

*algorytm genetyczny, optymalizacja,
filtr Kalmana, układ dwumasowy*

Krzysztof DRÓZDŹ*

OPTYMALIZACJA ROZMYTEGO FILTRU KALMANA PRZY WYKORZYSTANIU ALGORYTMÓW GENETYCZNYCH

W artykule przedstawiono zagadnienia związane z optymalizacją rozmytego filtra Kalmana, pracującego w adaptacyjnej strukturze sterowania układu dwumasowego. Omówiono przykłady współczesnych struktur sterowania układów elektrycznych z połączeniem sprzężystym, wymagających zastosowania metod estymacji zmiennych stanu obiektów dynamicznych. Szczególną uwagę zwrócono na estymatory oparte na teorii filtra Kalmana. Scharakteryzowano ich problematykę oraz przedstawiono możliwości zastosowania algorytmów genetycznych. Przedstawiono obiekt badań, model matematyczny oraz algorytmy genetyczne. Zaprezentowano proces optymalizacji rozmytego filtra Kalmana przy ich wykorzystaniu. Przedstawiono wyniki badań przy zastosowaniu obserwatora w otwartej oraz zamkniętej strukturze sterowania.

1. WPROWADZENIE

We współczesnych strukturach sterowania napędów elektrycznych wykorzystywane są sprzężenia zwrotne od różnych wielkości elektromechanicznych układów napędowych. W przypadku wielu algorytmów sterowania wymagane jest posiadanie informacji o wielkościach, które w praktyce są trudno mierzalne [1]. Przykładem występowania takiej sytuacji są struktury sterowania układów napędowych z połączeniem sprzężystym, gdzie wymagana jest dostępność informacji o takich wielkościach, jak: moment skrętny wału napędowego, moment obciążenia, prędkość maszyny roboczej, różnica prędkości silnika i maszyny roboczej, stała czasowa maszyny roboczej, czy pochodne wybranych wielkości [11]. W takim przypadku zastosowanie znajdują metody estymacji zmiennych stanu układów dynamicznych. Spośród wielu metod odtwarzania zmiennych stanu napędów elektrycznych, opisanych w [7], wyróżnić

* Instytut Maszyn Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, ul. Smoluchowskiego 19, 50-372 Wrocław, e-mail: krzysztof.drozd@pwr.wroc.pl.

można obserwatory oparte na teorii filtru Kalmana [10]. Zastosowanie takiego rozwiązania prowadzi do uzyskania pożądanej jakości estymacji wymaganych wielkości, w warunkach występowania zakłóceń pomiarowych i parametrycznych. Problematycznym zagadnieniem w tym przypadku jest dobór współczynników macierzy kowariancji zakłóceń stanu \mathbf{Q} i wyjścia \mathbf{R} . Pomimo istnienia metod analitycznych, które umożliwiają wyznaczenie wartości wspomnianych współczynników [3], najczęściej są one dobierane w sposób doświadczalny [11]. Podejście analityczne jest słuszne w przypadku dokładnej znajomości parametrów układu, które nie ulegają zmianie podczas jego pracy oraz przy braku występowania zakłóceń sygnałów wyjściowych. W przypadku występowania wymienionych czynników jednym z rozwiązań jest zastosowanie algorytmów genetycznych, które umożliwiają znalezienie wartości minimalnej przyjętej funkcji celu [4], [5], [9]. Funkcja ta powinna być określona w sposób zapewniający odporność układu na zmianę wybranych parametrów [11]. Algorytm genetyczny to procedura iteracyjna, której celem jest optymalizacja określonej funkcji celu poprzez zmiany osobników populacji wyjściowej. Osobniki te zakodowane są w postaci łańcuchów genów tworzących tzw. chromosomy. Ich zmiany następują dzięki przeprowadzeniu zdefiniowanych operacji genetycznych, jak mutacja, krzyżowanie i selekcja [7].

W niniejszej pracy przedstawiono zagadnienia związane z zastosowaniem algorytmów genetycznych do optymalizacji rozmytego filtru Kalmana (RFK), pracującego w adaptacyjnej strukturze sterowania układu dwumasowego. Do rozważań wykorzystano zmodyfikowany algorytm nieliniowego rozszerzonego filtru Kalmana (NRFK). Modyfikacja polegała na wprowadzeniu systemu rozmytego, którego zadaniem była adaptacja wybranych współczynników macierzy \mathbf{Q} , na podstawie aktualnej estymowanej wartości stałej czasowej maszyny roboczej. Rozważania teoretyczne zweryfikowano poprzez badania symulacyjne. W literaturze światowej istnieje szereg prac opisujących w sposób ogólny modyfikacje filtrów Kalmana [12]–[14], natomiast w literaturze krajowej występuje ich znikoma liczba [8]. Implementacja proponowanego rozwiązania stanowi nowe podejście, ze względu na brak prac opisujących zastosowanie rozmytego filtru Kalmana do estymacji zmiennych stanu i parametrów układu dwumasowego.

