

EWOLUCYJNA OPTYMALIZACJA WIELOKRYTERIALNA W AUTOMATYCE I DIAGNOSTYCE

Rozważa się problem optymalizacji wielokryterialnej. Zadania tego rodzaju mogą być skutecznie rozwiązywane za pomocą metod ewolucyjnych z zastosowaniem wprowadzonego ostatnio pojęcia genetycznego rodzajnika, wywodzonego ze stopnia przystosowania analizowanych osobników (rozwiązań) i stosowanego podczas krzyżowania w procesie wielokryterialnej optymalizacji. Omawia się mechanizm genetyczny, a jego działanie ilustruje przykładami wielokryterialnej syntezy układów automatyki.

EVOLUTIONARY MULTI-OBJECTIVE OPTIMIZATION IN AUTOMATIC CONTROL AND DIAGNOSTICS

Abstract. The tasks of multi-objective optimization are considered. Such problems can be efficiently solved by means of evolutionary methods with the use of a newly introduced notion of a genetic gender extracted from the fitness of individuals and applied during the parental crossovers in a multi-objective optimization process. Characteristics of this mechanism are discussed and its performance in exemplary multi-objective controller and state-observer syntheses is illustrated.

1. WPROWADZENIE

W inżynierii systemów coraz częściej wykorzystywane są algorytmy ewolucyjne, które naśladują sposób ewolucji systemów biologicznych. Podobnie jak w przyrodzie, również systemy techniczne powinny odznaczać się odpowiednimi cechami w zakresie optymalności, odporności i adaptacyjności. Nietrudno jest przy tym formułować odpowiednie zadania dotyczące optymalności rozwiązania, odporności na zakłócenia i zmiany parametrów oraz niedokładności modelowania, projektowania i realizacji, które prowadzą do bardziej skutecznego i niezawodnego działania konstruowanych układów. W takim projektowaniu często pojawia się jednak konieczność łącznej optymalizacji wielu cząstkowych kryteriów, między którymi trudno jest określić wzajemne zależności. Tego rodzaju problemy stanowią zadania optymalizacji wielokryterialnej [1, 10, 11].

Do rozwiązywania problemów wielokryterialnych stosuje się metodę ważonych zysków [11], metodę odległości [11], metodę sekwencyjnych ograniczeń nierównościowych

[12] lub metodę rankingu według Pareto-ptymalności [10, 3, 4, 6]. Pierwsze dwie metody zasadzają się na integracji wielu kryteriów w jedno. Wówczas zadanie wielokryterialnej optymalizacji wektorowej funkcji zysku sprowadza się do optymalizacji pewnej skalarnej funkcji celu. W metodzie ważonych zysków współrzędne wektora funkcji celów są agregowane w pojedynczą funkcję zysku za pomocą unormowanego wektora wag. Natomiast metoda odległości polega na wyznaczeniu normy różnicy pomiędzy wektorem funkcji celów a wektorem popytu. Metoda sekwencyjnych ograniczeń nierównościowych polega na przekształceniu zadania wielokryterialnej optymalizacji wektorowej funkcji celu na zbiór zadań optymalizacji skalarnych funkcji celu z ograniczeniami nierównościowymi. Powyższe metody są proste w zastosowaniu. Posiadają jednak istotną wadę, która tkwi w konieczności arbitralnego doboru wag, wektora popytu czy też numerycznych ograniczeń na wartość poszczególnych funkcji celu. Uzyskane w wyniku takiej optymalizacji rozwiązania obowiązują tylko dla wybranego sposobu parametryzacji (wektora wag, wektora popytu lub zbioru ograniczeń). Jest to oczywisty skutek wprowadzania upraszczania zadań wielokryterialnej optymalizacji. Ponadto dwie pierwsze z wymienionych metod (ważona i popytowa) opierają się na integracji wielu kryteriów w jedno, co zmusza projektanta do podejmowania nie zwykle trudnego i odpowiedzialnego zagadnienia, polegającego na decydowaniu o wzajemnych zależnościach pomiędzy kryteriami cząstkowymi.

