31, No. 5, s. 951–956.
- Rigo Ph., 2001 a, A module-oriented tool for optimum design of stiffened structures – Part I, *Marine Structures*, Vol. 14, s. 611–629.
- Rigo Ph., 2001 b, Least-Cost Structural Optimization Oriented Preliminary Design, *Journal of Ship Production*, Vol. 17, No. 4, s. 202–215.
- Rigo Ph., 2003, An integrated Software for Scantling Optimization and Least Production Cost, *Schiffstechnik, Bd. 50 / Ship Technology Research*, Vol. 50, s. 126–141.
- Rigo Ph., Fleury C., 2001, Scantling optimization based on convex linearizations and a dual approach – Part II, *Marine Structures*, Vol. 14, s. 631–649.
- Rigo Ph., Žanić V., Ehlers S., Andrić J., 2010, Design of Innovative Ship Concepts Using an Integrated Decision Support System for Ship Production and Operation, *Brodogradnja*, Vol. 61, No. 4, s. 367–381.
- Rodionov A.A., 1990, *Matematičeskie metody projektirovaniya optimalnykh konstrukcij sudogo korpusa*, Leningrad, Sudostrojenie, ISBN 5-7355-0207-7.
- Sanecka K., Wiliński A., Wojdała K., 1996, Optymalizacja statków i systemów oceanotechnicznych z zastosowaniem algorytmów genetycznych, *Marine Technology Transactions*, Vol. 7, s. 255–271.
- Sarker R., Coello Coello C.A., 2002, Evolutionary Optimization, Chapter 7, Assessment methodologies for multiobjective evolutionary algorithms, in: *Evolutionary Optimization*, eds. R. Sarker, M. Mohammadian, X. Yao, Boston, USA, Academic Publishers, s. 177–195, ISBN 0792376544, 978-0-7923-7654-5.
- Schaffer J.D., 1985, Multiple Objective Optimization with Vector Evaluated Genetic Algorithms, in: *Proceedings of the ICGA 1985. International Conference on Genetic Algorithms and Their Applications*, ed. J.J. Grefenstette, Carnegie-Mellon University, Pittsburgh, PA, USA, July 24–26, 1985, Lawrence Erlbaum Associates, s. 93–100, ISBN 978-0-8058-0426-3.
- Sekulski Z., 2000, *Wpływ wybranych parametrów konstrukcji na niektóre cechy eksploatacyjne dwukadłubowego statku morskiego o dużej prędkości*, Rozprawa doktorska, Szczecin, Politechnika Szczecińska.
- Sekulski Z., 2009 a, Least-weight topology and size optimization of high speed vehicle-passenger catamaran structure by genetic algorithm, *Marine Structures*, Vol. 22, No 4, 2009, s. 691–711.
- Sekulski Z., 2009 b, Structural weight minimization of high speed vehicle-passenger catamaran by genetic algorithm, *Polish Maritime Research*, Vol. 16, No. 2 (60), s. 11–23.
- Sekulski Z., 2010, Multi-objective topology and size optimization of high speed vehicle-passenger catamaran structure by genetic algorithm, *Marine Structures*, Vol. 23, No. 4, s. 405–433.

