



XV Krajowa Konferencja Automatyki

Tom II



**Redaktorzy:
Zdzisław Bubnicki
Roman Kulikowski
Janusz Kacprzyk**

XV Krajowa Konferencja Automatyki Tom II



Redaktorzy:
Zdzisław BUBNICKI
Roman KULIKOWSKI
Janusz KACPRZYK

ORGANIZATOR

Komitet Automatyki i Robotyki Polskiej Akademii Nauk
Instytut Badań Systemowych Polskiej Akademii Nauk

WSPÓŁORGANIZATORZY

Politechnika Warszawska

Przemysłowy Instytut Automatyki i Pomiarów

Polskie Stowarzyszenie Pomiarów, Automatyki i Robotyki

ORGANIZATOR

Komitet Automatyki i Robotyki Polskiej Akademii Nauk
Instytut Badań Systemowych Polskiej Akademii Nauk

WSPÓLORGANIZATORZY

Politechnika Warszawska
Przemysłowy Instytut Automatyki i Pomiarów
Polskie Stowarzyszenie Pomiarów, Automatyki i Robotyki

KOMITET PROGRAMOWY

Przewodniczący	Zdzisław BUBNICKI
Zastępca Przewodniczącego	Roman KULIKOWSKI

CZŁONKOWIE

Stanisław BAŃKA	Michał BIAŁKO
Mikołaj BUSŁOWICZ	Władysław FINDEISEN
Ryszard GESSING	Henryk GÓRECKI
Jakub GUTENBAUM	Jerzy JÓZEFczyk
Stanisław KACZANOWSKI	Tadeusz KACZOREK
Janusz KACPRZYK	Jerzy KLAMKA
Józef KORBICZ	Zbigniew KOWALSKI
Krzysztof KOZŁOWSKI	Juliusz L. KULIKOWSKI
Krzysztof KUŹMIŃSKI	Kazimierz MALANOWSKI
Krzysztof MALINOWSKI	Wojciech MITKOWSKI
Antoni NIEDERLIŃSKI	Władysław PEŁCZEWSKI
Tadeusz PUCHAŁKA	Leszek RUTKOWSKI
Stanisław SKOCZOWSKI	Roman SŁOWIŃSKI
Jerzy ŚWIĄTEK	Andrzej ŚWIERNIAK
Ryszard TADEUSIEWICZ	Piotr TATJEWSKI
Krzysztof TCHOŃ	Leszek TRYBUS
Jan WĘGLARZ	Andrzej P. WIERZBICKI

KOMITET ORGANIZACYJNY

Przewodniczący	Roman KULIKOWSKI
Zastępcy Przewodniczącego	Janusz KACPRZYK
	Stanisław KACZANOWSKI
	Tadeusz KACZOREK
	Krzysztof MALINOWSKI
Członkowie	Roman OSTROWSKI
	Tadeusz PUCHAŁKA
	Dariusz WAGNER
Sekretarze naukowci	Jan STUDZIŃSKI
	Jan W. OWSIŃSKI

ISBN 83-89475-01-4

Copyright © Instytut Badań Systemowych Polskiej Akademii Nauk
All rights reserved

Druk: ARGRAF, Warszawa

OPTYMALIZACJA
I PODEJMOWANIE DECYZJI

WIELOKRYTERIALNA OPTYMALIZACJA EWOLUCYJNA Z PRESELEKCJĄ KWALITATYWNYCH SUBKRYTERIÓW

Zdzisław KOWALCZUK

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

Streszczenie: W pracy rozważa się problem optymalizacji wielokryterialnej. Zadania tego rodzaju mogą być skutecznie rozwiązywane za pomocą metod ewolucyjnych z zastosowaniem zaproponowanego ostatnio pojęcia genetycznego rodzajnika, wywodzonego ze stopnia przystosowania analizowanych osobników (rozwiązań) i stosowanego podczas krzyżowania w procesie wielokryterialnej optymalizacji. Do oceny uzyskiwanych rozwiązań tego rodzaju problemów wykorzystywać można metody: ważonych zysków, odległości, sekwencyjnych ograniczeń nierównościowych lub rankingu według Pareto-optymalności. W pracy omawia się rodzajnikowy mechanizm genetyczny i jego działanie ilustruje przykładami wielokryterialnej syntezy wybranych układów automatyki (regulatorów i obserwatorów).

