

EWOLUCYJNA WIELOKRYTERIALNA OPTIMALIZACJA OBSERWATORÓW DETEKCYJNYCH

Zdzisław KOWALCZUK, Tomasz BIAŁASZEWSKI

Politechnika Gdańska, Wydział Elektroniki Telekomunikacji i Informatyki
ul. Narutowicza 11/12, 80-952 Gdańsk, e-mail: {kova, bialas}@eti.pg.gda.pl

Streszczenie

W pracy omawiane są możliwości wykorzystania algorytmów ewolucyjnych, opartych na niszowaniu oraz rodzajnikowaniu genetycznym (przypisywaniu rodzajnika), do poszukiwania optymalnych rozwiązań inżynierskich zadań wielokryterialnej optymalizacji. W tego rodzaju obliczeniach skutecznie wykorzystuje się koncepcję Pareto-optymalności oraz rangowania (przypisywania rangi). Realizowany ranking pozwala na uniknięcie arbitralnego ważenia celów kryterialnych (kosztów lub zysków). Zamiast tego, dokonuje się użytecznej klasyfikacji rozwiązań, która bardziej obiektywnie uwzględnia poszczególne kryteria. Jako przykład ilustrujący skuteczność proponowanego podejścia przedstawia się metodologię konstruowania liniowych obserwatorów stanu wykorzystywanych w układach detekcyjnych. Szczególną implementację tego podejścia stanowi projekt systemu diagnostyki bezzałogowego samolotu oraz układu napędowego jednostki pływającej.

Słowa kluczowe: diagnostyka, obserwatory detekcyjne, wielokryterialna optymalizacja, algorytmy genetyczne.

EVOLUTIONARY MULTI-OBJECTIVE OPTIMIZATION OF DETECTION OBSERVERS

Summary

In this paper the concept of evolutionary searching using mechanisms of genetic gendering and niching is used for solving engineering multi-objective optimization tasks. In such types of evolutionary computation (EC) the ideas of Pareto optimality and ranking are effectively utilized. Within the ranking approach we avoid arbitrary weighting of optimisation objectives (costs or gains). Instead, a useful classification of the solutions is performed that takes into account particular objectives more appropriately. In order to illustrate the applicability of the proposed variants of EC, we consider the issue of designing detection observers, which serve as a principal element in procedures of detecting faults, which may occur in exemplarily objects, like an unmanned plane and a ship propulsion system.

Keywords: diagnosis, detection observers, multi-objective optimization, genetic algorithms.

1. WPROWADZENIE

Projektowane systemy techniczne powinny odznaczać się takimi cechami jak: optymalność, odporność, adaptacyjność itp. Łatwo formuluje się też zadania dotyczące optymalności rozwiązania, odporności na zakłócenia oraz zmiany parametrów, które prowadzą do bardziej skutecznego i niezawodnego działania konstruowanych układów detekcji. Ponadto w zadaniach projektowych często pojawia się potrzeba łącznej optymalizacji wielu cząstkowych kryteriów, między którymi trudno jest określić wzajemne zależności [4, 9].

Metody rozwiązywania zadań optymalizacji wielokryterialnej można podzielić na dwie grupy: klasyczne oraz rankingowe (szeregowania). Wśród klasycznych metod optymalizacji wielokryterialnej wyróżnić można: metodę ważonych zysków, metodę odległości oraz metodę ograniczeń nierównościowych. Do metod rankingowych należy zaliczyć: metodę rankingu wg Pareto-optymalności (P-optymalności) oraz metodę rankingu wg globalnego poziomu optymalności (GOL) [3, 4, 7].

Powyższe metody oceny rozwiązań wielokryterialnych łatwo mogą być zastosowane w obliczeniach ewolucyjnych [1, 11, 12, 7].

W pracy omawiane są możliwości wykorzystania mechanizmów niszowania [4, 6, 9] oraz rodzajnika genetycznego [3, 5, 8] w ewolucyjnym rozwiązywaniu wielokryterialnych zadań.

