

**LIDIA JACKOWSKA-STRUMIŁŁO****JACEK KUCHARSKI**Wydział Elektrotechniki, Elektroniki, Informatyki i Automatyki  
Politechnika Łódzka**METODY SZTUCZNEJ INTELIGENCJI  
W MODELOWANIU I IDENTYFIKACJI  
OBIEKTÓW ELEKTROTERMICZNYCH**Recenzent: **dr hab. inż. Marek Orzyłowski**

Maszynopis dostarczono: 1. 10. 2010

*W pracy przedstawiono zastosowanie metod sztucznej inteligencji do modelowania i identyfikacji wybranych obiektów elektrotermicznych. Zastosowano sztuczne sieci neuronowe do modelowania i identyfikacji nieliniowych własności dynamicznych dwóch typów rezystancyjnych czujników Pt 100 w osłonie umieszczonych w oleju silikonowym. Stosowano dwuwarstwowe sieci perceptronowe oraz sieci rekurencyjne. Zaproponowano także rozmyte podejście do modelowania wybranej klasy obiektów cieplnych – rezystancyjnych pieców komorowych. W szczególności uwzględniono rozłożony charakter parametrów tego typu obiektów i zaproponowano rozwiązanie, które umożliwia uwzględnienie w modelu zmian parametrów dynamicznych obiektu wynikających ze zmian stopnia nasycenia cieplnego warstw izolacyjnych. Rozważania teoretyczne zweryfikowano na drodze symulacyjnej i eksperymentalnej, dowodząc skuteczności proponowanych metod dla rozważanych klas obiektów, a ogólność przeprowadzonej analizy wskazuje na możliwość rozszerzenia zakresu zastosowań.*

**1. WPROWADZENIE**

Zagadnienie modelowania obiektów elektrotermicznych jest niezwykle istotne przy projektowaniu układów ich sterowania. Klasyczny model

analityczny obiektu budowany jest na podstawie praw termodynamiki (wiedza 'a priori') oraz danych eksperymentalnych (wiedza 'a posteriori'). Do wyznaczenia parametrów modelu wykorzystywane są różne metody identyfikacji, z których największe znaczenie praktyczne mają metody identyfikacji *on-line* i *in situ*. Metody te mogą być stosowane w ograniczonym zakresie temperatur, i w stałych warunkach pracy, w których właściwości obiektu mogą być opisane modelem liniowym i stacjonarnym. W innych warunkach klasyczne metody modelowania i identyfikacja są niewystarczające. W szerokim zakresie temperatur obiekty elektrotermiczne wykazują nieliniowe właściwości statyczne i dynamiczne. Dotyczy to zarówno różnego typu urządzeń grzejnych jak i czujników temperatury. W pracy przedstawiono zastosowanie sztucznych sieci neuronowych do modelowania i identyfikacji nieliniowych własności dynamicznych rezystancyjnych czujników temperatury. Zaproponowano także rozmyte podejście do modelowania wybranej klasy obiektów cieplnych – rezystancyjnych pieców komorowych. Wykorzystanie zbiorów rozmytych i logiki rozmytej umożliwia wprowadzenie do modelu nieprecyzyjnych, ale intuicyjnie zrozumiałych pojęć: „stała czasowa początkowa” i „stała czasowa nasycenia”, przy zachowaniu stosunkowo prostej struktury modelu bazowego (człon inercyjny I-go rzędu).

## 2. MODELOWANIE WŁASNOŚCI DYNAMICZNYCH CZUJNIKÓW TEMPERATURY

Własności dynamiczne czujników temperatury zależą od wielu parametrów związanych z ich budową i warunkami pracy, takimi jak: rodzaj ośrodka, w którym umieszczony jest czujnik, oraz jego temperatura, wilgotność, ciśnienie, prędkość przepływu, itp. [1]. Ze względu na dużą różnorodność czynników wpływających na dynamikę czujnika oraz złożoność problemu, w praktyce stosowane są przybliżone, uproszczone modele czujników o ściśle określonym i ograniczonym zakresie stosowalności. Stopień złożoności modelu zależy od funkcji, jaką dany model ma spełniać.