Odmienne podejście stosowane jest w metodzie rankingu z zastosowaniem pojęcia Pareto-ptymalności, która pozwala klasyfikować uzyskane rozwiązania zadania wielokryterialnej maksymalizacji jako rozwiązania zdominowane lub niezdominowane (Pareto-ptymalne lub w skrócie P-ptymalne) [1, 11]. Ocena według Pareto-ptymalności nie tylko wyznacza zbiór P-ptymalnych rozwiązań, ale również pozwala na uszeregowanie wszystkich możliwych rozwiązań pod względem stopnia zdominowania. Jednak odwzorowanie to selekcjonuje raczej zbiory Pareto-ptymalnych rozwiązań i nie wskazując na żadne konkretne (pojedyncze) rozwiązanie. Jest to cena jaką płaci się za równoważne traktowanie poszczególnych kryteriów składowych wektorowej funkcji zysku. Oczywiście projektant zawsze może wprowadzić dodatkową ocenę uzyskanych P-ptymalnych rozwiązań.

W algorytmach genetycznych (bądź ewolucyjnych) implementować można wszelkiego rodzaju mechanizmy generowania nowych generacji rozwiązań i podejmowania decyzji. W niniejszej prezentacji skupimy się na przedstawieniu nowego podejścia do rozwiązywania zadań wielokryterialnej optymalizacji opartego na algorytmach ewolucyjnych, w których każdemu rozwiązaniu przyporządkowana jest dodatkowa informacja o stopniu jego przynależności do ustalonego podzbioru kryteriów, sygnowanego określonym rodzajnikiem genetycznym (atrybutem płci lub wariantu; X_j , $j=1,2,\dots$), który jest elementem dopuszczalnego zbioru rodzajników [7-9], na przykład: $GEND=\{XX, XY\}$.

Koncepcja wariantu genetycznego zasadza się zatem na podziale zbioru funkcji celów na podzbiory. Podział ten jest związany z charakterem rozważanych celów (np. cele jakościowe i odpornościowe). Realizowana w ten sposób suboptymalizacja wykorzystywana jest w procesie prokreacji (kojarzenia i krzyżowania rozwiązań), w którym tylko rozwiązania o różnym wariantcie genetycznym mogą tworzyć pary rodzicielskie generujące nowe rozwiązania.

Ilustrację rozważanego podejścia stanowią przykłady wielokryterialnej syntezy układów regulacji i diagnostyki, a uzyskane wyniki potwierdzają potencjalną skuteczność propo-

nowanej metody optymalizacji, która pozwala na przykład na uzyskiwanie systemów zarówno o dużej odporności, jak i o wysokiej jakości.

2. OPTYMALIZACJA WIELOKRYTERIALNA

Pojawiająca się konieczność łącznej optymalizacji wielu cząstkowych kryteriów prowadzi do formułowania zadań optymalizacji wielokryterialnej.

2.2. Zadanie wielokryterialnej optymalizacji

Załóżmy, że dany jest n -wymiarowy wektor $f(x) \in \mathfrak{R}^m$ funkcji celów

$$f(x) = [f_1(x) \quad f_2(x) \quad \dots \quad f_m(x)]^T \quad (1)$$

gdzie

$$x = [x_1 \quad x_2 \quad \dots \quad x_n]^T \in \mathfrak{R}^n \quad (2)$$

oznacza m -wymiarowy wektor poszukiwanych parametrów, zaś $f_j(x)$; $j = 1, 2, \dots, m$ są cząstkowymi celami.

Załóżmy, że współrzędne wektora kryterialnego (1) są funkcjami zysku. Problem optymalizacji wielokryterialnej definiowany wówczas może być jako zadanie wielokryterialnej maksymalizacji (bez ograniczeń) wektora zysków

$$\max_x f(x) \quad (3)$$

Rozwiązanie (osobnik) w algorytmie genetycznym opisane jest następującym wektorem

$$x_i = [x_{i_1} \quad x_{i_2} \quad \dots \quad x_{i_n}]^T \in \mathfrak{R}^n \quad (4)$$