Istotą niszowania jest utrzymanie stałej liczby istniejących gatunków: zarówno tych bardziej licznych (lepiej przystosowanych), jak i tych mniej licznych (słabiej przystosowanych).

Z kolei koncepcja wariantu genetycznego zasada się na podziale zbioru funkcji celów na podzbiory. Podział ten ma pewne własności niszowania, jednak odnosi się do charakteru rozważanych celów tzn. dotyczy przestrzeni kryteriów, a nie rozwiązań. Realizowana w ten sposób suboptymalizacja wykorzystywana jest w procesie ewolucji, w którym tylko rozwiązania o różnym wariacie genetycznym mogą tworzyć pary rodzicielskie generujące nowe rozwiązania.

W pracy prezentuje się wyniki przeprowadzonych genetycznych poszukiwań oraz

jakościową ocenę uzyskanych obserwatorów detekcyjnych na dwóch przykładach konstruowania liniowego obserwatora stanu jako układu detekcyjnego monitorującego system sterowania bezzałogowym samolotem oraz system napędowy jednostki pływającej.

2. GENETYCZNY RODZAJNIK

W naturze podział osobników ze względu na płeć wiąże się nie tylko z ich funkcjami rozrodczymi, ale również kojarzy się z ich funkcjonalną przydatnością do życia w danej społeczności. Zgodnie z tą obserwacją, zaproponowana w [3, 5, 8] idea rodzajnika genetycznego zasadza się na podziale zbioru funkcji celów na kilka rozłącznych podzbiorów, którym przypisywana jest odrębny rodzajnik. Podział ten wynikać powinien z charakteru rozważanych celów. Do ustalonego podzbioru/wariantu (X_j) mogą należeć kryteria o „jednoimiennych” cechach, które są jedynie w stanie „wewnętrznej” rywalizacji (posiadają w przybliżeniu jednakowe znaczenie). Taki zbiorczy sposób kwalifikacji zwalnia projektanta z trudnego zadania wyboru pojedynczego rozwiązania spośród wielu P-optymalnych rozwiązań.

Natomiast zbiór rodzajników genetycznych (X_j) wyraża różne grupy ‘interesów’ (kryteriów), które są trudne do apriorycznego wyważenia przez projektanta. Podział na owe podzbiory może być stosowany w celu umożliwienia ‘zewnętrznej’ rywalizacji „różnoimiennych” cech, która nie jest prosta do rozwiązania. Do ostatecznej oceny uzyskanych rozwiązań można stosować na przykład koncepcję P-optymalności lub globalnej optymalności [3, 4].

W podejściu GGA stosuje się mechanizm przydziału rodzajnika podczas całego ewolucyjnego cyklu w celu tworzenia nowych rozwiązań, ale tylko z osobników rodzicielskich o różnych rodzajnikach. Wektor funkcji kryterialnej może być zatem podzielony na s podwektorów

$$f(x) = [f_1(x) \quad \dots \quad f_s(x)]^T, \quad f_j(x) \in \mathbb{R}^m \quad (1)$$

($j = 1, 2, \dots, s$) definiujących podzbiór cech (wariant X_j). Wśród elementów tego podzbioru ustala się rangę opartą na P-optymalności. W ten sposób każdemu z osobników x_i przyporządkowuje się wektor rang $r(x_i) = [r_1(x_i) \quad r_2(x_i) \quad \dots \quad r_s(x_i)]^T$, w którym $r_j(x_i)$ ($j = 1, 2, \dots, s$) reprezentuje rangę osobnika x_i w ramach j -tego subkryterium (wariantu X_j). Przypisanie konkretnego rodzajnika osobnikom realizowane jest poprzez ich preselekcję [2, 4-6]

$$\varphi_i = \max_{j=1,2,\dots,s} \varphi_i^j, \quad l_i = \arg \max_{j=1,2,\dots,s} \varphi_i^j \quad (2)$$

z zastosowaniem względnej rangi $\varphi_i^j = r_j(x_i) / r_{j_{\max}}$

oraz $r_{j_{\max}} = \max_{i=1,2,\dots,N} \{r_j(x_i)\}$. Dzięki takiej normalizacji, φ_i stanowi najwyższy (rozmyty) stopień suboptymalności, tj. przynależności i -tego osobnika do l_i -tego wariantu genetycznego, zaś $r_{j_{\max}}$ oznacza maksymalną rangę, jaką osiągają wszystkie rozwiązania względem j -tego subkryterium (X_j).