### 2.1. Modele liniowe

Rozważmy rezystancyjny czujnik temperatury w osłonie w kształcie walca dostatecznie długiego, aby można było założyć, że wymiana ciepła zachodzi jedynie w kierunku promienia. Załóżmy, że każda z warstw czujnika wykonana jest z materiału jednorodnego i izotropowego, a pojemność cieplna pomiędzy częścią czułą czujnika a jego osią jest pomijalnie mała. Czujnik jest zanurzony całkowicie w ośrodku badanym, a jego pojemność cieplna jest mała w stosunku do pojemności cieplnej ośrodka. Wówczas w małym zakresie temperatur

mierzonych dla niezmiennych warunków pracy czujnika można opisać jego własności dynamiczne modelem liniowym. Najczęściej stosowanym modelem jest transmitancja operatorowa cieplnego stopnia przetwarzania, która dla wielowarstwowego czujnika temperatury określona wzorem [2]:

$$G_T(s) = \frac{\Theta_T(s)}{\Theta_O(s)} = \frac{1}{\prod_{i=1}^n (1 + sN_i)}, \quad (1)$$

gdzie:  $\Theta_O(s)$  – transformata Laplace'a zmiany temperatury ośrodka ponad jego temperaturę początkową  $T_O$ ,  $\Theta_T(s)$  – transformata Laplace'a zmiany temperatury części czulej czujnika spowodowanej zmianą temperatury ośrodka  $\Theta_O$ , przy stałej mocy prądu przepływającego przez czujnik,  $N_i$  – stałe czasowe czujnika, dla  $i = 1, 2, \dots, n$ .

W szerszym zakresie temperatur własności termofizyczne materiałów konstrukcyjnych czujnika i otaczającego go ośrodka są funkcją temperatury, a modele liniowe nie zapewniają wystarczającej dokładności.

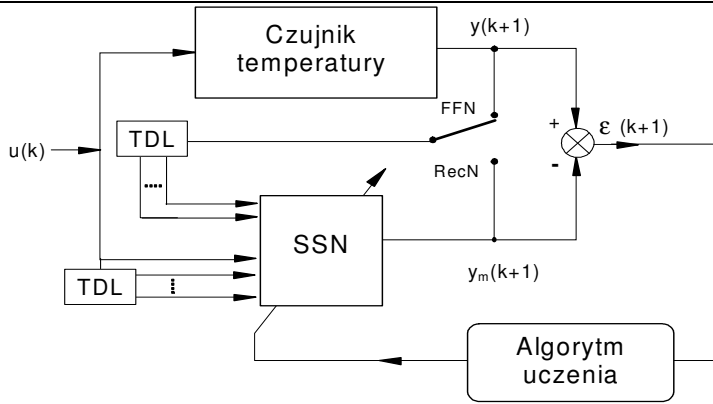
## 2.2. Modelowanie własności dynamicznych czujników za pomocą SNN

Nieliniowy model dynamiczny czujnika temperatury można opisać równaniem (2), które jest ogólnym modelem dyskretnym jednowymiarowego obiektu dynamicznego [3]. Jest to model predykcyjny. Wartość sygnału  $y$  na wyjściu czujnika w chwili  $k+1$  jest określona na podstawie kolejnych  $n$  wartości sygnału  $y$  i  $m$  wartości sygnału wejściowego  $u$  z chwil poprzednich.

$$y(k+1) = f[y(k), y(k-1), y(k-n+1), u(k), u(k-1), u(k-m+1)], \quad (2)$$

gdzie:  $y$  – sygnał wyjściowy, tj. zmiana temperatury części czulej czujnika  $\Theta_T$ ,  $u$  – sygnał wejściowy, tj. zmiana temperatury ośrodka  $\Theta_O$ ,  $f$  – funkcja nieliniowa.