- Sekulski Z., 2011 a, Multi-objective optimization of high speed vehicle-passenger catamaran by genetic algorithm. Part I. Theoretical background on evolutionary multi-objective optimization, *Polish Maritime Research*, Vol. 18, No. 2 (69), s. 3–18.
- Sekulski Z., 2011 b, Multi-objective optimization of high speed vehicle-passenger catamaran by genetic algorithm. Part II. Computational simulations, *Polish Maritime Research*, Vol. 18, No. 3 (70), s. 3–30.
- Sekulski Z., 2011 c, Multi-objective optimization of high speed vehicle-passenger catamaran by genetic algorithm. Part III. Analysis of results, *Polish Maritime Research*, Vol. 18, No. 4 (71), s. 3–13.
- Sekulski Z., Czyrkun D., 2003, Approximate formulae for evaluation of structural mass of twin hull high speed ferries, *Marine Technology Transactions*, Vol. 14, s. 227–247.
- Sekulski Z., Jastrzebski T., 1998, Optimisation of the fast craft deck structure by the Genetic Algorithms, *Marine Technology Transactions*, Vol. 9, s. 165–188.
- Sekulski Z., Jastrzebski T., 1999 a, Optimisation of the fast craft structure by the genetic algorithm, in: *Proceedings of the ODRA '99. Third International Conference on Marine Technology*, eds. T. Graczyk, T. Jastrzebski, C.A. Brebbia, Szczecin, Poland, October 11–13, 1999, Southampton, England, WIT Press, s. 51–60, ISBN 1853126993 9781853126994.
- Sekulski Z., Jastrzebski T., 1999 b, 3D optimisation problem of the ship hull structure by the Genetic Algorithm, *Marine Technology Transactions*, Vol. 10, s. 247–264.
- Sen P., Shi W., Caldwell J., 1989 a, Efficient design of panel structures by a general multiple criteria utility, *Engineering Optimization*, Vol. 14, No. 4, s. 287–310.
- Sen P., Yang J.B., 1995, An Investigation Into the Influence of Preference Modelling in Ship Design with Multiple Objectives, in: *Proceedings of PRADS '95. 6th International Symposium on Practical Design of Ships and Mobile Units*, eds. H. Kim, J.W. Lee, Seoul, Korea, September 17–22, 1995, Vol. 2, [b.m.], Society of Naval Architects of Korea, s. 1252–1263.
- Shaffer J.D., 1985, Multiple objective optimization with vector evaluated genetic algorithms, in: *Proceedings of the ICGA 1985. First International Conference on Genetic Algorithms*, ed. J.J. Grefenstette, Pittsburgh, PA, USA, July, 1985, [b.m.], Lawrence Erlbaum Associates, s. 93–100, ISBN 0-8058-0426-9
- Shin S.H., Song H.C., Jang C.D., 2006, Optimum structural design of tankers using multi-objective optimization technique, *Ships and Offshore Structures*, Vol. 1, No. 3, s. 213–219.
- Ship Design and Construction*, 1980, ed. R. Taggard, New York, N.Y., USA, The Society of Naval Architects and Marine Engineers, ISBN-10 0960304800, ISBN-13 978-0960304806.
- Sindhya K., Deb K., Miettinen K., 2008, A local Search Based Evolutionary Multi-Objective Optimization Approach for Fast and Accurate Convergence, in: *Proceedings of the PPSN 2008. 10th International Conference On Parallel Problem Solving from Nature*, eds. G. Rudolph, T. Jansen, S. Lucas, C. Poloni, N. Beume, Technische Universität Dortmund, Germany, September 13–17, 2008, Heidelberg, Springer-Verlag, s. 815–824, ISBN 978-3-540-87699-1.
- Sommersel T., 1997, Application of genetic algorithms in practical ship design, in: *Proceedings of the IMDC'97. The Sixth International Marine Design Conference*, eds. P. Sen, R. Birmingham, Vol. 1, Department of Marine Technology, University of Newcastle, June 23–25, 1997, [b.w.], s. 611–626, ISBN 0951880691.
- Soremekun G., Gurdal Z., Haftka R.T., Watson L.T., 2001, Composite laminate design optimization by genetic algorithm with generalized elitist selection, *Computers and Structures*, Vol. 79, s. 131–143.
- Spears W.M., De Jong K.A., 1991, An Analysis of Multi-Point Crossover, in: *Proceedings of the FOGA 1991. Foundations of Genetic Algorithms*, ed. G.J.E. Rawlins, Bloomington Campus, Indiana, USA, July 15–18, 1990, San Francisco, Morgan Kaufmann Publishers, s. 301–315, ISBN 1-55860-170-8, 978-1-55860-170-3.