którego współrzędna x_{i_k} ; $i = 1, 2, \dots, N$, $k = 1, 2, \dots, n$, oznacza k -ty parametr poszukiwanego i -tego osobnika, zaś N reprezentuje liczbę osobników w populacji

$$X = [x_1 \quad x_2 \quad \dots \quad x_N] \quad (5)$$

2.3. Pareto-optymalność

Warunek optymalności w sensie Pareto dla zadania maksymalizacji (3) może być sformułowany następująco. Niech $f(x_p), f(x_r) \in \mathfrak{R}^m$, gdzie x_p i x_r reprezentują dwa osobniki (rozwiązania). Wektor $f(x_p)$ jest częściowo mniejszy od wektora $f(x_r)$ wtedy i tylko wtedy, gdy dla wszystkich współrzędnych zachodzi warunek [1, 10, 11]

$$\left(\bigvee_j f_j(x_p) \leq f_j(x_r) \right) \wedge \left(\exists_j f_j(x_p) < f_j(x_r) \right) \quad (6)$$

Rozwiązanie x_p jest zdominowane w sensie Pareto, jeżeli istnieje takie rozwiązanie

x_r , którego wektor funkcji zysku $f(x_r)$ jest częściowo większy niż $f(x_p)$. Rozwiązanie x_r , które nie jest zdominowane, nazywa się rozwiązaniem *niezdominowanym* lub *Pareto-optymalnym* (*P-optymalnym*).

2.4. Ranking względem P-optymalności

Ustalanie rangi osobników (rozwiązań) względem P-optymalności służy ocenie osobników: Każdemu rozwiązaniu można przyporządkować pewną skalarną wielkość zwaną rangą [10]. Owa ranga odpowiada liczności zbioru rozwiązań, przez które dane rozwiązanie jest zdominowane w sensie Pareto. Stąd ranga $r(x_i)$ danego rozwiązania x_i to:

$$r(x_i) = \mu_{\max} - \mu(x_i) + 1, \quad \mu_{\max} = \max_{i=1,2,\dots,N} \mu(x_i) \quad (7)$$

gdzie $\mu(x_i)$ jest stopniem zdominowania, tzn. liczbą rozwiązań dominujących nad x_i , zaś μ_{\max} stanowi maksymalną wartość spośród wszystkich $\mu(x_i)$.

3. WARIANT GENETYCZNY OSOBNIKÓW

W naturze podział osobników ze względu na płeć wiąże się nie tylko z ich funkcjami rozrodczymi (jako podstawowy wyróżnik), ale również (zwłaszcza w zaadaptowanych do życia we wspólnocie grupach) kojarzy się z ich funkcjonalną przydatnością do życia w danej społeczności. Zgodnie z tą obserwacją, proponowana idea genetycznego wariantu (GVAR) zasada się na podziale zbioru funkcji celów na kilka rozłącznych podzbiorów, którym przypisywana może być określona nazwa (wspólny atrybut / rodzajnik genetyczny; X_j) będąca elementem zbioru GEND [7-9]. Podział ten jest związany z charakterem rozważanych celów. Do ustalonego podzbioru / wariantu (X_j) mogą należeć kryteria o 'jednoimiennych' cechach, które są jedynie w stanie 'wewnętrznej' rywalizacji (dla projektanta natomiast mają one w przybliżeniu jednakowe znaczenie). Taki zbiorczy sposób kwalifikacji zwalnia projektanta z trudnego zadania wyodrębnienia pojedynczego rozwiązania spośród wielu (P-optymalnych) rozwiązań.

Natomiast zbiór rodzajników (wariantów) 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 rozwiązań najlepszym sposobem jest wówczas koncepcja P-optymalności.