Słowa kluczowe: Optymalizacja, wielokryterialność, wielowymiarowość, algorytmy ewolucyjne, regulatory PID, optymalne obserwatory detekcyjne.

1. WPROWADZENIE

Postępowanie w sposób precyzyjny, charakteryzujący podejście matematyczne, nie zawsze prowadzi do efektywnego rozwiązania. Tymczasem w przyrodzie zaobserwować można istnienie wielu naturalnych mechanizmów, które z niezwykłą skutecznością prowadzą do osiągnięcia 'sukcesu', widzianego w kategoriach zdobycia pożywienia, schronienia, wychowania potomstwa i przeżycia w szerszym znaczeniu.

Zapoczątkowało to duże zainteresowanie inżynierów tego rodzaju mechanizmami. Znacznie uproszczone, ale jednak użyteczne ich wersje szybko uzyskały postać praktyczną, wyrażającą się w formie rozmaitych elementów sztucznej inteligencji, do których zaliczają się na przykład metody rozmytego oceniania analizowanych wielkości, wnioskowania ekspertowego, modelowania neuronowego, oraz obliczeń ewolucyjnych (genetycznych).

W nauce i technice szczególnie często wykorzystywany jest optymalizacyjny sposób stawiania problemów. W ich rozwiązywaniu coraz to większe zastosowanie mają algorytmy ewolucyjne, które naśladują fundamentalny sposób ewolucji systemów biologicznych, pozwa-

lający na poszukiwanie optymalnych form życia (organizmów) opierając się na wyselekcjonowanym materiale genetycznym, charakteryzującym osobniki, które już dowiodły swojej przydatności i przystosowania do panujących warunków życia.

Podobnie jak to się dzieje w przyrodzie, również w praktyce inżynierskiej chcielibyśmy, aby budowane przez nas systemy techniczne odznaczały się zarówno pożądanymi cechami w zakresie doskonałości działania (wykonywania podstawowych funkcji), jak i odpornością na mniej znaczące zmiany w środowisku (odporności, niewrażliwości) oraz umiejętności dostosowania się do większych zmian (samo/uczenia, samo/organizacji, samo/strojenia, adaptacyjności).

W praktyce problem sprowadza się do sformułowania odpowiedniego globalnego zadania optymalizacyjnego uwzględniającego rozmaite aspekty działania układu, w tym skuteczność realizacji jego podstawowych funkcji, niewrażliwość na sygnały zakłócające, jak również odporność na zmiany parametrów oraz niedokładność modelowania, projektowania i realizacji. Prowadzi to do niezwykle istotnego z inżynierskiego punktu widzenia, projektowania 'optymalnego', gwarantującego bardziej skuteczne i niezawodne działanie konstruowanych układów. Tego rodzaju projektowanie, oparte na zadaniu optymalizacji wielokryterialnej [1, 13, 14, 10], oznacza konieczność łącznej optymalizacji wielu cząstkowych kryteriów, między którymi trudno jest określić wzajemne zależności.

Przy rozwiązywaniu problemów wielokryterialnych wykorzystuje się metodę ważonych zysków [14], metodę odległości [14], metodę sekwencyjnych ograniczeń nierównościowych [15] lub metodę rankingu według Pareto-optymalności [13, 3, 6, 10-12]. 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 odle-

głości 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 stosunkowo 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 narzuconego arbitralnie uproszczenia zadania wielokryterialnej optymalizacji. Zwłaszcza metody (ważona i popytowa) opierające się na integracji wielu kryteriów w jedno, zmuszają projektanta do podejmowania niezwykle trudnego i odpowiedzialnego zadania, polegającego na decydowaniu o wzajemnych zależnościach pomiędzy kryteriami cząstkowymi.

Bardziej właściwe podejście związane jest z metodą rankingową opartą na pojęciu Pareto-optymalności, które pozwala oceniać i klasyfikować uzyskane rozwiązania zadania wielokryterialnej maksymalizacji jako rozwiązania zdominowane lub niezdominowane (Pareto-optymalne lub w skrócie P-optymalne) [1, 14].