2. OPIS I MODEL MATEMATYCZNY OBIEKTU BADAŃ

Przedmiotem badań jest rozmyty filtr Kalmana pracujący w adaptacyjnej strukturze sterowania układu dwumasowego. Do rozważań wykorzystano model matematyczny układu dwumasowego z bezinercyjnym połączeniem sprężystym, który można opisać następującymi równaniami stanu w jednostkach względnych [11]:

$$\frac{d\omega_1(t)}{dt} = \frac{1}{T_1}(m_e(t) - m_s(t)), \quad (1)$$

$$\frac{d\omega_2(t)}{dt} = \frac{1}{T_2}(m_s(t) - m_L(t)), \quad (2)$$

$$\frac{dm_s(t)}{dt} = \frac{1}{T_c}(\omega_1(t) - \omega_2(t)) \quad (3)$$

gdzie:

ω_1 – prędkość silnika,

ω_2 – prędkość maszyny roboczej,

m_e – moment elektromagnetyczny,

m_s – moment skrzętny,

m_L – moment obciążenia,


T_1 – mechaniczna stała czasowa silnika,

T_2 – mechaniczna stała czasowa maszyny roboczej,

T_c – stała sprężystości.

Wartości parametrów analizowanego układu wynosiły: $T_1 = T_2 = 0,203$ s, $T_c = 0,0012$ s. Pozostałe dane zamodelowanego obiektu znajdują się w [11].

W badaniach wykorzystano strukturę sterowania adaptacyjnego z regulatorem PI i dwoma dodatkowymi sprzężeniami zwrotnymi, od momentu skrzętnego (k_1) oraz różnicy prędkości (k_2) [11]. Schemat omawianej struktury sterowania przedstawiono na rysunku 1. W badaniach założono szeroki zakres zmian stałej czasowej maszyny roboczej (od $0,4 T_{2N}$ do $4 T_{2N}$).



Rys. 1. Schemat blokowy struktury sterowania

Przyjęto następującą transmitancję pętli wymuszenia momentu elektromagnetycznego:

$$G_p(s) = \frac{1}{0,002s + 1}. \quad (4)$$

Współczynniki układu regulacji dobierano uwzględniając aktualną wartość stałej czasowej maszyny roboczej T_{2e} , według poniższych zależności:

$$K_I = \omega_r^4 T_1 T_2 T_c, \quad (5)$$

$$K_p = 4\xi_z \omega_r^3 T_1 T_2 T_c, \quad (6)$$

$$k_2 = \frac{1}{\omega_r^3 T_2 T_c} - 1, \quad (7)$$

$$k_1 = \frac{T_1(4\xi_z^2 - k_2)}{T_2(1 + k_2)} - 1 \quad (8)$$

gdzie:

ω_r – zadana pulsacja rezonansowa,

ξ_z – zadany współczynnik tłumienia układu,

K_I, K_p – wzmocnienia części całkowej i proporcjonalnej regulatora PI prędkości.

W badaniach przyjęto następujące wartości: $\omega_r = 40 \text{ s}^{-1}$ i $\xi_z = 0,7$.

Przedmiotem rozważań jest rozmyty filtr Kalmana, stanowiący modyfikację klasycznego algorytmu nieliniowego rozszerzonego filtru Kalmana. Algorytm klasyczny można przedstawić następująco [10]:

1) Obliczenie predyktora wektora stanu:

$$\hat{\mathbf{x}}_{\mathbf{R}}(k+1/k) = \mathbf{A}_{\mathbf{R}}(k)\hat{\mathbf{x}}_{\mathbf{R}}(k/k) + \mathbf{B}_{\mathbf{R}}\mathbf{u}(k). \quad (9)$$

2) Estymacja macierzy kowariancji błędu predykcji:

$$\mathbf{P}(k+1/k) = \mathbf{F}_{\mathbf{R}}(k)\mathbf{P}(k)\mathbf{F}_{\mathbf{R}}^T(k) + \mathbf{Q}(k) \quad (10)$$

gdzie:

$$\mathbf{F}_{\mathbf{R}}(k) = \left. \frac{\partial \mathbf{f}_{\mathbf{R}}(\mathbf{x}_{\mathbf{R}}(k/k)\mathbf{u}(k), k)}{\partial \mathbf{x}_{\mathbf{p}}(k/k)} \right|_{\mathbf{x}_{\mathbf{R}} = \hat{\mathbf{x}}_{\mathbf{R}}(k/k)}, \quad (11)$$

$$\mathbf{F}_{\mathbf{R}} = \begin{bmatrix} 1 & 0 & \frac{-1}{T_1}T_s & 0 & 0 \\ 0 & 1 & \frac{1}{T_2(t)}T_s & \frac{-1}{T_2(t)}T_s & T_s(m_s(k) - m_L(k)) \\ \frac{1}{T_c}T_s & \frac{-1}{T_c}T_s & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}. \quad (12)$$