Idea identyfikacji własności dynamicznych czujników temperatury z zastosowaniem sztucznych sieci neuronowych została przedstawiona schematycznie na rysunku 1.



Rys. 1. Identyfikacja obiektu dynamicznego za pomocą sztucznej sieci neuronowej

Sieci neuronowe stosowane do modelowania obiektów dynamicznych można podzielić na dwie główne klasy [3]:

- sieci jednokierunkowe (ang. *FeedForward Networks* – FFN), w których przepływ sygnału odbywa się w jednym kierunku od warstwy neuronów wejściowych poprzez tzw. neurony ukryte, do warstwy neuronów wyjściowych,
- sieci rekurencyjne (ang. *Recurrent Neural Networks* – RNN), w których występują sprzężenia zwrotne tworzące co najmniej jedną, zamkniętą pętlę przepływu sygnału w sieci.

Aby uzyskać możliwość modelowania dynamicznego w sieci jednokierunkowej stosuje się człony opóźniające na wejściu układu, które stanowią tzw. linię opóźniającą z odczepami (ang. *Tapped Delay Line* – TDL). Wektory sygnałów wejściowych i wyjściowych obiektu rozszerzone o wartości sygnału w chwilach poprzednich doprowadzane są do wejścia sieci w procesie jej uczenia. Jest to tzw. szeregowo-równoległa metoda identyfikacji (rys. 1) [3]. Utworzony w ten sposób model dynamiczny jest modelem predykcyjnym.

Zgodnie z teorią systemów nieliniowymi sieci rekurencyjne są układami dynamicznymi. Można je stosować do modelowania obiektów o nieliniowych własnościach dynamicznych. W tym przypadku wykorzystywana jest metoda równoległa identyfikacji. Reguły projektowania sieci rekurencyjnych są jednakże znacznie bardziej skomplikowane od metod projektowania sieci jednokierunkowych. Często występują problemy związane z niestabilnością sieci i brakiem zbieżności algorytmu uczenia sieci [4].

Dla sieci wielowarstwowych jednokierunkowych istnieją skuteczne algorytmy ich uczenia [4]. Z tego względu sieci jednokierunkowe i szeregowo-równoległa metoda identyfikacji są znacznie częściej i chętniej stosowane do identyfikacji obiektów dynamicznych niż sieci rekurencyjne.

W przeprowadzonych badaniach do identyfikacji własności dynamicznych czujników temperatury zastosowano szeregowo-równoległą metodę identyfikacji i sieci jednokierunkowe typu perceptron wielowarstwowy (ang. *Multi-Layer Perceptron* – MLP). Sieci uczono za pomocą algorytmu wstecznej propagacji błędów oraz metody optymalizacyjnej Levenberga-Marquardta dla średniokwadratowej funkcji celu [4]. Do modelowania dynamiki czujników stosowano sieci FFN typu MLP oraz sieci rekurencyjne RNN otrzymane z sieci MLP poprzez zamknięcie sprzężeń zwrotnych (rys. 1) [5]. Do uczenia sieci modelujących nieliniowe właściwości czujników w rozprawie zaproponowano sygnał złożony z serii wymuszeń skokowych narastających i opadających o różnych amplitudach [5].


## 2.3. Badania eksperymentalne

Badania właściwości dynamicznych czujników przeprowadzono w oleju silikonowym o dużej lepkości przeznaczonym do wypełniania termostatów i innych urządzeń elektrotermicznych. Obiektami badań były dwa czujniki Pt 100 firmy KFAP:

- czujnik TOPI 61 firmy KFAP o wymiarach: długość  $l = 175$  mm, średnica  $d = 6$  mm, kl. B, zakres  $(-200 \div 600)$  °C, zaprojektowany specjalnie do pomiarów dynamicznych;
- czujnik TOPC4 firmy KFAP o danych:  $l = 115$  mm,  $d = 4$  mm, kl. B,  $(-50 \div 200)$  °C, stanowiący wyposażenie miernika cyfrowego, przeznaczony do pomiarów temperatury cieczy i gazów.