- Srinivas N., Deb K., 1994, Multiobjective Optimization Using Nondominated Sorting in Genetic Algorithms, *Evolutionary Computation*, Vol. 2, No. 3, s. 221–248.
- Stadnicki J., 2006, *Teoria i praktyka rozwiązywania zadań optymalizacji*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-3140-9.
- Statnikov R.B., Matosov J.B., 1995, *Multicriteria Optimization and Engineering*, New York Chapman & Hall, ISBN 0-412-99231-0.
- Stoffa P.L., Sen M.K., 1991, Nonlinear multiparameter optimization using genetic algorithms: Inversion of plane-wave seismograms, *Geophysics*, Vol. 56, No. 11, s. 1794–1810.
- Studziński A., 2005, *Eksploracja chłodniowców*, Gdynia, Trademar, ISBN 83-915444-7-8.
- Syswerda G., 1989, Uniform Crossover in Genetic Algorithms, in: *Proceedings of the ICGA 1989. Third International Conference on Genetic Algorithms*, ed. J.D. Schaffer, Fairfax, Virginia, USA, George Mason University, June 4–7, 1989, [b.m.], Morgan Kaufmann Publishers, s. 2–9, ISBN 1558600663.
- Syswerda G., 1993, Simulated crossover in genetic algorithms, in: *Proceedings of the FOGA 1992. Foundations of Genetic Algorithms Workshop*, ed. D. Whitley, Vail, Colorado, USA, July 26–29, 1992, [b.m.], Morgan Kaufmann, s. 239–255, ISBN 1-55860-263-1.
- Szarejko J., Roguski R., 1974, *Zarys budowy okrętu*, Gdańsk, Wydawnictwo Morskie.
- Szymczak Cz., 1998, *Elementy teorii projektowania*, Warszawa, Wydawnictwo Naukowe PWN, ISBN 83-01-12606-X.
- Tanker Structure Co-operative Forum, 2010, *Guidelines for the Inspection and Maintenance of Double Hull Tanker Structures*, Edinburgh, Scotland, UK., Witherby Seamanship International Ltd., ISBN 1-85609-080-9.
- Tarnowski W., 1984, Model procesu wyboru w projektowaniu technicznym, Gliwice, *Zeszyty Naukowe Politechniki Śląskiej, Seria Automatyka*, nr 72.
- Tarnowski W., 1997, *Podstawy projektowania technicznego*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-2165-9.
- Tarnowski W., 2007, Polioptymalizacja – 25 lat w Polsce, w: *Prace XXV Ogólnopolskiej Konferencji. Polioptymalizacja i komputerowe wspomaganie projektowania Mielno 2007*, red. W. Tarnowski, T. Kiczowski, Koszalin-Sarbinowo, 18–21 czerwca 2007, Koszalin, Politechnika Koszalińska, s. 11–30, ISSN 1640-4572.
- Tarnowski W., 2009, *Optymalizacja i polioptymalizacja w mechatronice*, Koszalin, Wydawnictwo Uczelniane Politechniki Koszalińskiej, ISBN 978-83-7365-172-2.
- Tarnowski W., 2011, *Optymalizacja i polioptymalizacja w technice*, Koszalin, Wydawnictwo Uczelniane Politechniki Koszalińskiej, ISBN 978-83-7365-273-6.
- Taylor D.A., 1984, *Merchant Ship Construction*, Whitstable, Kent, UK, Butterworths & Co. Ltd, ISBN 0-408-01535-7.
- Third Auto Express 82 arrives in Northern Europe, 1997, *Fast Ferry International*, Vol. 36, No. 5, s. 35–36.
- Todd D.S., Sen P., 1997, Multiple Criteria Scheduling Using Genetic Algorithms in a Shipyard Environment, in: *Proceedings of the ICCAS'97. 9th International Conference on Computer Applications in Shipbuilding*, Yokohama, Japan, October 13–17, 1997, [b.w.], s. 259–273.
- Trincas G., Zanic V., Grubisic I., 1994, Comprehensive Concept Design of Fast RO-RO Ships by Multi-Attribute Decision-Making, in: *Proceedings of the IMDC 1994. 5th International Marine Design Conference*, Delft, May 24–27, 1994, [b.w.], s. 403–417.
- Turkmen B.S., Turan O., 2007, A new integrated multi-objective optimisation algorithm and its application to ship design, *Ships and Offshore Structures*, Vol. 2, No. 1, s. 21–37.
- Vanderplaats G.N., 1984, *Numerical Optimization Techniques for Engineering Designs*, New York, McGraw-Hill, ISBN-10 0070669643, ISBN-13 9780070669642.