3) Obliczenie wzmocnienia Kalmana:

$$\mathbf{K}(k+1) = \mathbf{P}(k+1/k)\mathbf{C}_R^T(k+1) \times [\mathbf{C}_R(k+1)\mathbf{P}(k+1/k)\mathbf{C}_R^T(k+1) + \mathbf{R}(k)]^{-1}. \quad (13)$$

4) Wyznaczenie estymaty wektora stanu:

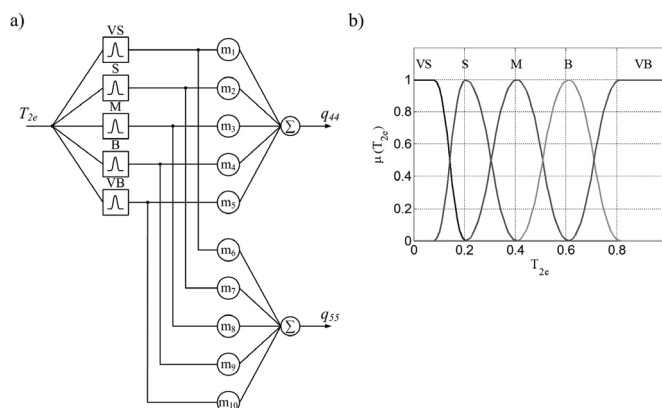
$$\hat{\mathbf{x}}_R(k+1/k+1) = \hat{\mathbf{x}}_R(k/k) + \mathbf{K}(k+1) \times [\mathbf{y}(k+1) - \mathbf{C}_R(k+1)\hat{\mathbf{x}}_R(k+1/k)]. \quad (14)$$

5) Obliczenie macierzy kowariancji błędu estymaty:

$$\mathbf{P}(k+1/k+1) = [\mathbf{I} - \mathbf{K}(k+1)\mathbf{C}_R(k+1)]\mathbf{P}(k+1/k). \quad (15)$$

6) Powrót do pierwszego kroku.

Zaproponowana w pracy modyfikacja przedstawionego algorytmu polegała na wprowadzeniu systemu rozmytego, którego strukturę przedstawiono na rysunku 2. Zadaniem systemu było wyznaczanie wartości elementów q_{44} i q_{55} macierzy \mathbf{Q} , na podstawie aktualnej wartości stałej czasowej maszyny roboczej T_{2e} . Dokładny opis zastosowanego rozwiązania znajduje się w [2]. Przedstawiony system rozmyty wymaga doboru współczynników m_i , gdzie $i = 1, 2, \dots, 10$.

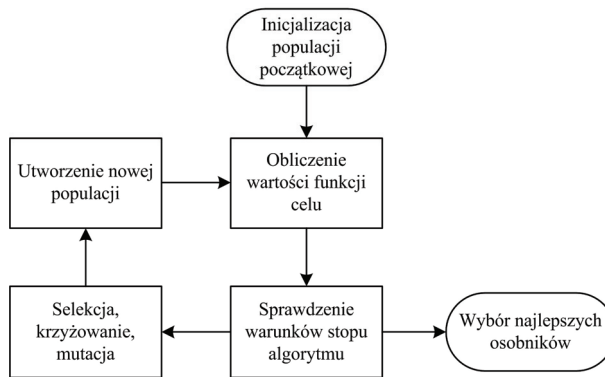


Rys. 2. Struktura wykorzystanego systemu rozmytego (a) oraz zastosowane funkcje przynależności zmiennej wejściowej (b)

3. ALGORYTMY GENETYCZNE

Algorytmy genetyczne oparte są na inspiracjach biologicznych. Ich działanie odzwierciedla sposób ewolucji organizmów żywych, które to w jej toku adaptują się do warunków swojego środowiska naturalnego. Algorytm genetyczny jest procedurą iteracyjną, której celem jest optymalizacja założonej funkcji celu. Działanie takiej procedury prowadzi do uzyskania osobników populacji wyjściowej, które zakodowane

są w postaci łańcuchów genów tworzących chromosomy. Chromosomy wraz z postępowaniem procedury iteracyjnej ulegają zmianom prowadzącym do uzyskania najlepszego rozwiązania, w świetle przyjętego kryterium. Zmiany te są wynikiem operacji genetycznych, takich jak mutacja, krzyżowanie i selekcja. Schemat działania algorytmu genetycznego przedstawiono na rysunku 3.