Subkryterialne populacje (warianty) są monitorowane pod względem założonej minimalnej liczby osobników. Brakujące pozycje są uzupełniane osobnikami nie(sub)optymalnymi, pochodzącymi z najniższych frontów Pareto, które były wstępnie przypisane innym wariantom.

Przyjmuje się, że tylko osobniki różnoimienne (o odmiennym wariacie) tworzą pary biorące udział w generowaniu potomków poprzez proces krzyżowania. Procedura selekcji osobników do suboptymalnych (wariantowych, rodzajnikowych) pul rodzicielskich jest przeprowadzana na przykład metodą stochastycznego doboru resztowego [7, 9] na podstawie stopnia przynależności φ_i (efektywnej suboptymalności).

3. NISZOWANIE

Mechanizm niszczenia polega na modyfikacji wektora stopnia przystosowania lub skalarną rangi (wyznaczonej wg Pareto-optymalności) każdego osobnika znajdującego się we ‘własnej’ niszy stosownie do następującego przepisu [1, 7, 9]

$$\tilde{\psi}(x_i) = \psi(x_i) / \sum_{j=1}^N \delta_{ij}, \quad (4)$$

gdzie $\psi(x_i)$ jest wektorem stopnia przystosowania lub skalarną rangę i -tego osobnika, natomiast $\tilde{\psi}(x_i)$ oznacza jego niszczo-uwarunkowany odpowiednio wektor stopnia przystosowania lub skalarną rangę. Natomiast δ_{ij} reprezentuje funkcję bliskości dwu osobników $x_i, x_j \in \mathbb{R}^n$ definiowaną następująco:

$$\delta_{ij} = \begin{cases} 1 - \|x_i - x_j\|_p, & 0 \leq \|x_i - x_j\|_p < 1, \\ 0, & \|x_i - x_j\|_p \geq 1 \end{cases} \quad (5)$$


gdzie $\|x\|_p = \sqrt{x^T [\text{diag}\{\Delta_1^2 / 4\varepsilon^2, \dots, \Delta_k^2 / 4\varepsilon^2\}]^{-1} x}$, zaś Δ_k reprezentuje niezerowy zakres poszukiwań k -tego poszukiwanego parametru, ε oznacza liczbę części na jaką jest podzielony ten zakres poszukiwań, zaś Δ_k / ε wyraża k -ta średnica hiperelipsoidy o środku w i -tym osobniku. Funkcja bliskości przyjmuje wartości z przedziału $[0, 1]$. Wartość zerowa funkcji bliskości oznacza, że osobniki nie są (‘geometrycznie’) spokrewnione, tj. nie należą do tego samego gatunku, z kolei wartość 1 oznacza najbliższe pokrewieństwo (identyczność).

Metody niszczenia mogą dotyczyć modyfikacji przystosowania lub rang osobników całej populacji lub tylko puli rodzicielskiej (NF, NR, NFP, NRP). Natomiast ze względu na czas trwania podczas

cyklu genetycznego rozważyć można niszowanie *ciągłe* (tj. stosowane we wszystkich generacjach) lub *okresowe* (stosowane w wybranych pokoleniach [8]). Niszowanie poprzez odpowiednią modyfikację przystosowania lub rang osobników pozwala zwiększyć szansę znalezienia się w następnym pokoleniu potomków z materiałem genetycznym gatunków z rzadkich populacyjnie nisz oraz zmniejszyć ową szansę dla gatunków z gęstych nisz. W ten sposób skonstruowany algorytm ewolucyjny zabezpiecza przed zjawiskiem przedwczesnej zbieżności.