W podejściu GVAR stosuje się mechanizm przydziału rodzajnika podczas całego ewolucyjnego cyklu w celu tworzenia nowych rozwiązań, ale tylko z osobników rodzicielskich o różnych wariantach / rodzajnikach (X_j). Wektor funkcji zysku (1) może być zatem podzielony na s podwektorów:

$$f(x) = [f_1(x) \quad f_2(x) \quad \dots \quad f_s(x)]^T \quad (8)$$

gdzie

$$f_j(x)^T \in \mathfrak{R}^{m_j}, \quad m = \sum_{i=1}^s m_i \quad (9)$$

oznacza j -ty podwektor ($j=1,2,\dots,s$) definiujący podzbiór cech (jako wariant lub rodzajnik genetyczny X_j). W zakresie wszystkich elementów tego podzbioru ustala się rangę osobników opartą Pareto- optymalności. Zatem każdemu z osobników x_i przyporządkowuje się wektor rang:

$$r(x_i) = [r_1(x_i) \quad r_2(x_i) \quad \dots \quad r_s(x_i)]^T \quad (10)$$

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 (sub-optymalizację) [7-9]:

$$\begin{aligned} \varphi_i &= \max_{j=1,2,\dots,s} \varphi_i^j \\ l_i &= \arg \max_{j=1,2,\dots,s} \varphi_i^j \end{aligned} \quad (11)$$

gdzie względna ranga

$$\varphi_i^j = \frac{r_j(x_i)}{r_{j_{\max}}}, \quad r_{j_{\max}} = \max_{i=1,2,\dots,N} \{r_j(x_i)\} \quad (12)$$

Dzięki zastosowanej normalizacji, φ_i stanowi najwyższy (rozmyty) stopień suboptymalności, tj. przynależności i -tego osobnika do l_i -tego (optymalnego dla niego) wariantu genetycznego, zaś $r_{j_{\max}}$ oznacza maksymalną rangę jaką osiągają wszystkie rozwiązania względem j -tego subkryterium (X_j).

Populacje wariantowe (subkryterialne) są monitorowane pod względem założonej minimalnej liczby osobników (np. $N/(3s)$). Brakujące pozycje są uzupełniane osobnikami niesuboptymalnymi, pochodzącymi z najniższych frontów Pareto, które były wstępnie przypisane innym wariantom.

Należy podkreślić, iż 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 metodą stochastycznego doboru resztowego [3, 4] na podstawie (efektywnego) stopnia przynależności (suboptymalności) φ_i .

3.1. Algorytm ewolucyjny EA-GVAR/GEND

Algorytm ewolucyjny z zastosowaniem wariantu / rodzajnika genetycznego streścić można następująco [7-9]:

Inicjacja N osobników w populacji X ;

Dopóki $t \leq t_{\max}$

Wyznaczenie przystosowania każdego osobnika;
 P-suboptymalny ranking (wg subkryteriów / wariantów);
 Rozpoznanie genetycznego wariantu / rodzajnika osobników;
 Selekcja suboptymalnych pul rodzicielskich;
 Tworzenie nowej populacji X' poprzez:
 - proces krzyżowania różnowariantowych osobników, oraz
 - mutację;
 Zastąpienie starej populacji nową ($X \leftarrow X'$);
 $t \leftarrow t+1$;

koniec.

4. SYNTEZA REGULATORA PID

Jako przykład zastosowania proponowanego podejścia, rozważmy zadanie wielokryterialnej optymalizacji regulatora PID. Taki regulator może być opisany w dziedzinie częstotliwości następująco

$$G_c(s) = K_p + \frac{1}{sT_i} + sT_d \quad (13)$$

Poszukiwanymi parametrami są K_p, T_i, T_d . Zatem

$$\mathbf{x} = [x_1 \quad x_2 \quad x_3]^T \in \mathfrak{R}^3 \quad (14)$$

oznacza wektor poszukiwanych parametrów regulatora PID ($x_1 = K_p, x_2 = T_i, x_3 = T_d$). Dla danego liniowego obiektu sterowania zadanie wielokryterialnej optymalizacji określone jest następującymi kryteriami:

$$IMSE = f_1(\mathbf{x}) = \int_0^{\infty} [\dot{e}(\mathbf{x}, t) + \lambda e(\mathbf{x}, t)]^2 dt \quad (15)$$

$$ITSE = f_2(\mathbf{x}) = \int_0^{\infty} t^2 e^2(\mathbf{x}, t) dt \quad (16)$$