### 2.3.1. Przygotowanie danych do uczenia sieci

Dla badanych czujników przeprowadzono kilka serii eksperymentów identyfikacji metodą wymuszenia zewnętrznego skokowego. Badania przeprowadzono w termostacie uniwersalnym w intensywnie mieszanym oleju silikonowym dla różnych wartości amplitudy skoku temperatury. Czujniki były chłodzone w wodzie z lodem do temperatury 0 °C, osuszane, a następnie zanurzone w termostacie wypełnionym olejem o wyższej temperaturze. Odpowiedzi czujników na wymuszenie skokowe były rejestrowane w systemie komputerowym. Dla każdego czujnika spośród kilkunastu wymuszeń narastających i opadających (rys. 2) dwa posłużyły do budowy zbioru testowego, a pozostałe do budowy zbioru uczącego dla sieci.



Rys. 2. Zbiór danych treningowych do uczenia i testowania sieci: a) dla czujnika TOPC 4, b) dla czujnika TOPI 6. Linia przerywaną oznaczono sygnał wymuszenia, a linią ciągłą odpowiedź czujnika [5]

### 2.3.2. Modelowanie dynamiki czujników za pomocą SSN

Do modelowania własności dynamicznych czujników stosowano dwuwarstwowe sieci jednokierunkowe typu MLP, oraz sieci rekurencyjne o strukturze  $(v-x-1)$ , gdzie  $v$  oznacza liczbę wejść,  $x$  – liczbę neuronów o sigmoidalnej funkcji aktywacji w warstwie ukrytej, a 1 – jedno wyjście. Sieci jednokierunkowe posłużyły do budowy modeli predykcyjnych. Sieci rekurencyjne, otrzymano z sieci MLP poprzez zamknięcie sprzężeń zwrotnych [6]. Przebadano kilkaset sieci o różnej liczbie wejść i neuronów w warstwie ukrytej. Sieci uczono w sposób cykliczny zapisując do pliku parametry dla każdej z sieci oraz błędy obliczone dla danych treningowych i testowych. Głównym kryterium wyboru najlepszej struktury sieci MLP i RNN było minimum pierwiastka błędu średniokwadratowego  $E_{sk}$  dla danych testowych, ale porównywano też błędy maksymalne  $E_{max}$ , błędy średnie z wartości bezwzględnych  $E_{abs}$ , błędy średnie  $E_{sr}$  oraz błąd  $E_{sk}$  dla danych treningowych. Zestawienie błędów modelowania dla kilku wybranych sieci zamieszczono w tabeli 1 [6].

Tabela 1. Błędy modelowania własności dynamicznych czujników temperatury w zakresie  $(0-100)^{\circ}\text{C}$  przy zastosowaniu sieci MLP i sieci rekurencyjnych


Nr	czujnik	struktura sieci	$N_{Ep}$	d. treningowe	dane testowe				
				$E_{sk}$	$E_{sk}$	$E_{max}$	$E_{abs}$	$E_{sr}$	
			-	K	K	K	K	K	
1	TOPC 4	MLP (3-6-1)	7	0,11	0,09	0,47	0,07	-0,03	
2	TOPC 4	MLP (5-20-1)	5	0,08	0,07	0,49	0,03	-0,004	
3	TOPI 61	MLP (3-4-1)	6	0,33	0,21	0,97	0,14	0,02	

4	TOPI 61	MLP (5-22-1)	7	0,13	0,11	0,99	0,04	0,006
5	TOPC 4	RNN (5-20-1)	5	0,08	0,57	1,8	0,42	-0,03
6	TOPI 61	RNN (3-4-1)	6	0,33	1,4	7,3	1,1	0,36

$E_{sk}$  – błąd średni kwadratowy,  $E_{max}$  – błąd maksymalny,  $E_{abs}$  – błąd średni bezwzględny,  $E_{sr}$  – błąd średni,  $N_{Ep}$  – liczba taktów uczenia sieci