4. OPTIMALNA SYNTEZA OBSERWATORA

Zadanie syntezy obserwatora detekcyjnego służącego generowaniu residuów w systemie detekcji i izolacji (FDI) [7, 10] przedstawiono na rys. 1.



Rys. 1. Zadanie syntezy generatora residuów

Problem wielokryterialnej optymalizacji generatora resztowego można przedstawić następująco:

$$\underset{(K,Q)}{\text{opt}} \begin{bmatrix} J_1(K,Q) \\ J_2(K,Q) \\ J_3(K,Q) \\ J_4(K,Q) \\ J_5(K) \\ J_6(K) \end{bmatrix} = \begin{bmatrix} \max_{(K,Q)} \|W_1(s) \cdot G_{rf}(s)\|_{\infty} \\ \min_{(K,Q)} \|W_2(s) \cdot G_{rd}(s)\|_{\infty} \\ \min_{(K,Q)} \|W_3(s) \cdot G_{rv}(s)\|_{\infty} \\ \min_{(K,Q)} \|W_4(s) \cdot G_{rv}(s)\|_{\infty} \\ \min_K \|A_0^{-1} K\|_s \\ \min_K \|A_0^{-1}\|_s \end{bmatrix} \quad (5)$$

gdzie $G_{rf}(s) = Q\{C[sI_n - A_0]^{-1}(F_1 - KF_2) + F_2\}$, $G_{rd}(s) = QC[sI_n - A_0]^{-1}N$, $G_{rv}(s) = QC[sI_n - A_0]^{-1}$, $G_{rv}(s) = Q\{I_m - C[sI_n - A_0]^{-1}K\}$, $A_0 = A - KC$, $\|M(s)\|_{\infty} = \sup_{\omega} \bar{\sigma}[M(j\omega)]$, $\|M\|_s = \bar{\sigma}[M]$, zaś $\bar{\sigma}[M]$ jest maksymalną wartością szczególną macierzy M , a $W_1(s)$, $W_2(s)$, $W_3(s)$, $W_4(s)$ to macierzowe funkcje wazące znaczenie poszczególnych częstotliwości.

Problem wielokryterialnej optymalizacji łatwo można wyrazić jako zadanie optymalizacji wartości własnych $\{\lambda_i\}$ macierzy A_0 . Ustalając macierze Q oraz $W_1(s)$, $W_2(s)$, $W_3(s)$, $W_4(s)$ uzyskujemy

zadanie optymalizacji, w którym wyznacza się jedynie macierz K dla poszukiwanego spektrum macierzy tranzyjacji stanu obserwatora A_0 .


Optymalnej syntezy obserwatorów dla rozważonych, przykładowych obiektów dokonano stosując *ciągłe* i *okresowe* niszowanie czterech rodzajów (NF, NR, NFP, NRP) oraz rodzajnikowanie (GGA) oraz klasyczny algorytm GA (pozbawiony obu modyfikacji). W algorytmie GGA wektor (5) został podzielony na trzy rodzajniki reprezentujące trzy podzbiory częściowych funkcji kryterialnych. Pierwszy rodzajnik $X1$ oznacza kryterium jakościowe ($J_1 = [J_1]^T$ – wpływ uszkodzeń na residuum), drugi wariant genetyczny ($X2$) obejmuje dwa niewrażliwościowe kryteria (oddziaływanie zakłóceń i szumów – $J_2 = [J_2 \ J_4]^T$), natomiast trzeci rodzajnik ($X3$) opisuje dwie odpornościowe miary (wpływ statycznych odchyłek od nominalnego modelu obiektu – $J_3 = [J_5 \ J_6]^T$).