Rys. 3. Schemat blokowy algorytmu genetycznego

Algorytm genetyczny składa się z kilku etapów, które można przedstawić następująco:

- inicjalizacja populacji początkowej – jest to rozpoczęcie procesu iteracyjnego od losowania N chromosomów będących łańcuchami liczb binarnych lub rzeczywistych o długości L ,
- selekcja – na tym etapie obliczana jest wartość przyjętej funkcji celu $f(x)$ dla każdego chromosomu x , a następnie na podstawie oceny wartości funkcji celu dla poszczególnych chromosomów tworzona jest nowa populacja N chromosomów, gdzie prawdopodobieństwo wyboru nowego chromosomu do nowej populacji zależne jest od wartości funkcji celu,
- krzyżowanie – gdzie z prawdopodobieństwem p_c zachodzi krzyżowanie par chromosomów,
- mutacja – gdzie z prawdopodobieństwem p_m ma miejsce zamiana bitów lub zmiana wartości liczby rzeczywistej o Δx w nowym łańcuchu chromosomu,
- iteracja – wymienione operacje genetyczne są powtarzane w celu uzyskania nowych generacji o optymalnej wartości funkcji celu, w sensie założonego kryterium,
- zatrzymanie algorytmu – następuje w momencie uzyskania pożądanego rozwiązania lub po wyczerpaniu zaplanowanej liczby kroków.

Algorytmy genetyczne znajdują szerokie zastosowanie w zagadnieniach optymalizacji, szczególnie optymalizacji wielokryterialnej przy występowaniu zakłóceń oraz zmiennej w czasie funkcji celu [7]. Szczegółowy opis algorytmów genetycznych można znaleźć między innymi w [6].

4. OPTIMALIZACJA ROZMYTEGO FILTRU KALMANA

Proces optymalizacji rozpoczęto od doboru wartości współczynników macierzy kowariancji \mathbf{Q} i \mathbf{R} nieliniowego rozszerzonego filtru Kalmana, do którego sygnałów wejściowych dodano szumy białe o wartościach wariancji wynoszących $4e-5$ dla momentu elektromagnetycznego, $5e-6$ dla prędkości silnika i wartościach średnich równych 0. Wartości te dobrano na podstawie analizy szumów występujących na stanowisku laboratoryjnym, na którym planuje się przeprowadzenie badań eksperymentalnych. Następnie, do klasycznego algorytmu filtru Kalmana, dołączono proponowany system rozmyty i przeprowadzono jego optymalizację. Oba procesy zrealizowano przy wykorzystaniu algorytmów genetycznych o różnych liczbach populacji początkowej, zakresach startowych, liczbach iteracji i postaciach funkcji celu. W każdym z przypadków zastosowano jednolitą selekcję stochastyczną, reprodukcję 2 osobników, mutację adaptacyjną oraz krzyżowanie rozproszone. W pracy przedstawiono przypadki zbadanych nastaw algorytmów genetycznych i postaci funkcji celu dające najlepsze rezultaty, w świetle przyjętych kryteriów. W prezentowanych badaniach wykorzystano następujące funkcje celu:

$$F_1 = \left(\sum_1^n |\omega_1 - \omega_{1e}| \right) \left(\sum_1^n |\omega_2 - \omega_{2e}| \right) \left(\sum_1^n |m_s - m_{se}| \right) \left(\sum_1^n |m_L - m_{Le}| \right) \left(\sum_1^n |T_2 - T_{2e}| \right) \quad (16)$$

$$F_2 = \left(\sum_1^n |m_L - m_{Le}| \right) \left(\sum_1^n |T_2 - T_{2e}| \right) \quad (17)$$

gdzie:

n – liczba próbek,

x_e – wartość estymowana.

Funkcja F_1 uwzględniła wszystkie wielkości wyjściowe filtru Kalmana i posłużyła do optymalizacji współczynników macierzy \mathbf{Q} i \mathbf{R} klasycznego algorytmu. W przypadku funkcji F_2 wzięto pod uwagę iloczyn modułów różnic wielkości rzeczywistych i estymowanych, dla momentu obciążenia i stałej czasowej maszyny roboczej. Funkcja ta posłużyła do optymalizacji współczynników systemu rozmytego. Wybór omawianej funkcji celu motywowany był faktem największego wpływu współczynników q_{44} i q_{55} , na jakość estymacji uwzględnionych w niej wielkości. W tabeli 1 przedstawiono zestawienie wybranych nastaw algorytmów w poszczególnych procesach optymalizacji. Tabele 2 i 3 prezentują przyjęte ograniczenia, wynikające z wiedzy eksperckiej (lub doświadczenia), obszaru poszukiwań wartości dobieranych współczynników w obu procesach. W wyniku przyjętych założeń otrzymano wartości współczynników, które zestawiono w tabelach 5 i 6, dla poszczególnych procesów optymalizacji. Przebiegi tych procesów zobrazowano na rysunku 4.