- Veldhuizen Van D.A., 1999, *Multiobjective Evolutionary Algorithms: Classifications, Analyses, and New Innovations*, PhD Thesis, Ohio, USA, Air Force Institute of Technology, Wright-Patterson AFB.
- Veldhuizen Van D.A., Lamont G.B., 2000, On measuring multiobjective evolutionary algorithm performance, in: *Proceedings of the CEC 2000. Congress on Evolutionary Computation*, eds. A. Zazala, R. Eberhart, La Jolla, CA, USA, July 16–19, 2000, Piscataway, NJ, USA, IEEE Press, s. 204–211.
- Veldhuizen Van D.A., Lamont G.B., 1998, *Multiobjective Evolutionary Algorithm Research: A History and Analysis*, Technical Report TR-98-03, Ohio, USA, Department of Electrical and Computer Engineering, Graduate School of Engineering, Air Force Institute of Technology, Wright-Patterson AFB, Ohio.
- Vorus V., 2010, *Vibration*, The Principles of Naval Architecture Series, New York, N.Y., USA, The Society of Naval Architects and Marine Engineers (SNAME), ISBN 978-0-939773-75-6.
- Wagner T., Beume N., Naujoks B., 2007, Pareto-, Aggregation-, and Indicator-Based Methods in Many-Objective Optimization, in: *Proceedings of the EMO 2007. 4th International Conference on Evolutionary Multi-Criterion Optimization*, eds. S. Obayashi, K. Deb, C. Poloni, T. Hiroyasu, T. Murata, Matsuhima, Japan, March 5–8, 2007, Berlin, Springer-Verlag, s. 742–756, ISBN 3-540-70927-4.
- Wakula W., 1975, *Konstrukcja kadłuba okrętu*, Gdańsk, Wydawnictwo Morskie.
- Wewiórski S., Wituszyński K., 1977, *Konstrukcja stalowego kadłuba okrętowego*, Gdańsk, Wydawnictwo Morskie.
- Wierzchoń S.T., 2001, *Sztuczne systemy immunologiczne: teoria i zastosowania*, Warszawa, Akademicka Oficyna Wydawnicza EXIT, ISBN 83-87674-30-3.
- Wiewióra A., Wesołek Z., Puchalski J., 1999, *Ropa naftowa w transporcie morskim*, Gdynia, Trademar, ISBN 83-905412-9-7.
- Więckiewicz W., 1998, *Zarys budowy statków morskich*, Gdynia, Wydawnictwo Uczelniane WSM.
- Więckiewicz W., 1999, *Budowa kadłubów statków morskich*, Gdynia, Wydawnictwo Uczelniane WSM.
- Wolf R., Dickmann J., Boas R., 2005, Ship Design using Heuristic Optimization Methods, in: *Proceedings of the 46th AIAA/ASME/ASCE/AHS/ASC Structures. Structural Dynamics and Materials Conference*, Austin, TX, USA, April 18–21, 2005, [b.w.], s. 2235–2246.
- Yager R.R., Filev D.P., 1995, *Podstawy modelowania i sterowania rozmytego*, Warszawa, Wydawnictwa Naukowo-Techniczne, ISBN 83-204-1909-3.
- Yang J.M., Hwang C.N., 2002, Optimization of Corrugated Bulkhead Forms by Genetic Algorithm, *Journal of Marine Science and Technology*, Vol. 10, No. 2, s. 146–153.
- Yang C., Soto O., Löhner R., Noblesse F., 2002, Hydrodynamic Optimization of Trimaran, *Ship Technology Research*, Vol. 49, s. 70–92.
- Zamarin A., Jelovica J., Hadjina M., 2009, Multi-objective structural optimization – a review of the genetic algorithm methods, *Engineering Review*, Vol. 29, No. 2, s. 87–100.
- Zanic V., Das P.K., Pu Y., Faulkner D., 1993, Multiple Criteria Synthesis Techniques Applied to Reliability Based Design of SWATH Ship Structure, in: *Proceedings of the Integrity of Offshore Structures – 5. Fifth International Conference on the Integrity of Offshore Structures*, eds. D. Faulkner, M.J. Cowling, A. Incecik, P.K. Das, Glasgow, U.K., June 17–18, 1993, Glasgow, U.K., EMAS Scientific Publications, s. 387–415, ISBN 0-947817-58-1.
- Zanic V., Jancijev T., Andric J., 2000, Mathematical Models for Analysis and Optimization in Concepts and Preliminary Ship Structural Design, in: *Proceedings of the IMAM 2000. 7th International Congress of International Maritime Association of Mediterranean*, eds. P. Cassella, A. Scamardella, G. Festinese, Ischia Island, Naples, Italy, April 2–6, 2000, [b.w.], s. 15–22, ISBN 88-87951-00-4.