Ocena według Pareto-optymalności nie tylko wyznacza zbiór P-optymalnych rozwiązań, ale również pozwala na uszeregowanie wszystkich możliwych rozwiązań pod względem stopnia zdominowania. Należy jednak pamiętać, że odwzorowanie to wskazuje raczej na zbiory Pareto-optymalnych rozwiązań – nie dokonując selekcji żadnego konkretnego (pojedynczego) rozwiązania. Jest to konsekwencją równoważnego traktowania poszczególnych składowych kryteriów zawartych w wektorowej funkcji zysku. Oczywiście projektant zawsze może wprowadzić jakąś dodatkową ocenę uzyskanych P-optymalnych rozwiązań, która pozwoli dokonać ostatecznej selekcji.

W algorytmach ewolucyjnych (genetycznych) [1, 14, 3, 6, 9, 10, 12] implementować można wszelkiego rodzaju mechanizmy prowadzące do tworzenia nowych generacji rozwiązań i podejmowania ostatecznych 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 wariantem subkryterialnym; $X_j, j=1,2,\dots$), który jest elementem dopuszczalnego zbioru rodzajników [7-9, 11], np. {żeński i męski} jak to się dzieje w systemach naturalnych.

Koncepcja wariantu (sub-)kryterialnego zasadza się na podziale zbioru funkcji celów na podzbiory. Podział ten

jest związany z charakterem rozważanych celów (np. cele jakościowe, wrażliwościowe i odpornościowe). Realizowana w ten sposób suboptymalizacja wykorzystywana jest w procesie prokreacji (kojarzenia i krzyżowania rozwiązań), w którym tylko rozwiązania o odmiennym wariantcie kryterialnym mogą tworzyć pary rodzicielskie, uwzględniane w iteracyjnym procesie generowania nowych rozwiązań, którego celem jest uzyskanie optymalnego rozwiązania.

Ilustrację rozważanego podejścia stanowią przykłady prostych abstrakcyjnych przykładów jedno-, dwu- i trójwymiarowych funkcji celu [6], jak również praktyczne zadania wielokryterialnej syntezy układów regulacji [7-9] oraz diagnostyki systemów lotniczych [3, 4, 10] i okrętowych [2, 5, 10-12], a uzyskane wyniki potwierdzają dużą skuteczność proponowanej metody optymalizacji, która pozwala na przykład na uzyskiwanie optymalnych systemów charakteryzujących się zarówno wysoką jakością, jak i dużą niewrażliwością na zakłócenia oraz odpornością na błędy projektowania i realizacji.

2. OPTIMALIZACJA WIELOKRYTERIALNA

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

2.1. 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 $f_j(x), j=1,2,\dots,m$, stanowią cele cząstkowe.

Przyjmijmy, 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 (bądź osobnik w naturze) 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 współrzędną $x_{i_k}, i=1,2,\dots,N, k=1,2,\dots,n$, oznacza k -ty parametr poszukiwanego i -tego osobnika, zaś N reprezentuje liczbę osobników w populacji

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

2.2. 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, 13, 14]

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

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).

2.3. Ranking względem P-optymalności

Ustalanie rangi osobników (rozwiązań) względem P-optymalności służy ocenie osobników: Każdemu rozwiązaniu można przyporządkować pewną skalarną wielkość zwaną rangą [13]. 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:

$$r(x_i) = \mu_{\max} - \mu(x_i) + 1 \quad (7)$$

$$\mu_{\max} = \max_{i=1,2,\dots,N} \mu(x_i)$$

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 KRYTERIALNY 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 wariantu kryterialnego (GVAR) zasadza się na podziale zbioru funkcji celów na kilka rozłącznych podzbiorów, którym przypisywana może być określona nazwa (wspólny atrybut lub 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 'jednolitych' 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 genetycznych rodzajników (wariantów) (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 'różnolitych' cech, która nie jest prosta do rozwiązania. Do ostatecznej oceny uzyskanych rozwiązań można stosować na przykład koncepcję 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 rodzajnikach (lub z różnych wariantów kryterialnych 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 kryterialny 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 (suboptymalizację) [7-9]:

$$\varphi_i = \max_{j=1,2,\dots,s} \varphi_i^j \quad (11)$$

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

gdzie względną rangę wyznacza się następująco:

$$\varphi_i^j = \frac{r_j(x_i)}{r_{j_{\max}}} \quad (12)$$

$$r_{j_{\max}} = \max_{i=1,2,\dots,N} \{r_j(x_i)\}$$

Dzięki zastosowanej normalizacji, φ_i stanowi najwyższy rozmyty stopień suboptymalności, tj. przynależności i -tego osobnika do l_i -tego wariantu kryterialnego (do którego jest on najlepiej przystosowany), zaś $r_{j_{\max}}$ oznacza maksymalną rangę, jaką osiągają wszystkie rozwiązania względem danego 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 kryterialnym.