Ewolucyjna optymalizacja obserwatorów została przeprowadzona dla następujących parametrów GA:

- 60 osobników w populacji ($N = 60$)
- genotyp osobnika złożony ze 160 bitów (32 bity na poszczególne parametry)
- krzyżowanie z prawdopodobieństwem $p_c = 0.8$
- mutacja z prawdopodobieństwem $p_m = 0.02$
- k -ta średnica niszy $\phi_k = \Delta_k / 3$
- strategia podstawienia – z pełną reprodukcją (oznaczająca brak elitarności).

4.1. System sterowania bezzałogowym samolotem

Pierwszym obiektem, dla którego przeprowadzono zadanie syntezy detekcyjnego obserwatora, jest system sterowania bezzałogowym samolotem [2, 10].



Rys. 2. Schemat samolotu i jego lotnicze parametry

Na rys. 2 przedstawiono parametry lotnicze takiego obiektu. Należy tu wyróżnić następujący wektor stanu $x = [\alpha \ \beta \ \rho \ \phi \ \psi]^T$, gdzie ϕ jest kątem przechylenia wokół osi x , ψ jest kątem pochylenia wokół osi y natomiast, ζ jest kątem kierunkowym wokół osi z , α oznacza ślizg, β reprezentuje szybkość przechylenia, ρ jest szybkością obrót samolotu w locie dookoła jego osi

pionowej z. Z elementami wykonawczymi obiektu związane są 2 zmienne sterujące $u = [\tau \ \theta]^T$: położenie τ steru pionowego oraz kąt θ wychylenia lotki.

Zlinearyzowany model tego obiektu [2] reprezentują następujące macierze opisu stanowego:

$$A = \begin{bmatrix} -0.277 & 0 & -32.9 & 9.81 & 0 \\ -0.1033 & -8.525 & 3.75 & 0 & 0 \\ 0.3649 & 0 & -0.639 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}, \quad N = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix},$$

$$B = \begin{bmatrix} -5.432 & 0 \\ 0 & -28.64 \\ -9.49 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \quad C = \begin{bmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \quad D = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}.$$

W analizowanym przykładzie zakłada się, że uszkodzenie dotyczy toru sterującego, co oznacza, że w modelu $F_1 = B$ oraz $F_2 = D$. Sygnał zakłócający $d(t)$ i szum wejściowy $w(t)$ są nierozróżnialne, a zatem modelowane są łącznie jako sygnał $d(t)$. W wektorze funkcji celu (5) nie występuje wówczas współrzędna J_3 , a poszukiwanie P-optymalnych obserwatorów ogranicza się do pięciu kryteriów.


Na rys. 3 przedstawiono porównanie uśrednionych wyników optymalizacji genetycznej z zastosowaniem okresowego niszowania w czterech rodzajach (NF, NR, NFP, NRP) oraz rezultaty uzyskane poprzez obliczenia ewolucyjne oparte na wariacie genetycznym osobnika (GGA) i na klasycznym schemacie GA, pozbawionym obu modyfikacji. Osiągnięte dane zostały opracowane statystycznie. Wszystkie algorytmy były inicjalizowane z jednakową populacją początkową.

Do dalszych badań symulacyjnych wybrano przykładowe rozwiązania o największym globalnym poziomie optymalności (GOL) [4]. Wskaźnik ten określa, w jakim stopniu/procencie spełniono wszystkie kryteria (względem ich osiągalnych wartości).


Przyjęto, iż usterka modelowana jest na pierwszej współrzędnej wektora $d(t)$ sygnału zakłócającego, o kształcie „esicy”, który po czasie 8 sekund zaczyna wolno narastać do wartości 0.05.

Jak widać na rys. 4, odpowiednie dwie współrzędne (r_1, r_3) detekcyjnego/residualnego wektora $r(t)$ wykazują istotne zmiany, analogiczne do sygnału usterki. Owe zaobserwowane reszty mogą posłużyć jako sygnały niosące użyteczną informację o usterekach (symptomach) dla układu diagnostycznego. Ostateczna detekcja usterek może być osiągnięta na przykład po zastosowaniu odpowiedniej procedury filtracyjno-progowej

(uwagę skupiono tu wyłącznie na zadaniu projektowania odpornego obserwatora).