Dla struktur sieci (3- $x$ -1) wektor sygnałów wejściowych składa się z aktualnej wartości sygnału wejściowego  $u(k)$  oraz z aktualnej i przeszłej próbki sygnału wyjściowego  $y(k)$  i  $y(k-1)$ . Dla struktur (5- $x$ -1) wektor sygnałów wejściowych składa się z aktualnej i przeszłej próbki sygnału wejściowego  $u(k)$  i  $u(k-1)$ , z aktualnej wartości sygnału wyjściowego  $y(k)$  oraz dwóch próbek z przeszłości  $y(k-1)$  i  $y(k-2)$ . Wartość sygnału na wyjściu czujnika  $y(k+1)$  jest obliczana na wyjściu sieci zgodnie z równaniem (2). Obliczone błędy modelowania dla sieci RNN w tabeli 1 są większe niż odpowiadające im błędy dla sieci jednokierunkowych MLP.

Na rysunku 3 przedstawiono wyniki modelowania własności dynamicznych czujników za pomocą sieci MLP dla danych testowych.



Rys. 3. Modelowanie własności dynamicznych czujników za pomocą sieci dwuwarstwowych typu MLP; linia przerywana – sygnał wymuszający  $u(t)$ , linia ciągła – sygnał na wyjściu czujnika  $y(t)$ , linia kropkowana – sygnał na wyjściu sieci  $y_{sim}(t)$ :  
a) czujnik TOPC 4, sieć (5-20-1); b) czujnik TOPI 6 sieć (3-4-1) [6]

Przebiegi sygnałów na wyjściu sieci prawie idealnie pokrywają się z sygnałami na wyjściu czujników, co potwierdza dobre własności generalizacyjne sieci. Wyniki zamieszczone w tabeli 1 i na rysunku 3 potwierdziły, iż zaprojektowane sieci typu FFN MLP pozwalają na modelowanie własności dynamicznych badanych czujników z dużą dokładnością w całym zakresie temperatur, w którym przeprowadzone zostały eksperymenty identyfikacji, tzn. (0-100 oC).

### 3. ROZMYTE MODELOWANIE WŁASNOŚCI DYNAMICZNYCH REZYSTANCYJNYCH PIECÓW KOMOROWYCH

W projektowaniu układów regulacji temperatury wielu typów obiektów elektrotermicznych, w tym rezystancyjnych pieców komorowych, najczęściej wykorzystuje się uniwersalne modele parametryczne, wśród których ważną pozycję zajmuje model inercyjny I-go rzędu z czasem opóźnienia, wyrażony transmitancją:

$$G(s) = \frac{\vartheta(s)}{P(s)} = \frac{K}{1 + sN} e^{-sL} \quad (3)$$

gdzie:  $\vartheta(s)$ ,  $P(s)$  – transformaty temperatury i mocy grzejnej,  
 $K$ ,  $N$ ,  $L$  – wzmacnienie, stała czasowa i opóźnienie obiektu.

Model (3) jest uproszczonym opisem zjawisk zachodzących w rzeczywistym obiekcie, który w istocie jest nieliniowym układem o parametrach rozłożonych, co wymagałoby stosowania nieliniowych równań różniczkowych cząstkowych [7]. Niekiedy uproszczenia te prowadzą do znacznych rozbieżności rzeczywistych przebiegów temperatury w porównaniu z przebiegami wynikającymi z tego modelu [8, 9], co sugerowało by stosowanie modeli wyższych rzędów. Zaletą jednak modelu (3) jest - oprócz prostoty - łatwa interpretacja występujących w jego opisie parametrów [10]. Wykorzystanie technik inteligencji obliczeniowej otwiera możliwość dokładniejszego modelowania własności obiektów elektrotermicznych za pomocą prostych strukturalnie modeli parametrycznych typu (3), co stanowi rozsądny kompromis pomiędzy złożonością i adekwatnością opisu.