- Zanic V., Preberg P., 2004, Primary response assessment method for concept design of monotonous thin-walled structures, in: *Proceedings of the AED 2004. 4th International Conference on Advanced Engineering Design*, Glasgow, UK, September 2004, [b.w.], s. 1–10, ISBN 80-86059-41-3.
- Zanic V., Rogulij A., Jancijev T., Bralić S., Hozmec J., 2002, Methodology for evaluation of ship structural safety, in: *Proceedings of the IMAM 2002. 10th International Congress of International Maritime Association of Mediterranean*, Crete, Greece, May 13–17, 2002, [b.w.].
- Zhang Q., Li H., 2007, MOEA/D: A multiobjective Evolutionary Algorithm Based on Decomposition, *IEEE Transactions on Evolutionary Computation*, Vol. 11, s. 712–731.
- Zhou G., Nobukawa H., Yang F., 1997 a, Discrete optimization of cargo ship with large hatch opening by genetic algorithms, in: *Proceedings of the ICCAS'97. 9th International Conference on Computer Applications in Shipbuilding*, Yokohama, Japan, October 13–17, 1997, [b.m.], The Society of Naval Architects of Japan, s. 231–246, ISBN-10 4930966027, ISBN-13 978-4930966025.
- Zhou G., Nobukawa H., Yang F., 1997 b, Discrete Optimization of Ship Structures from the Viewpoint of Practical Design, *Journal of the Society of Naval Architects of Japan*, Vol. 182, s. 551–559.
- Zitzler E., 1999, *Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications*, Dissertation for degree of Doctor of Technical Sciences, Zurich, Switzerland, Swiss Federal Institute of Technology.
- Zitzler E., Deb K., Thiele L., 2000, Comparison of multiobjective evolutionary algorithms: Empirical results, *Evolutionary Computation*, Vol. 8, No. 2, s. 173–195.
- Zitzler E., Laumanns M., Bleuler S., 2002 a, A tutorial on evolutionary multiobjective optimization, in: *Proceedings of the International workshop MOMH. Multiple Objective MetaHeuristics (MOMH)*, Paris, November 04–05, 2002, Berlin, Springer-Verlag, ISBN 3-540-20637-X.
- Zitzler E., Laumanns M., Thiele L., 2001, *SPEA2: Improving the Strength Pareto Evolutionary Algorithm*, TIK-Report 103, May 2001, Zurich, Switzerland, Swiss Federal Institute of Technology (ETH), Department of Electrical Engineering, Computer Engineering and Networks Laboratory (TIK).
- Zitzler E., Laumanns M., Thiele L., 2002 b, SPEA2: Improving the strength pareto evolutionary algorithm for multiobjective optimization, in: *Proceedings of the EUROGEN 2001. Evolutionary Methods for Design, Optimization, and Control*, eds. K. Giannakoglou, D. Tsahalis, J. Periaux, K. Papailiou, T. Fogarty, Athens, Greece, September 19–21, 2001, Barcelona, Spain, International Center for Numerical Methods in Engineering (Cmine), s. 19–26, ISBN 84-89925-97-6.
- Zitzler E., Laumanns M., Thiele L., Fonseca C.M., Grunert da Fonseca V., 2002 c, Why Quality Assessment of Multiobjective Optimizers is Difficult, in: *Proceedings of the GECCO 2002. Genetic and Evolutionary Computation Conference*, eds. W.B. Langdon, E. Cantú-Paz, K.E. Mathias, R. Roy, D. Davis, R. Poli, K. Balakrishnan, V. Honavar, G. Rudolph, J. Wegener, L. Bull, M.A. Potter, A.C. Schultz, J.F. Miller, E.K. Burke, N. Jonoska, New York, USA, July 9–13, 2002, [b.m.], Morgan Kaufmann Publishers, s. 666–674, ISBN 1-55860-878-8.
- Zitzler E., Thiele L., 1998 a, *An Evolutionary Algorithm for Multiobjective Optimization: The Strength Pareto Approach*, TIK-Report, No. 43, Computer Engineering and Communication Networks Lab, Swiss Federal Institute of Technology, Zurich, Switzerland.
- Zitzler E., Thiele L., 1998 b, Multiobjective Optimization Using Evolutionary Algorithms – A Comparative Case Study, in: *Proceedings of the PPSN V. Fifth International Conference on Parallel Problem Solving from Nature*, eds. E.A.E. Eiben, T. Bäck, M. Schoenauer, H.P. Schwefel, Amsterdam, The Netherlands, September 27–30, 1998, Berlin, Germany, Springer, s. 292–301, ISBN-10 3540650784, ISBN-13 9783540650782.