$$ISC = f_3(\mathbf{x}) = \int_0^{\infty} u^2(\mathbf{x}, t) dt \quad (17)$$

$$g_m(\mathbf{x}) = f_4(\mathbf{x}) = \text{gain margin} \quad (18)$$

$$p_m(\mathbf{x}) = f_5(\mathbf{x}) = \text{phase margin} \quad (19)$$

Kryteria całkowite są wyznaczane poprzez rozwiązanie odpowiedniego równania Lapunowa. Powyższe funkcje kryterialne zostały podzielone na dwa podzbiory wariantowe, które są reprezentowane następująco:

$$\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \quad f_2(\mathbf{x})]^T \in \mathfrak{R}^5 \quad (20)$$

gdzie pierwsze z subkryteriów (XX='JAKOŚĆ') składa się z trzech jakościowych wskaźników całkowych

$$f_1(x) = [f_1(x) \quad f_2(x) \quad f_3(x)]^T \in \mathbb{R}^3 \quad (21)$$

zaś w skład drugiego suboptymalizowanego wektora (XY='ODPORNOSC') wchodzi dwa kryteria o cechach odpornościowych, tzn. zapas wzmocnienia i fazy

$$f_2(x) = [f_4(x) \quad f_5(x)]^T \in \mathbb{R}^2 \quad (22)$$

Do poszukiwania P-optymalnych parametrów regulatora PID zastosowano proponowaną ewolucyjną metodę, w której osobnik posiada następującą postać

$$x_i = [x_{1i} \quad x_{2i} \quad x_{3i}]^T \in \mathbb{R}^3 \quad (23)$$

W procesie ewolucji w każdej iteracji każdemu osobnikowi przypisuje się rodzajnik, który desygnuje jeden z dwu wariantów: jakościowy albo odpornościowy.

4.1. Przykład projektowy

Rozważmy nieminimalnofazowy liniowy obiekt

$$G_p(s) = \frac{(-0.5s+1)(s+4)}{s(s+2)(s^2+6s+10)} \quad (24)$$


Synteza regulatora PID sprowadza się do rozwiązania zadania wielokryterialnej optymalizacji wektora (14) ze względu na cząstkowe kryteria (15)-(19).

Przyjęto następujący obszar poszukiwań:

$$x_1 = K_p \in [0, 10], \quad x_2 = T_i \in [0, 3], \quad x_3 = T_d \in [0, 1] \quad (25)$$


4.2. Wyniki ewolucyjnej optymalizacji

Porównanie wyników podejścia klasycznego (GA) i wariantowego (GVAR) na płaszczyźnie jakościowej przedstawia rys. 1. Podobny efekt uzyskano w innych rozważanych podprzestrzeniach.



Rys. 1. Dwa typy rozwiązań optymalnych PID na płaszczyźnie jakościowej

Porównanie uzyskanych P-optymalnych regulatorów PID, będących suboptymalnymi jakościowo ('kółka') i odpornościowo ('trójkąty'), na tle wskaźników odpornościowych prezentuje rys. 2.




Rys. 2. P-optymalne rozwiązania na płaszczyźnie odpornościowej

Uzyskane wyniki pokazują, że prezentowane podejście z rozpoznawaniem genetycznego wariantu jest bardziej skuteczne niż globalna Pareto-optymalizacja.

4.3. Wyniki symulacji układów regulacji

Porównanie efektywności różnych regulatorów PID przedstawiono na rys. 3.



Rys. 3. Nominalna odpowiedź skokowa układów regulacji PID




Rys. 4. Odpowiedź układu sterowania w przypadku zaburzonych parametrów obiektu

Rys. 4 ilustruje stopień odporności rozważanych regulatorów PID w przypadku zaburzenia parametrów obiektu polegającym na zmianie ich wartości (multiplikatywnej względem nominalnych parametrów) z zastosowaniem równomiernego rozkładu losowego. Widać, że układy uzyskane na podstawie syntezy poprzez suboptymalizację (GV) posiadają naturalną odporność na odchyłki parametrów obiektu w porównaniu z pozostałymi regulatorami.

5. SYNTEZA OBSERWATORA DETEKCYJNEGO

Rozważmy zadanie syntezy obserwatora detekcyjnego służącego generowaniu residuów w systemie detekcji i izolacji (FDI) przedstawione na rys. 5.