Rys. 3. Uśrednione (po 20 symulacjach) przebiegi: średniego globalnego poziomu optymalności



Rys. 4. Obserwowane sygnały residualne

4.2. Okrętowy system napędowy

Rozważmy stanowy opis systemu napędowego [3]:

$$\dot{x}(t) = Ax(t) + Bu(t) + Nd(t) + F_1 f(t) + w(t) \quad (6)$$

$$y(t) = Cx(t) + F_2 f(t) + v(t) \quad (7)$$


gdzie $x = [\theta \ n \ v \ Q_{eng}]^T$ jest wektorem stanu, w którym występuje θ kąt natarcia śruby (względem kierunku obrotów), n prędkość obrotowa wału, v prędkość okrętu, oraz Q_{eng} moment obrotowy silnika (Diesla), $u = [\theta_{ref} \ Y]^T$ oznacza sterowanie, które zawiera wartość zadaną kąta natarcia θ_{ref} oraz wtrysk paliwa Y ; $f = [\Delta\theta \ \Delta\dot{\theta} \ \Delta n]^T$ reprezentuje addytywne usterki, obejmującym błąd pomiaru kąta natarcia $\Delta\theta$, wyciek hydrauliczny $\Delta\dot{\theta}$ (wolny dryft kąta natarcia), oraz błąd pomiaru prędkości obrotowej Δn , $d = [Q_f \ T_{ext}]^T$ jest zakłóceniem, opisującym moment tarcia Q_f oraz zewnętrzną siłę (wpływ wiatru i fal T_{ext}), $y = [\theta_m \ n_m \ v_m]^T$ oznacza pomiary, zaś $w, v \in \mathcal{R}^3$ są odpowiednio szumami wejściowymi i pomiarowymi.

Obecność uszkodzeń w rozważanym obiekcie związana jest z czujnikiem kąta natarcia płata śruby (liniowy potencjometr), czujnikiem prędkości obrotowej wału napędowego (tachoprądnica) oraz z silnikiem napędowym [4]. Czujnik kąta natarcia

płata śruby θ może sygnalizować uszkodzenie w przypadku generowania zbyt niskiego lub dużego sygnału (z odchyłką ujemną $\Delta\theta_{low}$ lub dodatnią $\Delta\theta_{high}$) z powodu zerwanego połączenia, zwarcia lub zablokowania wału napędowego przy najmniejszym lub przy największym kącie natarcia. Innego rodzaju uszkodzeniem pośrednio związanym z tym czujnikiem jest wyciek płynu z instalacji hydraulicznej, który będzie powodować powolną zmianę kąta natarcia płata ($\Delta\dot{\theta}$).

Tachoprądnica może mieć uszkodzenia generowanie (przez zakłócenie elektromagnetyczne) maksymalnego sygnału (Δn_{max}) lub minimalnego sygnału (Δn_{min}) z powodu zaniku sygnałów w przetwornicy.


Wystąpienie powyższych uszkodzeń może mieć poważne konsekwencje. Skutkiem uszkodzenia $\Delta\theta_{high}$ może być zmniejszenie prędkości okrętu, co podnosi ryzyko w manewrowaniu, wywołuje opóźnioną reakcję okrętu lub zwiększenie kosztów eksploatacji. Odwrotny skutek ma uszkodzenie $\Delta\theta_{low}$, które może spowodować zwiększenie prędkości okrętu, co również może grozić kolizją. Uszkodzenie Δn_{max} wywołuje zmniejszenie prędkości statku, które jest źródłem opóźnienia reakcji okrętu w czasie manewrowania lub zwiększenie kosztów eksploatacji. Z kolei skutkiem uszkodzenia Δn_{min} jest niezamierzone przyspieszenie okrętu, które może również spowodować kolizję.