- Zitzler E., Thiele L., 1999, Multiobjective Evolutionary Algorithms: A Comparative Case Study and Strength Pareto Approach, *IEEE Transactions on Evolutionary Computation*, Vol., No. 4, s. 257–271.
- Zitzler E., Thiele L., Laumanns M., Fonseca C.M., Grunert da Fonseca V., 2002 d, *Performance Assessment of Multiobjective Optimizers: An Analysis and Review*, TIK-Report No. 139, Zurich, Switzerland, Swiss Federal Institute of Technology (ETH).
- Zitzler E., Thiele L., Laumanns M., Fonseca C.M., Grunert da Fonseca V., 2003, Performance Assessment of Multiobjective Optimizers: An Analysis and Review, *IEEE Transactions on Evolutionary Computation*, Vol. 7, No. 2, s. 117–132.





## **Summary**

### **Selected problems of multi-objective optimization in the seagoing ship hull structure preliminary design**

In the continuously changing economic situation the methods for ship structural design used nowadays are sometimes insufficient. A need for modernization of the cognitive apparatus is more and more apparent in the ship structural design to discover and conceptualize various aspects of designing. New methods can be attempted to be found or change the ones used so far. It is possible and may turn efficient application of methods developed in other fields. The results of the investigations prove that in the ship design and, especially, in the ship structural design, multi-objective evolutionary algorithms may be especially useful. Applications of these algorithms, even not many numerous, have been attempted, also by the author, since the 1990th confirmed their effectiveness also in the ship structural design. In this context, an objective of the dissertation is to develop a method for evolutionary multi-objective optimization of complex structures such as ship hull structures.

Multi-objective optimization of complex objects such as the hulls of seagoing vessels, despite more and more greater research and computational potential still encounters many barriers making practical application difficult even at the preliminary design where the models are significantly simpler than the models at the next design stages. The difficulties make investigations and applications related to the ship hull optimization focus on single-objective despite the fact that the most real problems in the ship structural design call for considering more than one optimization objective.

From the point of view of the problems related to the ship hull structural design searching optimal solutions is performed in the following four areas: shape optimization, material optimization, topology optimization as well as optimization of dimensions of structural elements. Due to the specific features of the optimization problems solved in each of these areas it is thus impossible to formulate and solve a single optimization problem covering all the areas. A common practice is therefore that in each of the areas the optimization problem is formulated and solved independently of the others. The division is disadvantageous, however, for the correct designing and the reason can be the lack of suitable tools for simultaneous designing-optimization in all areas. Formulation of the separate optimization problems makes the ship design both longer and more expensive as well as delimits or disables effective search for satisfactory optimal solutions. Yet there is no promising alternative for such a procedure, therefore it seems advisable to attempt to solve unified shape-material-topology-dimension optimization problem. So far the effective tools have not been developed. Investigation towards developing methods for multi-objective optimization seems justified. Due to the complexity of the problem it is reduced to topology-shape optimization treating it as the first step on the way towards formulation and solution of the full unified shape-material-topology-dimension optimization problem.

In the context of the general theory of evolutionary algorithms of multi-objective optimization an original method was developed and applied based on the genetic algorithm. In the method evolution is controlled by the scalar fitting function allowing for consideration of the evaluation objective, level of violating the formulated constraints, internal structure of the set of permissible solutions as well as distances of the generated solutions from the asymptotic solution defined in the dissertation. A set of non-dominated solution in the Pareto sense was taken as the result of solution of the multi-objective problem of the multi-objective optimization. The set is interpreted as an approximation of (unknown) real set of Pareto-optimal solutions. A number of original computational procedures were developed which were applied in the computer codes. Problems of assessment of solution quality and efficiency of the multi-objective evolutionary algorithms, controversial but rarely referred to in the literature, were discussed in details. Quality measures were suggested which allow for efficiency assessment of the developed algorithm.

