

Romuald ZIELONKO, Michał KOWALEWSKIPOLITECHNIKA GDAŃSKA, WYDZIAŁ ELEKTRONIKI, TELEKOMUNIKACJI I INFORMATYKI,
KATEDRA OPTOELEKTRONIKI I SYSTEMÓW ELEKTRONICZNYCH**Nowa, metrologicznie zorientowana sieć neuronowa
i metoda diagnostyki obiektów technicznych****Prof. dr inż. Romuald ZIELONKO**

Absolwent Wydziału Łączności Politechniki Gdańskiej. Tytuł profesora uzyskał w 1990 r. Autor ponad 160 publikacji, 19 patentów i jednej książki z zakresu metrologii i diagnostyki elektronicznej. Promotor 10 ukończonych i 4 otwartych przewodów doktorskich. Kierownik Katedry Metrologii i Systemów Elektronicznych w latach 1991-2006. Członek Komitetu Metrologii i Aparatury Naukowej PAN. Redaktor naczelny obcojęzycznego kwartalnika PAN Metrology and Measurement Systems.



e-mail: zielonko@eti.pg.gda.pl

Streszczenie

W artykule przedstawiono nową, metrologicznie ukierunkowaną sieć neuronową oraz bazującą na niej metodę diagnostyki uszkodzeń parametrycznych układów analogowych, z klasyfikacją neuronową, o zwiększonej odporności na tolerancje elementów układu i niepewności pomiaru. Zaproponowano sieć neuronową z Dwu-centrowymi Radialnymi Funkcjami Bazowymi (DRFB), której walorem jest lepsze odwzorowanie słownika uszkodzeń, poprawa dokładności klasyfikacji i większa odporność na tolerancje, w porównaniu z siecią zawierającą jedno-centrowe radialne funkcje bazowe (RFB). Opisano 2 metody konstrukcji słownika uszkodzeń, w postaci rozproszonych krzywych identyfikacyjnych, wykorzystujące transformację biliniową oraz analizę składowych głównych. Metodę zilustrowano na przykładzie diagnostyki 2 prostych układów analogowych. Może ona być stosowana do diagnozowania innych obiektów technicznych.

Słowa kluczowe: diagnostyka układów analogowych, metody słownikowe, uszkodzenia parametryczne, klasyfikatory neuronowe.

**New, metrologically oriented neural network
and method for technical objects diagnosis****Abstract**

In this paper a new metrologically oriented neural network and method for parametric fault localization and rough identification are presented. The characteristic feature of the network is application of new two-center radial basis functions in the hidden layer. In result, the better classification accuracy, as well as robustness against non-faulty component tolerances and measurement errors has been obtained, in comparison with known Radial Basis Function neural network. Two construction methods of fault dictionary in the form of dispersed identification curves are described: bilinear transformation and principal component analysis methods. The diagnosis method was illustrated on the exemplary 2 analog circuits. It can be used for diagnosis of other technical objects.

Keywords: diagnosis of analog circuits, dictionary methods, soft faults, neural classifiers.

1. Wstęp

Dynamiczny rozwój elektroniki, a zwłaszcza wzrost złożoności i różnorodność układów elektronicznych (dyskretnych, scalonych, pakietów, mikrosystemów) stwarza duże zapotrzebowanie na metody ich diagnostyki na wszystkich poziomach: detekcji, lokalizacji i identyfikacji uszkodzeń, jak też w różnych etapach życia układu: projektowania, prototypowania, produkcji i eksploatacji. Zapotrzebowanie to implikuje duże zainteresowanie badawcze diagnostyką elektroniczną, głównie środkami i metodami diagnozowania analogowych układów elektronicznych (AUE).