Rys. 5. Usrednione przebiegi sredniego indeksu GOL

Na rys. 5 przedstawiono porównanie usrednionych (po 20 symulacjach) wyników z zastosowaniem ciągłego niszowania w czterech rodzajach (NF, NR, NFP, NRP) oraz uzyskane poprzez algorytm GGA i klasycznym algorytmem GA (pozbawionym obu modyfikacji).

Sekwencję występowania możliwych addytywnych usterek [4] przedstawiono na Rys. 6. Uzyskane sygnały residualne ($r_\theta = \theta - \hat{\theta}$, $r_n = n - \hat{n}$ i $r_v = v - \hat{v}$) przedstawione na rys. 7, wykazują zmiany analogiczne do sygnałów uszkodzeń.



Rys. 6. Usterki występujące w obiekcie



Rys. 7. Residua rozwiązań: (a) jakościowego, (b) niewrażliwościowego i (c) odpornościowego na tle wyników klasycznego GA.

Rezultaty symulacji działania uzyskanych obserwatorów detekcyjnych zaprojektowanych według podejścia rodzajnikowego (GGA) przedstawia rys. 7. Trzy rozwiązania, każde o innym rodzaju porównano z osobnikiem uzyskanym wg algorytmu GA. Jak można zauważyć, obserwator stanu o jakościowym rodzaju prezentuje wyższą zdolność wykrywania usterek niż pozostałe obserwatory stanu, zaś wszystkie rozwiązania rodzajnikowe są bardziej skuteczne niż rozwiązanie optymalne uzyskane przez klasyczny GA.

5. WNIOSKI

Przedstawione metody rozwiązywania zadań wielokryterialnej optymalizacji oparte są na obliczeniach ewolucyjnych. Szczególną praktyczną wartość przedstawia metoda rozpoznawania wariantu genetycznego (suboptymalności) w każdym cyklu obliczeniowym. Informacja o stopniu przynależności do danego wariantu wydobywana jest poprzez odpowiedni ranking P-optymalnych rozwiązań. Informacja ta jest wykorzystywana przy krzyżowaniu, w którym kojarzone są tylko osobniki o odmiennym wariancie.

Olbrzymi sukces podejścia rodzajnikowego może być przypisany faktowi uporania się z dużą liczbą kryteriów poprzez redukcję wymiarowości analizowanej Pareto przestrzeni. Zaobserwować można, że w przypadku pełnego zakresu optymalizacji, z powodu wysokiego wymiaru przestrzeni kryteriów, liczba frontów Pareto jest mocno ograniczona. Oznacza to, że duża liczba osobników jest klasyfikowana jako równorzędne z punktu widzenia Pareto-optymalności (tzn. posiadają tę samą rangę). W wyniku tego, proces selekcji osobników jest nieefektywny i poszukiwania ewolucyjne są zbyt stochastyczne bez oznak postępu w jakimś szczególnym kierunku reprezentowanym przez zadane kryteria. Istotną cechą proponowanej metody jest sposób wykorzystania Pareto-optymalizacji. Dla każdego podzbioru kryterialnego, wiążanego z rodzajnikiem genetycznym, przeprowadzany jest P-optymalny ranking, będący narzędziem suboptymalnej oceny (jednoimiennej, wewnętrznej rywalizacji). Pozwala ona na selekcję rozwiązań do pul rodzicielskich w każdym ewolucyjnym cyklu. Oznacza to: (a) nowy mechanizm preselekcji osobników oraz (b) wzajemną skuteczną między-wariantową wymianę materiału genetycznego podczas krzyżowania. Ponadto w opozycji do tradycyjnego podejścia: (1) uzyskane fronty Pareto są bardziej regularne i jest ich więcej, (2) zachowuje się różnorodność rozwiązań, a projektant uzyskuje (3) możliwość łatwego formułowania subkryteriów oraz (4) jasne przesłanki co do końcowego rozstrzygnięcia.