To verify the computer code a computational model of the fast passenger-car ferry hull structure was developed. A number of computer simulations were performed using the model. The results, which were found the most important, were presented and discussed in details.

Application of the method to optimization of the twin-hull high-speed vessel allowed to demonstrate the specific features of the multi-objective evolutionary optimization methods. It was also possible to formulate the general conclusions and assess the applicability of the method to design analyses of such structures.

The method of multi-objective evolutionary optimization, presented in the dissertation, can be, according to the author's opinion, recommended to be applied to the ship structural preliminary design. It can also be applied to optimization of the other structures after implementation of computational procedures specific for the solved problem.

## **Zusammenfassung**

### **Ausgewählte Probleme der multikriteriellen Optimierung in der Vorentwurfsphase der Seeschiffsrumfskonstruktion**

In der sich ununterbrochen verändernden wirtschaftlichen Realität sind die gegenwärtig verwendeten Entwurfsmethoden von Schiffsrumfskonstruktionen manchmal nicht ausreichend. Im Ergebnis wird immer mehr ein Bedarf nach der Modernisierung des Erkenntnisapparats empfunden, um bestimmte Aspekte beim Entwerfen von diesen Konstruktionen zu entdecken und zu konzeptualisieren. Man kann daher versuchen, nach neuen Methoden zu suchen oder die bestehenden zu ändern. Zu diesem Zweck ist es möglich und kann sich auch als wirksam erweisen, die im Rahmen der anderen Disziplinen entwickelten Methoden zu verwenden. Die Ergebnisse von bisherigen Forschungsarbeiten weisen darauf hin, dass beim Entwerfen von Schiffsrumfskonstruktionen evolutionäre Algorithmen der multikriteriellen Optimierung nutzbar sein können. Die seit Mitte der neunziger Jahre des XX. Jahrhunderts nicht allzu oft vorgenommenen Versuche der Verwendung von diesen Algorithmen, auch vom Verfasser der vorliegenden Abhandlung, bestätigten zuerst ihre Wirksamkeit auch beim Entwerfen von Schiffsrumfskonstruktionen.

Die multikriterielle Optimierung der so komplexen Objekte wie die Seeschiffsrumfskonstruktion stößt trotz des immer größer werdenden Forschungs- und Berechnungspotenzials stets auf viele Hindernisse, die ihre praktische Verwendung sogar in der Vorentwurfsetappe erschweren, wo die entwickelten Konstruktionsmodelle wesentlich einfacher sind als Modelle, die während der nächsten Etappen der Projektierung entwickelt werden. Diese Schwierigkeiten haben zur Folge, dass sich der wesentliche Teil der Forschungs- und Applikationsarbeiten im Bereich der Optimierung der Schiffsrumfskonstruktion auf monokriteriellen Problemen konzentriert, obwohl die Mehrheit der wirklichen Probleme die Berücksichtigung von mehr als nur eines Kriteriums der Optimierung erfordert.

In Hinsicht auf Probleme, die im Entwertprozess von Schiffsrumfskonstruktionen gelöst werden, erfolgt heute die Suche nach optimalen Lösungen in vier Bereichen: Optimierung der Form, Optimierung des Werkstoffes, Optimierung der Topologie und Optimierung der Maße von Konstruktionsteilen. Aufgrund der Spezifik der Optimierungsaufgaben, die in jedem von diesen Bereichen gelöst werden, ist es nicht möglich, eine projektbezogene Optimierungsaufgabe der Schiffskonstruktion gleichzeitig in allen diesen Bereichen zu lösen. Es ist daher generell üblich, dass in jedem von diesen Bereichen Optimierungsaufgaben voneinander unabhängig formuliert und gelöst werden. Solche Aufteilung ist jedoch für korrektes Projektieren ungünstig und ihre Ursachen sind im Fehlen von geeigneten Werkzeugen zu suchen, die es erlauben würden, die Projektierung und Optimierung gleichzeitig in allen diesen Bereichen zu führen. Die Lösung von getrennten Optimierungsaufgaben verteuert und wesentlich verlängert den Projektierungsprozess des Schiffs als auch schränkt ein oder sogar