Układ elektroniczny, zwłaszcza analogowy, jest z reguły obiektem wieloparametrowym, wysokiego rzędu, modelowanym siecią zawierającą dziesiątki, setki lub tysiące elementów

Mgr inż. Michał KOWALEWSKI

W 2001 roku otrzymał tytuł magistra inżyniera na Wydziale Elektroniki, Telekomunikacji i Informatyki Politechniki Gdańskiej. Obecnie asystent w Katedrze Optoelektroniki i Systemów Elektronicznych Politechniki Gdańskiej. Zainteresowania naukowe: testowanie i diagnostyka analogowych układów elektronicznych z zastosowaniem metod sztucznej inteligencji.



e-mail: Michal.Kowalewski@eti.pg.gda.pl

składowych, dostępną pomiarowo z nielicznych węzłów, często tylko z zacisków we/wy. Z tego względu równania wiążące przestrzeń możliwych pomiarów \mathcal{H}^M z przestrzenią poszukiwanych parametrów \mathcal{H}^P są niezwykle złożone.

Zatem informacja o uszkodzeniach AUE, zwłaszcza parametrycznych, jest w uwikłany sposób ukryta w przestrzeni \mathcal{H}^M i dodatkowo maskowana tolerancjami elementów nieuszkodzonych. Wydobywanie tej informacji wymaga stosowania zaawansowanych, inteligentnych metod pomiarowych i analitycznych. Jest to otwarty problem naukowy, budzący aktualnie duże zainteresowanie na świecie, również z tego względu, że niektóre metody diagnostyki AUE można zastosować do parametrycznej identyfikacji i diagnostyki innych obiektów modelowanych obwodami elektrycznymi.

Istnieje wiele metod diagnostyki AUE o różnej złożoności i przydatności praktycznej, ich klasyfikację i krótką charakterystykę można znaleźć w pracy [1]. Różne są też kryteria klasyfikacji metod. Z punktu widzenia teorii diagnostyki AUE istotny jest, powszechnie uznany w literaturze, podział na metody z *symulacją przedtestową* SBT (ang. Simulation Before Test) i metody z *analizą potestową* SAT (ang. Simulation After Test), wg kryterium kiedy w procesie testowania następuje analiza wyników lub symulacja układu testowanego (UT).

W metodach SAT, matematyczna analiza układu odbywa się *on-line* po wykonaniu pomiarów, stąd duże jest zapotrzebowanie na moc obliczeniową i wydłużenie procesu testowania. W metodach SBT, modelowanie UT i symulacja a priori przewidywanych uszkodzeń odbywa się w trybie *off-line*, przed fizycznym procesem testowania, czego pozytywnym następstwem jest krótki czas testowania, tożsamy lub zbliżony do czasu surowych pomiarów.

Osobną klasę stanowią metody i środki z nadmiarowością układową (nazywane też *hardwerowymi*), do których należą *magistrale testujące* oraz *wbudowane układy testujące* BIST (Built in Self Tester) wymagające wbudowania dodatkowych struktur ułatwiających testowanie.

Najbardziej efektywne w zastosowaniach praktycznych są metody SBT, z których najważniejszą jest *metoda słownikowa*. W odróżnieniu od metod SAT, gdzie wykrywanie uszkodzeń odbywa się w przestrzeni parametrów \mathcal{H}^P , w metodach SBT odbywa się ono w przestrzeni pomiarów \mathcal{H}^M lub przestrzeni składowych głównych (po kompresji pomiarów). Na etapie potestowym wyniki pomiarów porównuje się z *sygnaturami* słownika uszkodzeń za pomocą klasyfikatorów.

Obok klasyfikatorów konwencjonalnych (z euklidesową miarą odległości), rozwijane są obecnie klasyfikatory inteligentne: *neuronowe* i *rozmyte* [2]. Mają one lepsze perspektywy rozwojowe ze względu na lepszą odporność na błędy pomiarów i zdolność tłumienia wpływu tolerancji maskujących uszkodzenia.