Rys. 5. Zadanie syntezy generatora residuów

Postawmy problem wielokryterialnej optymalizacji generatora resztowego:

$$\underset{(K, Q)}{\text{opt}} J(K, Q) = \begin{cases} \max_{(K, Q)} J_1(K, Q) \\ \min_{(K, Q)} J_2(K, Q) \\ \min_{(K, Q)} J_3(K, Q) \\ \min_{(K, Q)} J_4(K, Q) \\ \min_K J_5(K) \\ \min_K J_6(K) \end{cases} \quad (26)$$

gdzie

$$\begin{aligned} J_1(K, Q) &= \|W_1(s) \cdot G_{rf}(s)\|_\infty, & J_2(K, Q) &= \|W_2(s) \cdot G_{rd}(s)\|_\infty \\ J_3(K, Q) &= \|W_3(s) \cdot G_{rw}(s)\|_\infty, & J_4(K, Q) &= \|W_4(s) \cdot G_{rv}(s)\|_\infty \\ J_5(K) &= \|(A - KC)^{-1} K\|_s, & J_6(K) &= \|(A - KC)^{-1}\|_s \end{aligned}$$

oraz

$$G_{rf}(s) = Q[C[sI_n - A_0]^{-1}(F_1 - KF_2) + F_2],$$

$$G_{rd}(s) = QC[sI_n - A_0]^{-1}N;$$

$$G_{rv}(s) = QC[sI_n - A_0]^{-1},$$

$$G_{rw}(s) = Q\{I_m - C[sI_n - A_0]^{-1}K\},$$

$$A_0 = A - KC.$$

natomiast $\|M(s)\|_\infty = \sup_\omega \bar{\sigma}[M(j\omega)]$, $\|M\|_s = \bar{\sigma}[M]$, 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 wiążące znaczenie poszczególnych częstotliwości.

Powyższy problem wielokryterialnej optymalizacji łatwo można wyrazić jako zadanie optymalizacji wartości własnych $\{\lambda_i\}$ macierzy $A_0 = A - KC$. Przyjmując Q jako macierz jednostkową i ustalając macierze wiążące $W_1(s)$, $W_2(s)$, $W_3(s)$, $W_4(s)$ uzyskujemy następujące zadanie optymalizacji, w którym wyznacza się macierz K dla poszukiwanego genetycznie spektrum macierzy (A_0) tranzycji stanu obserwatora:

$$\underset{(K,Q)}{\text{opt}} J(K,Q) = \underset{K}{\text{opt}} J(K) = \underset{\lambda}{\text{opt}} J(K(\lambda)) \quad (27)$$

W analizowanym zagadnieniu optymalizacji zastosujemy podział kryteriów na 3 warianty (rodzajniki) suboptymalności:

$$J(\lambda) = [J_1(\lambda) \quad J_2(\lambda) \quad J_3(\lambda)]^T \in \mathfrak{R}^6 \quad (28)$$

obejmujące:

- 'JAKOŚĆ' (X1) (wpływ usterek na residuum), $J_1(\lambda) = [J_1(\lambda)]^T \in \mathfrak{R}$;
- 'NIEWRAŻLIWOŚĆ' (X2) (wpływ zakłóceń oraz szumów wejściowych i pomiarowych), $J_2(\lambda) = [J_2(\lambda) \quad J_3(\lambda) \quad J_4(\lambda)]^T \in \mathfrak{R}^3$; oraz
- 'ODPORNOŚĆ' (X3) (wpływ odchyłek od nominalnego modelu obiektu), $J_3(\lambda) = [J_5(\lambda) \quad J_6(\lambda)]^T \in \mathfrak{R}^2$.