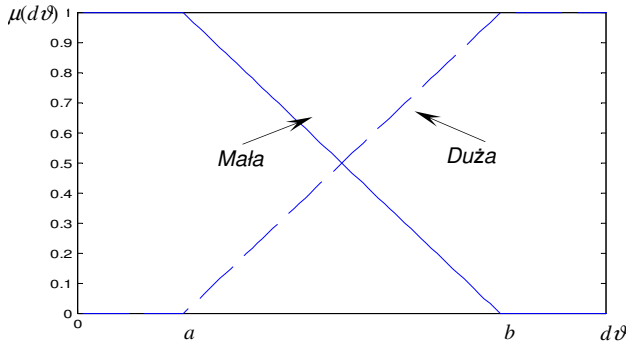
W odniesieniu do analizowanej klasy obiektów elektrotermicznych - rezystancyjnych pieców komorowych - funkcjonują w praktyce opisowe pojęcia „stałej czasowej początkowej” oraz „stałej czasowej nasycenia” [10], które są intuicyjnie kojarzone ze zmiennym stopniem nasycenia cieplnego elementów konstrukcyjnych obiektów. Trzeba jednak zauważyć, że rozróżnienie tak określonych dwóch stałych czasowych ma charakter nieostry, co sugeruje możliwość wykorzystania teorii zbiorów rozmytych i logiki rozmytej w rozwiązaniu postawionego problemu [11, 12]. Dzięki takiemu podejściu można bowiem w jednej strukturze modelu uwzględnić dwa człony inercyjne I-go rzędu o różnych stałych czasowych: „początkowej” i „nasycenia”, tak aby przejście od jednego modelu do drugiego miało charakter płynny - zależnie od stopnia nasycenia cieplnego warstw izolacyjnych.

Warto zauważyć, że głównym źródłem opóźnienia czasowego  $L$  jest czujnik temperatury [10], tak więc analizując zjawiska zachodzące w wymurowaniu



pieca można założyć bezinercyjność czujnika, co upoważnia przyjęcie w rozważaniach  $L=0$ .

Rozmytą ocenę stanu cieplnego obiektu można wyrazić analizując szybkość zmian jego temperatury  $d\vartheta$  w trakcie odpowiedzi skokowej. Wiadomo bowiem, że stan bliski nasyceniu charakteryzuje się małymi zmianami temperatury, podczas gdy w stanach dynamicznych - kiedy obiekt jest w stanie cieplnym nienasyconym - temperatura ulega znacznym zmianom. Dla rozróżnienia tych dwóch stanów należy więc w przestrzeni zmian temperatury  $d\vartheta$  zdefiniować zbiory rozmyte np. *Mała* i *Duża* (rys.4).



$$\mu_{Mała}(d\vartheta) = \begin{cases} 1 & \text{dla } d\vartheta \leq a \\ \frac{b-d\vartheta}{b-a} & \text{dla } a < d\vartheta \leq b \\ 0 & \text{dla } d\vartheta > b \end{cases}$$

$$\mu_{Duża}(d\vartheta) = \begin{cases} 0 & \text{dla } d\vartheta \leq a \\ \frac{d\vartheta-a}{b-a} & \text{dla } a < d\vartheta \leq b \\ 1 & \text{dla } d\vartheta > b \end{cases}$$

Rys. 4. Zbiory rozmyte *Mała* i *Duża* w przestrzeni zmian temperatury  $d\vartheta$

Realizacja rozmytego modelu obiektu cieplnego sprowadza się do implementacji systemu Takagi-Sugeno-Kanga (TSK) (np. [13]) uwzględniającego dwie wartości stałej czasowej: początkową  $N_p$  i nasycenia  $N_n$ , co wykorzystując dyskretną formę odpowiedzi obiektu można wyrazić jako:

$$\begin{aligned} \text{JEŻELI } d\vartheta \text{ jest } Duża \text{ TO } \vartheta_k &= w_k \theta_p \\ \text{JEŻELI } d\vartheta \text{ jest } Mała \text{ TO } \vartheta_k &= w_k \theta_n \end{aligned} \quad (4)$$

przy czym:  $\theta_p = \left[ \frac{K\Delta}{N_p + \Delta}, \frac{N_p}{N_p + \Delta} \right]^T$ ,  $\theta_n = \left[ \frac{K\Delta}{N_n + \Delta}, \frac{N_n}{N_n + \Delta} \right]^T$ ,  $w_k = [P_k, \vartheta_{k-1}]$ .