W pracy przedstawiono nową, specjalizowaną sieć neuronową ukierunkowaną na zastosowanie w klasyfikatorach neuronowych dla potrzeb diagnostyki AUE i innych obiektów oraz nową metodę

słownikową z klasyfikacją neuronową. Specjalizacja sieci polega na zastosowaniu nowych, dwucentrowych radialnych funkcjach bazowych (DRFB) neuronów w warstwie ukrytej. Są one dopasowane do sygnałów słownika uszkodzeń w postaci rozproszonych krzywych identyfikacyjnych na płaszczyźnie lub w przestrzeniach wielowymiarowych 3D i 4D. Rozproszenie krzywych jest implikowane wpływem tolerancji i niepewności pomiarów.

W dalszej części pracy przedstawiono:

- Dwie niekonwencjonalne metody konstrukcji słownika uszkodzeń w postaci rozproszonych krzywych identyfikacyjnych.
- Nową sieć neuronową DRFB z 2 wariantami dwucentrowych radialnych funkcji bazowych.
- Dwa przykłady diagnostyki uszkodzeń układów analogowych ilustrujące nową metodę słownikową.

2. Idea metody i konstrukcje słownika uszkodzeń

Koncepcja proponowanej metody diagnostyki została oparta na 2 następujących założeniach:

1. Niekonwencjonalna konstrukcja słownika uszkodzeń w postaci rodziny rozproszonych krzywych identyfikacyjnych, rozmieszczonych na płaszczyźnie lub w wielowymiarowych przestrzeniach 3D i 4D. Takie postacie sygnałów słownika uszkodzeń posiadają 2 zalety: uwzględniają maskujący wpływ tolerancji i umożliwiają nie tylko lokalizację, lecz także zgrubną identyfikację uszkodzeń.
2. Zastosowanie specjalizowanego klasyfikatora neuronowego, dopasowanego do rozproszonych krzywych identyfikacyjnych, opartego na opracowanej w zespole, metrologicznie zorientowanej sieci neuronowej z dwucentrowymi radialnymi funkcjami bazowymi, nazywanej siecią DRFB. Sieć ta dobrze odwzorowuje słownik w postaci rozproszonych krzywych identyfikacyjnych i odznacza się zminimalizowaną liczbą neuronów.

W konstrukcji słownika uszkodzeń wykorzystano 2 różne, komplementarne wobec siebie podejścia, pierwsze - oparte na analitycznej metodzie transformacji biliniowej (TB) i drugie - oparte na statycznej metodzie analizy składowych głównych (ASG).

2.1. Słownik uszkodzeń konstruowany metodą transformacji biliniowej

Podstawą tej metody jest biliniowy opis funkcji układowych względem pojedynczego parametru p_i

$$F_i^{(l)}(j\omega, p_i) = \frac{A_i^{(l)}(j\omega)p_i + B_i^{(l)}(j\omega)}{C_i^{(l)}(j\omega)p_i + D_i^{(l)}(j\omega)}, \quad (1)$$


przy spełnieniu warunku $A_i B_i - B_i C_i \neq 0$.

Funkcje takie dla różnych parametrów p_i można wyznaczyć analitycznie i wykreślić na płaszczyźnie zespolonej $\text{Re}(F^{(l)})$, $\text{Im}(F^{(l)})$ w postaci krzywych przecinających się w punkcie nominalnym, nazywanych krzywymi identyfikacyjnymi. Na krzywe te mogą być naniesione skale wartości p_i . Na rys. 1 i 2 pokazano przykład prostego układu i odpowiadającą mu rodzinę krzywych identyfikacyjnych. Przypisanie punktu pomiarowego do odpowiedniej krzywej umożliwia lokalizację pojedynczych uszkodzeń parametrycznych, a jego położenie na krzywej umożliwia identyfikację uszkodzeń.

W przypadku realnych układów z tolerancjami elementów, metodą Monte Carlo można symulować różne wartości tolerancji i uzyskać w ten sposób rozproszone krzywe identyfikacyjne.