Tabela 1. Zestawienie nastaw algorytmów genetycznych w procesach optymalizacji

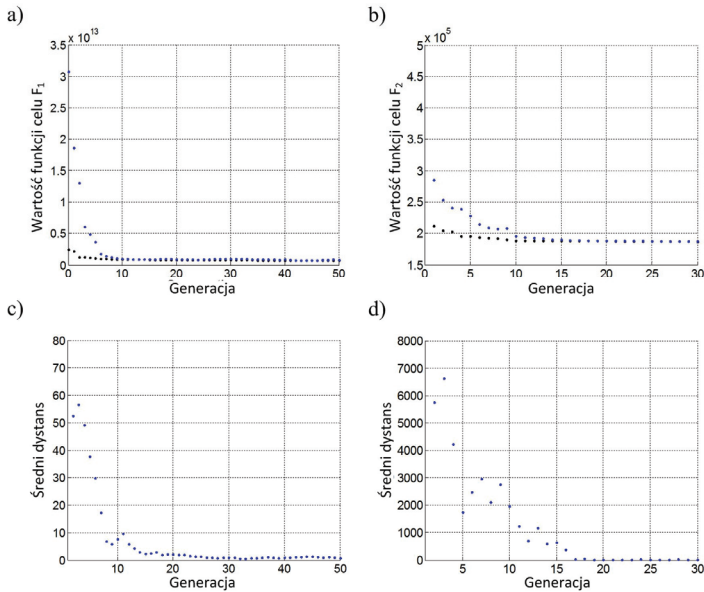
Proces optymalizacji	Parametr	Wartość
Nieliniowy rozszerzony filtr Kalmana	Populacja początkowa	50
	Zakres startowy	0–100
	Liczba iteracji	50
	Funkcja celu	F_1
Rozmyty filtr Kalmana	Populacja początkowa	100
	Zakres startowy	0–20000
	Liczba iteracji	30
	Funkcja celu	F_2

Tabela 2. Przyjęte wartości ograniczeń w procesie optymalizacji NRFK

Parametr	q_{11}	q_{11}	q_{11}	q_{11}	q_{11}	R
Ograniczenia	0–1	0–1	0–1	0–100	0–100	0–100

Tabela 3. Przyjęte wartości ograniczeń w procesie optymalizacji RFK

Parametr	m_1	m_2	m_3	m_4	m_5
Ograniczenia	0–200	0–300	0–500	0–350	0–300
Parametr	m_6	m_7	m_8	m_9	m_{10}
Ograniczenia	0–300	0–20000	0–1000	0–200	0–10



Rys. 4. Przebiegi procesów optymalizacji NRFK (a, c) oraz RFK (b, d) przy wykorzystaniu algorytmów genetycznych

Tabela 4. Zestawienie otrzymanych wartości parametrów macierzy NRFK

Parametr	q_{11}	q_{22}	q_{33}	q_{44}	q_{55}	R
Wartość	0,207	0,009	0,181	99,521	99,918	6,068

Tabela 5. Zestawienie otrzymanych wartości parametrów m_i RFK

Parametr	m_1	m_2	m_3	m_4	m_5
Wartość	11,948	240,603	57,562	245,596	62,185
Parametr	m_6	m_7	m_8	m_9	m_{10}
Wartość	298,018	4849,577	499,495	125,859	9,986

5. WYBRANE WYNIKI BADAŃ SYMULACYJNYCH


W ramach badań symulacyjnych przetestowano oba zastosowane algorytmy klasycznego nieliniowego rozszerzonego filtru Kalmana oraz rozmytego filtru Kalmana, pracujące poza strukturą sterowania, przy zastosowaniu otrzymanych w wyniku procesów optymalizacji wartości poszczególnych współczynników. Następnie przeprowadzono testy pracy obserwatora w zamkniętej strukturze sterowania. Na rysunku 5 przedstawiono sygnały wejściowe dla obu obserwatorów. Wyniki badań NRFK pracującego w otwartej strukturze sterowania, przy zastosowaniu wartości współczynników macierzy \mathbf{Q} i \mathbf{R} z tabeli 4, zaprezentowano na rysunku 6. Rysunek 7 obrazuje wyniki badań RFK pracującego poza strukturą sterowania. W celu wykonania oceny jakości estymacji poszczególnych zmiennych stanu i wielkości dodatkowych, obliczono błędy estymacji, zgodnie z poniższą zależnością:

$$\delta x = \frac{\sum_{i=1}^n |x_i - x_{ie}|}{n}, \quad i = 1, 2, \dots, n \quad (19)$$