Przyjmując typowe sposoby realizacji poszczególnych operacji logicznych w strukturze (4) (np. [13]) można wyrazić ostateczną postać modelu rozmytego:

$$\vartheta_k = w_k \left[ \mu_{Dzi\u015b}(\vartheta_k) \cdot \theta_p + \mu_{Mala}(\vartheta_k) \cdot \theta_n \right] \quad (5)$$

Estymacja parametr\u00f3w r\u00f3wnania (5) metod\u0105 najmniejszej sumy kwadrat\u00f3w wymaga rozwi\u0105zania nast\u0119puj\u0105cego problemu:

$$\{a, b, N_p, N_n\} = \operatorname{argmin} \sum_{k=1}^n \left( \vartheta_k - w_k \left[ \mu_{Dzi\u015b}(\vartheta_k) \cdot \theta_p + \mu_{Mala}(\vartheta_k) \cdot \theta_n \right] \right)^2 \quad (6)$$

W celu weryfikacji zaproponowanego rozwi\u0105zania por\u00f3wnano przebieg odpowiedzi skokowej uzyskany dla modelu \u015bciany pieca uwzgl\u0119dniaj\u0105cego roz\u0142\u00f3zony charakter parametr\u00f3w oraz modelu rozmytego (rys.5). Parametry modelu rozmytego wyznaczono zgodnie z (6).



Rys. 5. Odpowied\u017c skokowa modelu o parametrach roz\u0142\u00f3zonych (linia przerywana) i modelu rozmytego (linia ci\u0105g\u0142a)

Jak wida\u0107 „rozmyte po\u0142\u0105czenie” dw\u00f3ch cz\u0142on\u00f3w inercyjnych I rz\u0119du umo\u017cliwia dobre odwzorowanie w\u0142asno\u015bci dynamicznych pieca zar\u00f3wno w pocz\u0105tkowej fazie odpowiedzi, jak te\u017c w stanie nasycenia cieplnego izolacji. Jednocześnie zaproponowany model zachowuje prostot\u0119 element\u00f3w sk\u0142adowych oraz \u0142atw\u0105 interpretowaln\u00f3\u015b\u0107 parametr\u00f3w.

## 4. PODSUMOWANIE

W artykule przedstawiono wybrane sposoby wykorzystania metod inteligencji obliczeniowej dla potrzeb modelowania urządzeń elektrotermicznych i czujników temperatury. W szczególności omówiono zastosowanie SSN do modelowania i identyfikacji własności dynamicznych elektrycznych czujników termometrycznych. W szerokim zakresie temperatur klasyczne modele liniowe czujników są niewystarczające, a SSN umożliwiają modelowanie nieliniowych własności dynamicznych czujników i są dla nich korzystniejszą alternatywą. Przedstawiono także wykorzystanie logiki rozmytej w modelowaniu rezystancyjnego pieca komorowego, który w rzeczywistości jest nieliniowym obiektem o parametrach rozłożonych. Rozmyte podejście do modelowania tego typu obiektów pozwala uzyskać model posiadający zdolność elastycznego dopasowania się do fazy pracy urządzenia elektrotermicznego.