5.1. Przykład projektowy

Rozważmy stanowy model okrętowego systemu napędowego [2]:

$$\dot{x}(t) = Ax(t) + Bu(t) + Nd(t) + F_1 f(t) + w(t) \quad (29)$$

$$y(t) = Cx(t) + F_2 f(t) + v(t) \quad (30)$$

- z wektorem stanu $x = [\theta \quad n \quad v \quad Q_{eng}]^T$, w którym występuje θ kąt natarcia śruby (względem kierunku obrotów), n prędkość obrotowa wału, v prędkość okrętu, oraz Q_{eng} moment obrotowy silnika (diesela);
- wektorem sterowania $u = [\theta_{ref} \quad Y]^T$, który zawiera wartość zadana kąta natarcia θ_{ref} oraz wtrysk paliwa Y ;
- wektorem addytywnych usterek $f = [\Delta\theta \quad \Delta\dot{\theta} \quad \Delta n]^T$, obejmującym błąd pomiaru kąta natarcia $\Delta\theta$, wyciek hydrauliczny $\Delta\dot{\theta}$ (wolny dryft kąta natarcia), oraz błąd pomiaru prędkości obrotowej Δn ;
- wektorem zakłóceń $d = [Q_f \quad T_{ext}]^T$, opisującym moment tarcia Q_f oraz zewnętrzną siłę reprezentującą wpływ wiatru i fal T_{ext} ;
- wektorem pomiarów $y = [\theta_m \quad n_m \quad v_m]^T$; oraz
- wektorem szumów wejściowych i pomiarowych $w, v \in \mathfrak{R}^3$.

W rozważanym zadaniu przestrzeń poszukiwań parametrów (wartości własnych) reprezentuje 4-wymiarowy wektor (j -te rozwiązanie/osobnik)


$$\lambda_j = \begin{bmatrix} \lambda_j^1 \\ \lambda_j^2 \\ \lambda_j^3 \\ \lambda_j^4 \end{bmatrix} \in \mathfrak{R}^4 \quad (31)$$

który został zawężona do ograniczonej hiperkostki:


$$\lambda_j^1 \in [-30, -0.5], \quad \lambda_j^2 \in [-30, -0.5], \quad \lambda_j^3 \in [-100, -31], \quad \lambda_j^4 \in [-100, -31].$$

5.2. Wyniki ewolucyjnej optymalizacji

Przykład skuteczności wariantowej optymalizacji (GVAR) w przestrzeni jakościowej przedstawia rys. 6. W analizowanym przypadku, rezultaty podejścia klasycznego (GA) były bliskie rozwiązaniom nie-jakościowym (niewrażliwym i odpornym). Podobny efekt uzyskano w innych rozważanych podprzestrzeniach, co ilustruje również rys. 7.




Rys. 6. Rezultaty wariantowej P-optimizacji w kategoriach jakościowych



Rys. 7. Rezultaty wariantowej P-optimizacji na płaszczyźnie odpornościowej


Interesującym, a pokazanym na rys. 8, efektem zastosowania podejścia subkryterialnego (wariantowego) jest wyraźnie zwiększona (względem podejścia klasycznego) liczba frontów Pareto, która wyraża użyteczną – w ewolucyjnych poszukiwaniach ‘optimum’ – różnorodność rozwiązań.




Rys. 8. Liczba frontów Pareto w trakcie ewolucji

5.3. Wyniki symulacji układów detekcji

Dla założonej sekwencji usterek z rys. 9, przebieg detekcji ilustruje rys. 10.



Rys. 9. Sekwencja usterek w systemie napędowym okrętu



Rys. 10. Przebiegi sygnałów resztowych w dwu generatorach FDI

6. PODSUMOWANIE

Przedstawiona metoda rozwiązywania zadań wielokryterialnej optymalizacji oparta jest na obliczeniach ewolucyjnych, w których dokonywane jest rozpoznawanie suboptymalności (wariantu genetycznego osobnika) w każdym cyklu obliczeniowym. Informacja o stopniu przynależności do danego wariantu wydobywana jest poprzez odpowiedni ranking wszystkich rozwiązań względem Pareto-optymalności. Informacja ta jest wykorzystywana w procesie krzyżowania, w którym tylko osobniki o odmiennym wariancie mogą być krzyżowane. Jako przykład zastosowania metody rozważano wielokryterialną optymalizację układów regulacji i diagnostyki. Przedstawione wyniki potwierdzają użyteczność i efektywność ewolucji wspartej rozpoznawaniem genetycznego wariantu.