Istnieje metoda [3] optymalnego doboru częstotliwości zapewniającego maksymalne oddalenie od siebie krzywych identyfikacyjnych i normalizację zbliżającą ich długość i skalę. Jednak nawet dla optymalizowanych częstotliwości i normalizacji krzywych niektóre z nich leżą zbyt blisko siebie i wręcz pokrywają się, uniemożliwiając ich odróżnienie i tworząc tzw.

grupy niejednoznaczności (ambiguity groups). Z tego względu, w celu zwiększenia oddalenia od siebie krzywych identyfikacyjnych i tym samym zwiększenia rozróżnialności uszkodzeń, w pracy [3] zaproponowano przeniesienie krzywych z płaszczyzny w przestrzeń wielowymiarową, na drodze pomiarów dwu lub więcej niezależnych funkcji układowych.



Rys. 1. Przykładowy układ filtra Butterwortha 3 rzędu ($R_1 = R_2 = R_3 = 5 \text{ k}\Omega$, $C_1 = 44,5 \text{ nF}$, $C_2 = 110 \text{ nF}$, $C_3 = 6,42 \text{ nF}$)


Fig. 1. Exemplary 3-rd order Butterworth filter ($R_1 = R_2 = R_3 = 5 \text{ k}\Omega$, $C_1 = 44,5 \text{ nF}$, $C_2 = 110 \text{ nF}$, $C_3 = 6,42 \text{ nF}$)



Rys. 2. Rodzina krzywych identyfikacyjnych dla układu z rys. 1 dla $f = 755 \text{ Hz}$

Fig. 2. Family of identification curves for Butterworth filter for $f = 755 \text{ Hz}$

Na rys. 3 pokazano rezultat przeniesienia krzywych identyfikacyjnych, po ich rozproszeniu, w przestrzeń 3-wymiarową 3D, w której osiami współrzędnych są: część rzeczywista i urojona transmitancji układu K_u oraz moduł admitancji wejściowej $|Y_{we}|$. Widoczne jest rozrzedzenie krzywych identyfikacyjnych, można je jeszcze zwiększyć transformując rodzinę krzywych w przestrzeń 4D, wykonując dodatkowy pomiar, np. części urojonej Y_{we} .



Rys. 3. Widok rozproszonych krzywych wskutek uwzględnienia 2% tolerancji rezystorów i 5% tolerancji kondensatorów


Fig. 3. Identification curves dispersed by component tolerances (2% for resistors and 5% for capacitances)

2.2. Słownik uszkodzeń konstruowany metodą analizy składowych głównych

Metoda analizy składowych głównych (ASG) jest znana z wielu zastosowań [1, 3]. Jej cechą charakterystyczną jest kompresja nadmiarowej ilości informacji w danych pomiarowych, redukująca ją do wzajemnie ortogonalnych składowych głównych. Zaletą metody jest to, iż jest ona niezależna od sposobu opisu układu testowanego (funkcje układowe, macierze zmiennych stanu) oraz jego analizy w dziedzinie czasu lub częstotliwości. Z tego względu metoda ta nadaje się do konstrukcji słowników uszkodzeń innych niż układy elektroniczne obiektów technicznych.

Szczegóły projektowania słownika metodą ASG zamieszczono w pracy autorów [1]. Na rys. 3 przedstawiono rodzinę rozproszonych krzywych na płaszczyźnie 2 pierwszych składowych głównych.

Jak widać z rys. 2 i 4 rodziny krzywych identyfikacyjnych uzyskane metodą TB i ASG są bardzo podobne, co dowodzi przydatności obu metod do tworzenia słowników uszkodzeń.



Rys. 4. Rodzina rozproszonych krzywych identyfikacyjnych na płaszczyźnie dwóch pierwszych składowych głównych dla układu z rys. 1

Fig. 4. Family of dispersed identification curves for Butterworth filter, projected in a 2-D space by Principal Components Analysis

3. Specjalizowana sieć neuronowa z funkcjami DRFB

Dotychczasowe badania autorów wykazały, iż z pośród 4 znanych rodzajów sieci neuronowych: *perceptron wielowarstwowy* MLP (Multi Layer Perceptron), *sieć samoucząca* SOM (Self Organizing Map), *sieć probabilistyczna* PNN (Probabilistic Neural Network) oraz *sieć z radialnymi funkcjami bazowymi* RBF (Radial Basis Function), najbardziej przydatna do diagnostyki uszkodzeń parametrycznych jest sieć RBF, która pojawiła się w literaturze najpóźniej. Jej przydatność do detekcji i lokalizacji uszkodzeń parametrycznych badał Catelani [4].