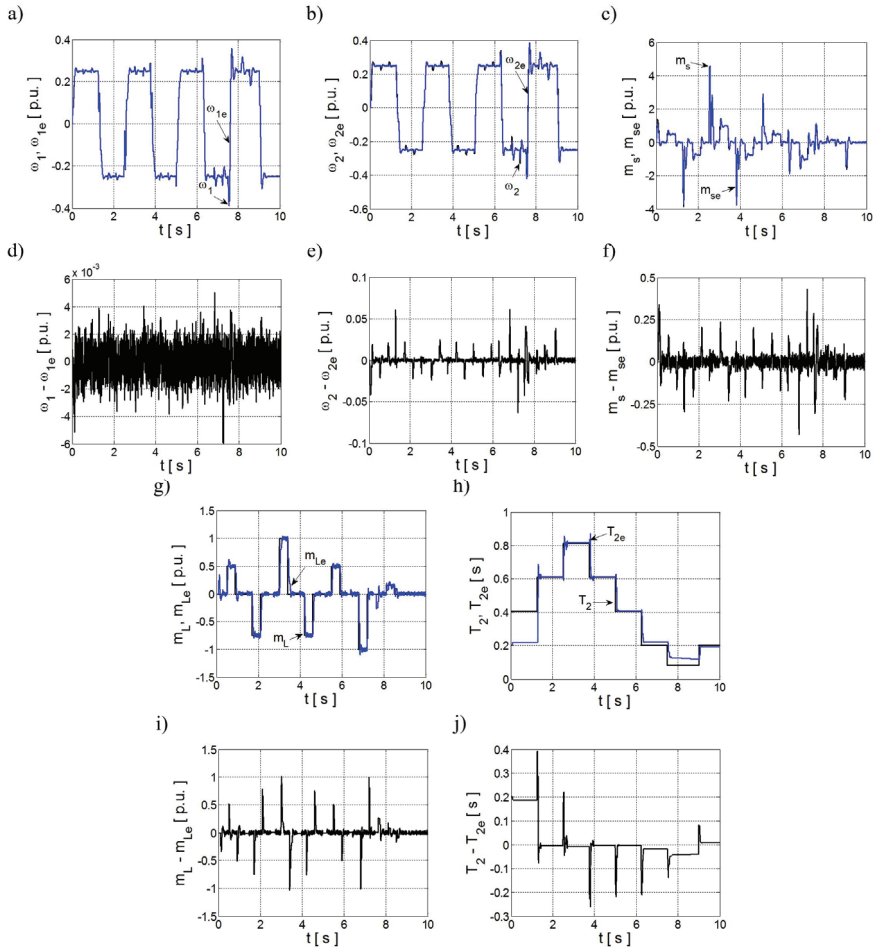
gdzie:

- x – wartość rzeczywista,
- x_e – wartość estymowana,
- n – liczba próbek.

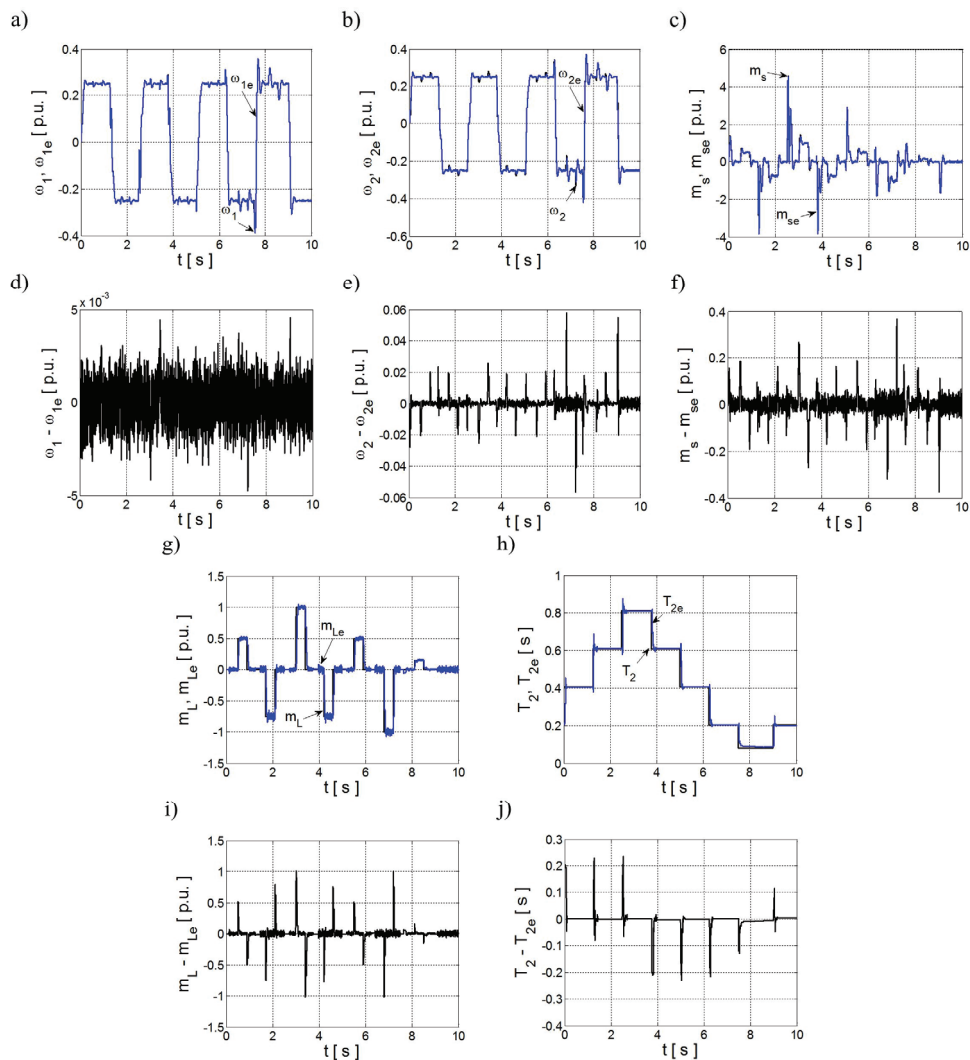
Wartości błędów estymacji zestawiono w tabeli 6. Otrzymane rezultaty wskazują na uzyskanie znaczącej poprawy jakości estymacji wszystkich wielkości. Kolejnym etapem badań była weryfikacja pracy obserwatora w zamkniętej strukturze sterowania. Wyniki tych badań zaprezentowano na rysunku 8, a obliczone wartości błędów estymacji dołączono do tabeli 6. Analiza uzyskanych rezultatów wskazuje na prawidłową pracę struktury sterowania, wykorzystującej zaprojektowany algorytm rozmytego filtru Kalmana, ze względu na brak występowania drgań skrętnych oraz podobieństwo przebiegu prędkości maszyny roboczej do odpowiedzi wielomianu odniesienia. Analizę przeprowadzono zgodnie z metodologią przedstawioną w [11].