Należy podkreślić, iż tylko osobniki różnoimienne (o odmiennym wariancie) tworzą pary biorące udział w generowaniu potomków poprzez proces krzyżowania. Procedura selekcji osobników do suboptimalnych (wariantowych) pul rodzicielskich o określonym rodzajniku jest prowadzona metodą stochastycznego doboru resztowego [3, 4] na podstawie (efektywnego) stopnia przynależności (suboptimalności) φ_i .

3.1. Algorytm ewolucyjny EA-GVAR/GEND

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

Inicjacja N osobników w populacji X;

Dopóki $t \leq t_{\max}$

Wyznaczenie przystosowania każdego osobnika;

P-suboptimalny ranking (wg subkryteriów/wariantów);

Rozpoznanie wariantu/rodzajnika osobników;

Selekcja suboptimalnych pul rodzicielskich;

Tworzenie nowej populacji X' poprzez:

- krzyżowanie różnowariantowych osobników,
- 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:

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

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

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

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

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

Kryteria całkowite wyznaczane są 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 (oznaczymy jako $XX = \text{'JAKOŚĆ'}$) składa się z trzech jakościowych wskaźników całkowitych

$$\mathbf{f}_1(\mathbf{x}) = [f_1(\mathbf{x}) \quad f_2(\mathbf{x}) \quad f_3(\mathbf{x})]^T \in \mathfrak{R}^3 \quad (21)$$

zaś w skład drugiego optymalizowanego wektora ($XY = \text{'ODPORNOŚĆ'}$) wchodzi dwa kryteria o cechach odpornościowych, tzn. zapas wzmocnienia i fazy

$$\mathbf{f}_2(\mathbf{x}) = [f_4(\mathbf{x}) \quad f_5(\mathbf{x})]^T \in \mathfrak{R}^2 \quad (22)$$

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

$$\mathbf{x}_i = [x_{1i} \quad x_{2i} \quad x_{3i}]^T \in \mathfrak{R}^3 \quad (23)$$

W czasie 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.



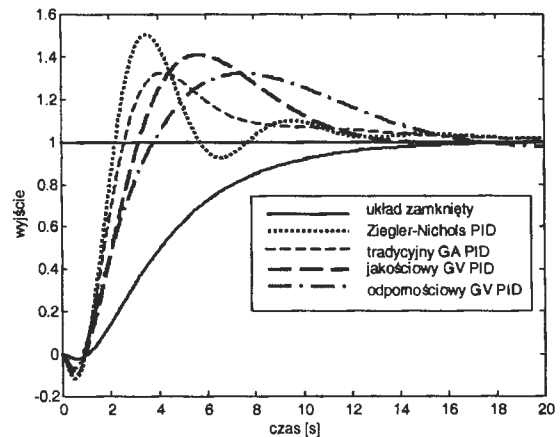
Rys. 2. P-optymalne rozwiązania na płaszczyźnie odpornościowej.

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


4.3. Wyniki symulacji układów regulacji

Porównanie efektywności różnych regulatorów PID przedstawiono na rys. 3.

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



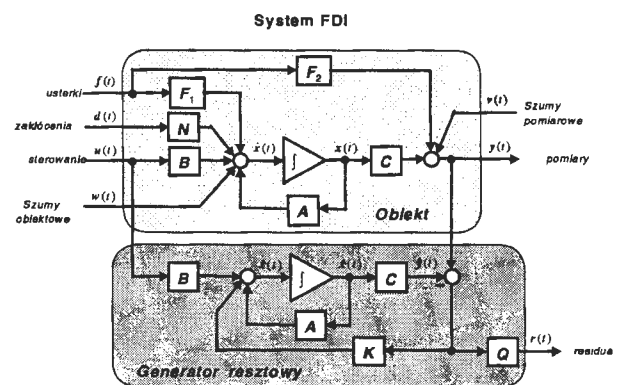
Rys. 3. Nominalna odpowiedź skokowa układów regulacji PID.