macht unmöglich eine wirksame Suche nach zufriedenstellenden Optimierungslösungen. Heute ist jedoch keine wirksame Alternativlösung für solche Verfahrensweise in Sicht. Daher scheint es zweckmäßig zu sein, die Versuche einer erfolgreichen Lösung von unifizierten Optimierungsaufgaben der Form, des Werkstoffs, der Topologie und des Maßes aufzunehmen. Bisher wurden dafür keine wirksamen Werkzeuge entwickelt. Als begründet scheinen deswegen Forschungen zu sein, die auf das Erarbeiten einer Methode der multikriteriellen Optimierung ausgerichtet sind, die beim Lösen solcher Aufgaben erfolgreich wäre. Aufgrund des Kompliziertheitsgrades des Problems beschränkte man sich in dieser Arbeit auf die Probleme der Optimierung der Topologie und des Maßes, die als erster Schritt auf dem Wege zum Formulieren und zum Lösen einer vollständigen, unifizierten Aufgabe der Optimierung der Form, des Werkstoffs, der Topologie und des Maßes betrachtet werden.

Im Kontext der allgemeinen Theorie von evolutionären Algorithmen der multikriteriellen Optimierung wurde ein eigener Algorithmus entwickelt und eingesetzt, der auf einem genetischen Algorithmus basiert. Im entwickelten Algorithmus wird die Evolution durch eine skalare Anpassungsfunktion geleitet, die eine Berücksichtigung im Optimierungsprozess der Bewertungskriterien, des Verletzungsgrades der formulierten Beschränkungen, der internen Struktur der Menge von zulässigen Lösungen als auch der Entfernung von generierten Lösungen von der in der Arbeit definierten asymptotischen Lösung ermöglicht. Als Ergebnis der multikriteriellen Lösung einer multikriteriellen Optimierungsaufgabe wurde eine Menge von Lösungen angenommen, die nicht im Sinne des Paretoprinzipis dominiert wurden. Diese Menge wird als eine Annäherung der (unbekannten) realen Menge der Optimallösungen im Sinne des Paretoprinzipis betrachtet. Es wurden viele originelle Berechnungsprozeduren und ein eigenes System der Computerprogramme entwickelt, die die erarbeiteten Algorithmen verwenden. Es wurden Probleme der Bewertung der Qualität von erzielten Lösungen und der Wirksamkeit der evolutionären Algorithmen der multikriteriellen Optimierung im Detail diskutiert, die in der Literatur selten aufgenommen werden und gleichzeitig viele Zweifel und Kontroversen erwecken. Es wurden eigene Qualitätsmaße vorgeschlagen, die eine Bewertung der Wirksamkeit des entwickelten Algorithmus erlauben.

Zur Verifizierung des entwickelten Berechnungswerkzeuges wurde ein Berechnungsmodell der Konstruktion einer schnellen Passagier- und Autofähre formuliert. Anschließend wurden mit diesem Modell viele Computersimulationen durchgeführt. Die als die wichtigsten erachteten Ergebnisse von diesen Berechnungen wurden präsentiert und im Detail diskutiert.

Der Einsatz der vorgeschlagenen Methode am Beispiel der Konstruktion eines schnellen Doppelrumpfschiffes erlaubte die Darstellung der Spezifik der evolutionären Methoden der multikriteriellen Optimierung beim Entwerfen der Seeschiffsrumfkonstruktion. Dies erlaubte wiederum die Formulierung von Verallgemeinerungen und die Bewertung der Eignung von dieser Methode für die Projektuntersuchungen derartiger Konstruktionen.

Die in der Arbeit entwickelte und vorgestellte Methode der multikriteriellen Optimierung kann nach Meinung des Verfassers für den Einsatz beim Entwerfen der Seeschiffsrumfkonstruktion in der Vorentwurfsetappe empfohlen werden. Sie kann auch für die Optimierung der Konstruktion von anderen Ingenieurobjekten eingesetzt werden, jedoch nach der Erarbeitung von entsprechenden Berechnungsprozeduren, die für das zu lösende Problem spezifisch sind.

Biblioteka Główna  
Zachodniopomorskiego Uniwersytetu  
Technologicznego w Szczecinie  
W.140214



012-140214-00-0

ISBN 978-83-7663-111-0