Algorytm genetyczny z mechanizmem niszowania umożliwia efektywną eksplorację

obszaru poszukiwań poprzez dbanie o różnorodność kolejnych generacji. W przypadku nadmiernego niszowania (rang), zaburzenie optymalnego doboru może osłabić szybkość zbieżności. Kiedy rozważane kryteria nie są zbyt złożone zastosowanie niszowania może być nieefektywne.

SPIS ZASTOSOWANYCH SKRÓTÓW

- EC – obliczenia ewolucyjne (ang. *Evolutionary Computation*).
- GA – algorytm genetyczny (ang. *Genetic Algorithm*)
- GGA – algorytm GA z rodzajnikiem genetycznym (ang. *Genetic Gender Algorithm*).
- GOL – globalny poziom optymalności (ang. *Global Optimality Level*).
- NF – mechanizm niszowania przystosowania (ang. *Niching of Fitness*).
- NFP – mechanizm niszowania przystosowania puli rodzicielskiej (ang. *Niching of Fitness of Parents*).
- NR – mechanizm niszowania rang (ang. *Niching of Ranks*).
- NRP – mechanizm niszowania rang puli rodzicielskiej (ang. *Niching of Ranks of Parents*).

LITERATURA

- [1] Goldberg D. E.: *Genetic Algorithms in Search, Optimisation and Machine Learning*. Addison-Wesley, Reading 1989.
- [2] Chen J., Patton R. J., Liu G.: *Optimal residual design for fault diagnosis using multi-objective optimisation and genetic algorithms*, International Journal of Systems Science, 1996, vol. 27, pp. 567-576.
- [3] Kowalczyk Z., Białaszewski T.: *Evolutionary multi-objective optimisation with genetic sex recognition*. 7th IEEE Intern. Conf. MMAR, Międzyzdroje, 2001, pp. 143-149.
- [4] Kowalczyk Z., Białaszewski T.: *Algorytmy genetyczne w wielokryterialnej optymalizacji obserwatorów detekcyjnych*. W: Diagnostyka Procesów: Modele, Metody Sztucznej Inteligencji, Zastosowania [Korbicz J., Kościelny J. M., Kowalczyk Z., Cholewa W. (Red.)], WNT, Warszawa 2002, ss. 465-511.
- [5] Kowalczyk Z., Białaszewski T.: *Multi-gender genetic optimization of diagnostic observers*, Proceedings of the IFAC Workshop Control Applications of Optimisation, 2003, Visegrad, Hungary, pp. 15-20.
- [6] Kowalczyk Z., Białaszewski T.: *Periodic and continuous niching in genetic optimization of detection observers*, Proc. of the 10th IEEE Int. Conf. MMAR, 2004, Międzyzdroje, Poland, vol. 1, pp. 781-786.



- [7] Kowalczyk Z., Białaszewski T.: *Improving evolutionary multi-objective optimisation by niching*. Int. J. Information Technology and Intelligent Computing, Vol. 1, no. 2, 2006.
- [8] Kowalczyk Z., Białaszewski T.: *Improving evolutionary multi-objective optimisation using genders*. Artificial Intelligence and Soft Computing. Lecture Notes in Artificial Intelligence, Vol. 4029, Springer-Verlag, Berlin, 2006, pp. 390-399.
- [9] Kowalczyk Z., Suchomski P., Białaszewski T.: *Evolutionary multiobjective Pareto optimisation of diagnostic state observers*. Int. J. Applied Math. and Computer Science, 1999, vol. 9, no. 3, pp. 689-709.
- [10] Patton R. J., Frank P. M., Clark R. N.: *Fault Diagnosis in Dynamic Systems, Theory and Application*. In: Control Engineering Series, Prentice Hall, New York 1989.
- [11] Man K. S., Tang K. S., Kwong S., Lang W. H.: *Genetic algorithms for control and signal processing*. Springer-Verlag, London 1997.
- [12] Michalewicz Z.: *Genetic Algorithms + Data Structures=Evolution Programms*. Springer-Verlag, New York 1996.