## LITERATURA

- [1] Michalski L., Eckersdorf K., Kucharski J. (1998): *Termometria. Przyrządy i metody*. Politechnika Łódzka, Łódź.
- [2] Kerlin T.W., Miller L.F., Hashemian H.M. (1978): *In-situ* response time testing of platinum resistance thermometers. *ISA Transactions*, Vol. 17, No. 4, pp.71-88.
- [3] Narendra K.S., Parthasarathy K. (1990): Identification and control of dynamical systems using neural networks, *IEEE Transactions on Neural Networks*, Vol. 1, No. 1, pp.4-27.
- [4] Korbicz J., Obuchowicz A., Uciński D. (1994): *Sztuczne sieci neuronowe, podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
- [5] Jackowska-Strumiłło L. (2004): ANN based modelling and correction in dynamic temperature measurements in *Artificial Intelligence and Soft Computing– ICAISC 2004*, (Eds. Rutkowski L., Siekman J., Tadeusiewicz R., Zadeh L.), Springer-Verlag, Berlin Heidelberg, s. 1124-1129.
- [6] Jackowska-Strumiłło L. (2009): *Modelowanie i korekcja wybranych systemów nieliniowych z zastosowaniem metod analitycznych i aproksymatorów neuronowych*, Rozprawa habilitacyjna, Zeszyty Naukowe, Politechnika Łódzka, 1043, Łódź.
- [7] Jakob M. (1958): *Heat transfer*. John Wiley & Sons, NY.
- [8] Łobodziński W. (1987): Wybrane zagadnienia estymacji parametrów uproszczonego modelu matematycznego pieców oporowych komorowych jako obiektów regulacji temperatury. *Prace PIE*, Cz1. z.103/ 1987; cz. 2 z.106 /1988, Warszawa.
- [9] Orzyłowski M., Łobodziński W., Sankowski D. (2001): Identyfikacja obiektów cieplnych metodami czasowymi i częstotliwościowymi dla celów regulacji. *Pomiary Automatyka Kontrola Cz.1: 3/2001*, ss.12-14; cz. 2: 4/2001, s.14-17.

- [10] Michalski L., Kuźmiński K., Sadowski J. (1981): *Regulacja temperatury urządzeń elektrotermicznych*. WNT, Warszawa.
- [11] Sugeno M., Yusukawa T. (1993): A Fuzzy-Logic-Based Approach to Qualitative Modeling. *IEEE Trans. on Fuzzy Systems*, Vol. 1, No. 1, 1993, pp. 7-31.
- [12] Kucharski J. (2008): Fuzzy modeling of chosen electroheat systems. *Przegląd Elektrotechniczny*, 2008, rocznik 84, nr 11, s.189-192.
- [13] Piegat A. (1999): *Modelowanie i sterowanie rozmyte*. EXIT, Warszawa.

## **METODY SZTUCZNEJ INTELIGENCJI W MODELOWANIU I IDENTYFIKACJI OBIEKTÓW ELEKTROTERMICZNYCH**

### **Streszczenie**

W pracy przedstawiono zastosowanie metod sztucznej inteligencji do modelowania i identyfikacji wybranych obiektów elektrotermicznych. Zastosowano sztuczne sieci neuronowe do modelowania i identyfikacji nieliniowych własności dynamicznych dwóch typów rezystancyjnych czujników Pt 100 w osłonie umieszczonych w oleju silikonowym. Stosowano dwuwarstwowe sieci perceptronowe oraz sieci rekurencyjne. Zaproponowano także rozmyte podejście do modelowania wybranej klasy obiektów cieplnych – rezystancyjnych pieców komorowych. W szczególności uwzględniono rozłożony charakter parametrów tego typu obiektów i zaproponowano rozwiązanie, które umożliwia uwzględnienie w modelu zmian parametrów dynamicznych obiektu wynikających ze zmian stopnia nasycenia cieplnego warstw izolacyjnych. Rozważania teoretyczne zweryfikowano na drodze symulacyjnej i eksperymentalnej, dowodząc skuteczności proponowanych metod dla rozważanych klas obiektów, a ogólność przeprowadzonej analizy wskazuje na możliwość rozszerzenia zakresu zastosowań.

Politechnika Łódzka  
Katedra Informatyki Stosowanej