Istotną cechą proponowanej metody jest sposób wykorzystania Pareto-optymalizacji. Dla każdego podzbioru kryterialnego, związanego z wariantem (rodzajnikiem) genetycznym, przeprowadzany jest P-optymalny ranking, będący narzędziem suboptymalnej oceny (i wyrazem jednoimiennej, wewnętrznej rywalizacji). Pozwala ona na selekcję rozwiązań do pul rodzicielskich w każdym ewolucyjnym cyklu. Proponujemy zatem (a) nowy mechanizm preselekcji osobników oraz (b) wzajemną skuteczną między-wariantową wymianę materiału genetycznego podczas krzyżowania. Standardowa koncepcja Pareto-optymalności może być użyta do końcowej oceny uzyskanych rozwiązań zwłaszcza tych 'różnoimiennych'. Innym sposobem końcowej oceny może być metoda oparta na pojęciu globalnego poziomu optymalności wyznaczanego na podstawie zarówno przystosowania, jak i rang osobników [5].

Wylania się kilka praktycznych aspektów proponowanej metody, które są w opozycji do tradycyjnego podejścia do wielokryterialnej optymalizacji: (1) uzyskane fronty

Pareto są bardziej regularne i jest ich więcej, (2) zachowuje się różnorodność rozwiązań zabezpieczającą przed przedwczesną zbieżnością, a projektant uzyskuje (3) możliwość łatwego formułowania subkryteriów oraz (4) jasne przesłanki co do końcowego rozstrzygnięcia.

Dziękuję niniejszym mojemu doktorantowi Tomaszowi Białaszewskiemu za realizację obliczeń ewolucyjnych oraz przeprowadzenie badań symulacyjnych.

LITERATURA

- [1] Goldberg D.E., *Genetic Algorithms in Search, Optimisation and Machine Learning*. Addison-Wesley, Reading, 1989.
- [2] Izadi-Zamanabadi R., Blanke M., A ship propulsion system model for fault-tolerant control. Technical Report R-1998-4262, Dept. Control Eng., Aalborg University, Denmark, 1998
- [3] Kowalczyk Z., Suchomski P., Białaszewski T., Evolutionary multiobjective Pareto optimisation of diagnostic state observers. *Int. J. Applied Math. and Computer Science*, 1999, Vol. 9, (3), pp.°689-709.
- [4] Kowalczyk Z., Suchomski P., Białaszewski T., Genetic multiobjective Pareto optimisation of state observers for FDI. Proc. ECC, Karlsruhe, Germany, 1999, pt. CP-15:10, pp.°1-6.
- [5] Kowalczyk Z., Białaszewski T., Pareto-optimal observers for ship propulsion systems by evolutionary computation. Proc. *IFAC Safeprocess*, Budapest, Hungary, 2000, pp.°914-919.
- [6] Kowalczyk Z., Białaszewski T., Fitness and ranks of individuals warped by niching mechanism. Proc. *Polish-German Symposium Science Research Education*, Zielona Góra, Poland, 2000, pp.°97-102.
- [7] Kowalczyk Z., Białaszewski T., Evolutionary multi-objective optimisation with genetic sex recognition. Symp. *MMAR*, Międzyzdroje, Poland, 2001, pp.°143-149.
- [8] Kowalczyk Z., Białaszewski T., Performance and robustness design of control systems via genetic-sex multi-objective optimization. *IFAC World Congress*, Spain, 2002, CD-ROM: T-Th-M16.
- [9] Kowalczyk Z., Białaszewski T., Genetic-sex multi-objective optimisation of control systems with pre-selection of criteria. *MMAR*, Poland, 2002, pp.°263-268.
- [10] Man K.S., Tang K.S., Kwong S., Lang W.A.H., *Genetic algorithms for control and signal processing*. Springer-Verlag, London, 1997.
- [11] Michalewicz Z., *Genetic Algorithms + Data Structures=Evolution Programs*. Springer-Verlag, New York, 1996.
- [12] Zakian V., Al-naib U., Design of dynamical and control systems by the method of inequalities. Proc. of *IEE*, 1973, Vol. 120, pp.°1421-1427.