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

5. OPTIMALIZACJA 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.

Problem wielokryterialnej optymalizacji generatora resztowego może być przedstawiony następująco:

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

gdzie

$$J_1(K,Q) = \|W_1(s) \cdot G_{rf}(s)\|_\infty,$$

$$J_2(K,Q) = \|W_2(s) \cdot G_{rd}(s)\|_\infty,$$

$$J_3(K,Q) = \|W_3(s) \cdot G_{rw}(s)\|_\infty,$$

$$J_4(K,Q) = \|W_4(s) \cdot G_{rv}(s)\|_\infty,$$

$$J_5(K) = \|(A - KC)^{-1} K\|_s,$$

$$J_6(K) = \|(A - KC)^{-1}\|_s,$$

oraz

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

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

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

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

$$A_0 = A - KC.$$

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 ważenia widmowego.

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 ważące $W_1(s)$, $W_2(s)$, $W_3(s)$, $W_4(s)$ 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 subkryterialne warianty (suboptymalności):

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

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),
 $J_2(\lambda) = [J_2(\lambda) \ J_3(\lambda) \ J_4(\lambda)]^T \in \mathfrak{R}^3$; oraz

- 'ODPORNOŚĆ' (X3) (wpływ odchyłek od nominalnego modelu analizowanego obiektu),
 $J_3(\lambda) = [J_5(\lambda) \ J_6(\lambda)]^T \in \mathfrak{R}^2$.

4.4. Przykład projektowy

Rozważmy stanowy model okrętowego systemu napędowego [2]:

$$\dot{x}(t) = Ax(t) + Bu(t) + Nd(t) + F_1f(t) + w(t) \quad (29)$$

$$y(t) = Cx(t) + F_2f(t) + v(t) \quad (30)$$

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

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

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

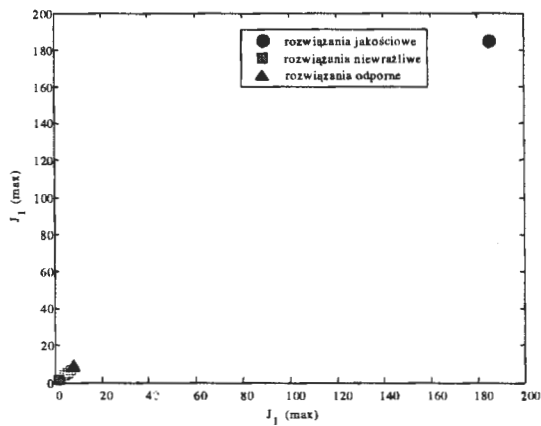
Przestrzeń ta zastała zawężona do ograniczonej hiperkostki:

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


4.5. Wyniki ewolucyjnej optymalizacji

Przykład skuteczności wariantowej optymalizacji (GVAR) w przestrzeni jakościowej przedstawia rys. 6.


W analizowanym przypadku, rezultaty podejścia klasycznego (GA) były bliskie rozwiązaniom niejakościowym (niewrażliwym i odpornym). Podobny efekt uzyskano w innych rozważanych podprzestrzeniach, co ilustruje również rys. 7.



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



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




Rys. 8. Liczba frontów Pareto w trakcie ewolucji.

Interesującym, zilustrowanym 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.

4.6. 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 kryterialnego lub rodzajnika genetycznego danego 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 rodzajnika, przy założonej preselekcji kwalitatywnych subkryteriów.

Istotną cechą proponowanej metody jest sposób wykorzystania Pareto- optymalizacji. Dla każdego podzbioru kryterialnego, wiążanego z wariantem subkryterialnym (rodzajnikiem genetycznym), przeprowadzany jest P- optymalny ranking, będący narzędziem suboptymalnej oceny (i wyrazem jednoimiennej, wewnętrznej rywalizacji). Pozwala ona na selekcję rozwiązań do pul rodzielskich 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].