Rys. 5. Przebiegi sygnałów wejściowych NRFK i RFK: momentu elektromagnetycznego (a) oraz prędkości silnika (b)



Rys. 6. Przebiegi rzeczywistych i estymowanych wielkości oraz błędy estymacji: prędkości silnika (a, d), prędkości maszyny roboczej (b, e), momentu skrętnego (c, f), momentu obciążenia (g, i), stałej czasowej maszyny roboczej (h, j) w przypadku pracy NRFK poza strukturą sterowania



Rys. 7. Przebiegi rzeczywistych i estymowanych wielkości oraz błędy estymacji: prędkości silnika (a, d), prędkości maszyny roboczej (b, e), momentu skrętnego (c, f), momentu obciążenia (g, i), stałej czasowej maszyny roboczej (h, j) w przypadku pracy RFK poza strukturą sterowania



Rys. 8. Przebiegi sygnałów wejściowych RFK: momentu elektromagnetycznego (a), prędkości silnika (b) oraz przebiegi wielkości rzeczywistych, estymowanych, błędów estymacji i parametrów układu regulacji: prędkości silnika (c, f), prędkości maszyny roboczej (d, g), momentu skrętnego (e, h), momentu obciążenia (i, l), stałej czasowej maszyny roboczej (j, m), wzmacnień regulatora PI i dodatkowych sprzężeń zwrotnych (k, n) w przypadku pracy RFK w zamkniętej strukturze sterowania

Tabela 6. Zestawienie wartości błędów estymacji dla NRFK i RFK

Metoda	$\delta\omega_1$	$\delta\omega_2$	δm_s	δm_L	δT_2
	[p.u.]	[p.u.]	[p.u.]	[p.u.]	[s]
NRFK – poza strukturą sterowania	0,0008	0,0038	0,0334	0,0557	0,0425
RFK – poza strukturą sterowania	0,0007	0,0027	0,0268	0,0463	0,0101
RFK – w zamkniętej strukturze sterowania	0,0007	0,0027	0,0261	0,0475	0,0174

6. PODSUMOWANIE

W pracy przedstawiono zagadnienia związane z zastosowaniem algorytmów genetycznych do optymalizacji zaproponowanego algorytmu rozmytego filtru Kalmana, pracującego w adaptacyjnej strukturze sterowania układu dwumasowego. Zaprezentowano i opisano obiekt badań oraz jego model matematyczny. Scharakteryzowano algorytmy genetyczne wykorzystane w przedstawionych procesach optymalizacyjnych. Wyniki ich działania zweryfikowano poprzez ocenę pracy klasycznego algorytmu filtru Kalmana oraz rozmytego filtru Kalmana w otwartej strukturze sterowania, wykorzystujących wartości współczynników dobrane za pomocą algorytmów genetycznych. Uzyskano znaczącą poprawę jakości estymacji wszystkich wielkości wyjściowych rozmytego filtru Kalmana, w porównaniu do klasycznego algorytmu. Kolejno algorytm ten poddano testom pracy w zamkniętej strukturze sterowania. Analiza wyników badań pozwala na wyciągnięcie następujących wniosków:

- Zastosowanie algorytmów genetycznych do optymalizacji rozmytego filtru Kalmana, pracującego w adaptacyjnej strukturze sterowania układu dwumasowego, pozwala na uzyskanie zadowalających wyników pracy obserwatora, zarówno w otwartej, jak i zamkniętej strukturze sterowania.
- Przy zastosowaniu omawianych algorytmów należy zwrócić szczególną uwagę na dobór postaci funkcji celu.
- Przyjęcie odpowiednich nastaw algorytmów oraz ograniczeń obszarów poszukiwań prowadzi do skrócenia ich czasu pracy oraz poprawy wyznaczania najlepszych rozwiązań.