Wyłania 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 doboru subkryteriów, oraz
- (4) jasne przesłanki co do końcowego rozstrzygnięcia.

Za przeprowadzenie badań oraz opracowanie wyników, które posłużyły do opracowania niniejszego referatu plenarnego, dziękuję mojemu doktorantowi Tomaszowi Białaszewskiemu.

EVOLUTIONARY MULTI-OBJECTIVE OPTIMIZATION WITH PRESELECTION OF QUALITATIVE SUB-CRITERIA

Abstract: In this paper the issue of multi-objective optimization is 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. Evaluation of the solutions obtained can be performed by the methods of weighted gains, distances, sequential inequality boundaries or by the method of ranking with respect to Pareto-optimality. In this paper characteristics of the gender mechanism are discussed and its performance is illustrated by means of exemplary multi-objective controller and state-observer syntheses tasks.

Literatura

- [1] Goldberg D.E. (1989) *Genetic Algorithms in Search, Optimisation and Machine Learning*. Addison-Wesley, Reading.
- [2] Izadi-Zamanabadi R., Blanke M., (1998) A ship propulsion system model for fault-tolerant control.

Technical Report R-1998-4262, Dept. Control Eng., Aalborg University, Denmark.

- [3] Kowalczyk Z., Suchomski P., Białaszewski T. (1999) Evolutionary multiobjective Pareto optimisation of diagnostic state observers. *Int. J. Applied Math. and Computer Science*, 9(3), 689-709.
- [4] Kowalczyk Z., Suchomski P., Białaszewski T. (1999) Genetic multiobjective Pareto optimisation of state observers for FDI. *Proc. ECC*, Karlsruhe, Germany, CP-15:10, 1-6.
- [5] Kowalczyk Z., Białaszewski T. (2000) Pareto-optimal observers for ship propulsion systems by evolutionary computation. *Proc. IFAC Safeprocess*, Budapest, Hungary, 914-919.
- [6] Kowalczyk Z., Białaszewski T. (2000) Fitness and ranks of individuals warped by niching mechanism. *Proc. Polish-German Symposium Science Research Education*, Zielona Góra, Poland, 97-102.
- [7] Kowalczyk Z., Białaszewski T. (2001) Evolutionary multi-objective optimisation with genetic sex recognition. *Proc. 7th IEEE Conf. MMAR*, Międzyzdroje, Poland, 143-149.
- [8] Kowalczyk Z., Białaszewski T. (2002) Performance and robustness design of control systems via genetic-sex multi-objective optimization. *IFAC World Congress*, Barcelona, Spain, CD-ROM: T-Th-M16.
- [9] Kowalczyk Z., Białaszewski T. (2002) Genetic-sex multi-objective optimisation of control systems with pre-selection of criteria. *Proc. 8th IEEE Conf. MMAR*, Międzyzdroje, Poland, 263-268.
- [10] Kowalczyk Z., Białaszewski T. (2002) Algorytmy genetyczne w wielokryterialnej optymalizacji obserwatorów detekcyjnych. *Diagnostyka Procesów - Modele, Metody Sztucznej Inteligencji, Zastosowania* [Red. J. Korbicz, J.M. Kościelny, Z. Kowalczyk, W. Cholewa]. WNT, Warszawa, 465-511.
- [11] Kowalczyk Z., Białaszewski T. (2003) Multi-gender genetic optimisation of diagnostic observers. *Proc. 12th IFAC Workshop Control Applications of Optimisation*, Visegrad, Hungary, 15-20.
- [12] Kowalczyk Z., Białaszewski T. (2004) Periodic and continuous niching in genetic optimization of detection observers. *Proc. 10th IEEE Conf. Methods and Models in Automation and Robotics (MMAR)*, Międzyzdroje, Poland, I, 353-358.
- [13] Man K.S., Tang K.S., Kwong S., Lang W.A.H. (1997) *Genetic algorithms for control and signal processing*. Springer-Verlag, London.
- [14] Michalewicz Z. (1996) *Genetic Algorithms + Data Structures=Evolution Programs*. Springer-Verlag, New York.
- [15] Zakian V., Al-naib U. (1973) Design of dynamical and control systems by the method of inequalities. *Proceedings of IEE*, 120, 1421-1427.