Praca Finansowana Przez Narodowe Centrum Nauki W Ramach Projektu: 'Odporne Estymatory Zmiennych Stanu I Parametrów Układu Napędowego Z Połączeniem Sprężystym', Umo-2011/01/B/St7/03500. 2011-2014.

LITERATURA

- [1] BIAŁOŃ T., PASKO M., *Wielokryterialny dobór parametrów proporcjonalnego obserwatora strumieni magnetycznych silnika indukcyjnego przy wykorzystaniu algorytmu genetycznego*, Zeszyty Problemowe BOBRME-KOMEL – Maszyny Elektryczne, nr 91, 2011, 51–54.
- [2] DRÓŹDŹ K., SZABAT K., *Zastosowanie rozmytego filtru Kalmana w adaptacyjnej strukturze sterowania układu dwumasowego*, XI Konferencja Naukowa Sterowanie w Energoelektronice i Napędzie Elektrycznym, SENE 2013: Łódź, 20–22.11.2013, Wydawnictwo Politechniki Łódzkiej, 2013, 1–6.
- [3] HIRVONEN M., PYRHÖNEN O., HANDROOS H., *Adaptive nonlinear velocity controller for a flexible mechanism of a linear motor*, Mechatronics, Vol. 16, No. 5, 2006, 279–290.
- [4] ITOH D., IWASAKI M., MATSUI N., *Optimal design of robust vibration suppression controller using genetic algorithms*, IEEE Transaction on Industrial Electronics, Vol. 51, No. 5, 2004, 947–953.
- [5] LOW K.S., WONG T.S., *A multiobjective genetic algorithm for optimizing the performance of hard disk drive motion control system*, IEEE Transaction on Industrial Electronics, Vol. 43, No. 3, 2007, 1716–1725.
- [6] MICHAŁEWICZ Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
- [7] ORŁOWSKA-KOWALSKA T., *Metody sztucznej inteligencji w identyfikacji, estymacji zmiennych stanu i sterowaniu napędów elektrycznych*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, Vol. 58, Nr 25, 2005, 109–133.
- [8] SERKIES P.J., SZABAT K., *Adaptacyjny filtr Kalmana dla układu napędowego z połączeniem sprężystym*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, Studia i Materiały, Vol. 66, Nr 32, 2012, 118–124.
- [9] SZABAT K., ORŁOWSKA-KOWALSKA T., *Optimal design of the extended Kalman filter for the two-mass system using genetic algorithm*, Archive of Electrical Engineering, Vol. 55, nr. 3/4, 2006, 237–254.
- [10] SZABAT K., ORŁOWSKA-KOWALSKA T., *Performance Improvement of Industrial Drives With Mechanical Elasticity Using Nonlinear Adaptive Kalman Filter*, Transaction on Industrial Electronics, Vol. 55, No. 3, 2008, 1075–1084.
- [11] SZABAT K., *Struktury sterowania elektrycznych układów napędowych z połączeniem sprężystym*, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej, nr 61, Wrocław 2008.
- [12] XIANGWU Y., YANG Y., QI G., HECHUAN Z., WEI Q., *Electric vehicle battery SOC estimation based on fuzzy Kalman filter*, 2nd International Symposium on Instrumentation and Measurement, Sensor Network and Automation (IMSNA), 2013, 863–866.
- [13] YADAI AH N., SRIKANTH T., RAO V.S., *Fuzzy Kalman Filter based trajectory estimation*, 11th International Conference on Hybrid Intelligent Systems (HIS), 2011, 566–571.
- [14] ZHEN D., LEUNG H., CHAN K., *Model-set adaptation using a fuzzy Kalman filter*, Proceedings of the Third International Conference on Information Fusion, FUSION 2000, 2000, Vol. 1, p. MOD2/3-MOD2/9

APPLICATION OF THE GENETIC ALGORITHMS FOR OPTIMIZATION
OF THE FUZZY KALMAN FILTER

This paper deals with a problem of a fuzzy Kalman filter optimization for an adaptive control structure of a two-mass drive system. In the introduction section of this paper modern control structures of electrical drives with elastic joint are discussed. For their application state variables estimation of a dynamic object are required. A particular attention is given to the observers based on the Kalman filter

theory. Additionally, the problematic aspects of the observer applying design by using genetic algorithm are considered. Moreover, the remainder of the paper is organized as follows. First, the object of research and its mathematical model are described. Subsequently, genetic algorithms are discussed. Next, the optimization process of the fuzzy Kalman filter using genetic algorithms is presented. The simulation results of the drive performance in a open and closed-loop control structure are shown.