Istotą sieci neuronowej z radialnymi funkcjami bazowymi, jest zastosowanie neuronów z radialnym odwzorowaniem przestrzeni w otoczeniu zadanego punktu $\mathbf{c} = [c_1, c_2, \dots, c_n]$, stanowiącego centrum funkcji radialnej. Odwzorowanie to jest opisane w przestrzeni \mathcal{R}^N funkcją bazową Gaussa

$$y(\mathbf{x}) = \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - c_i)^2\right), \quad (2)$$

gdzie σ jest parametrem, charakteryzującym obszar rozmycia.


Wadą tej sieci jest duża liczba neuronów, niezbędna do dobrego odwzorowania rozproszonych krzywych identyfikacyjnych.

W celu ominięcia tej wady autorzy zaproponowali nowy typ sieci neuronowej z Dwu-centrowymi Radialnymi Funkcjami Bazowymi (DRFB). Jest ona lepiej dopasowana do kształtu rozproszonych krzywych identyfikacyjnych słownika uszkodzeń, co pozwala lepiej je odwzorować i radykalnie zmniejszyć liczbę neuronów w warstwie ukrytej. W odróżnieniu od jedno-centrowych radialnych funkcji bazowych, które odwzorowują przestrzeń wokół punktu, dwu-centrowe funkcje bazowe użyte w nowej sieci neuronowej odwzorowują przestrzeń wokół odcinka między punktami $\mathbf{c}^{(1)}$ i $\mathbf{c}^{(2)}$.

Łącząc ze sobą kilka odcinków na krzywej, można uzyskać w przestrzeni krzywą łamaną, która dobrze aproksymuje krzywą identyfikacyjną. Do odwzorowania przestrzeni wokół krzywej, o kształcie linii prostej, wystarcza jedna funkcja DRFB. Przy dużym stopniu zagięcia krzywej, dla lepszego dopasowania, konieczne jest odwzorowanie jej kilkoma funkcjami DRFB. Metodyka projektowania funkcji DRFB omówiona została w [1].


Zaproponowano dwa warianty funkcji DRFB: ze stałym ($\sigma = \text{const}$) i zmiennym ($\sigma \neq \text{const}$) parametrem rozmycia, stosownie do różnego charakteru rozproszenia krzywych identyfikacyjnych. Założenie $\sigma = \text{const}$ jest uzasadnione w przypadku jednorodnego rozproszenia krzywej w rozpatrywanym

zakresie zmian wartości parametrów układu testowanego. Z kolei dla lepszego odwzorowania krzywej o zmiennym rozproszeniu celowe jest zastosowanie funkcji DRFB ze zmiennym parametrem σ . Na rys. 5 i 6 przedstawiono kształty obu wariantów funkcji DRFB dla dwóch współrzędnych wejściowych. W tle widoczne są jedno-centrowe funkcje bazowe dla jednakowych (rys. 5), oraz różnych (rys. 6) wartości parametru σ .



Rys. 5. Kształt funkcji DRFB dla centrów $\mathbf{c}^{(1)} = [1, -1]$, $\mathbf{c}^{(2)} = [-1, 1]$ przy stałym stopniu rozmycia ($\sigma = 0,5$)

Fig. 5. The shape of the function DRFB for centers $\mathbf{c}^{(1)} = [1, -1]$ and constant spread parameter $\sigma = 0,5$




Rys. 6. Kształt funkcji DRFB dla centrów $\mathbf{c}^{(1)} = [1, -1]$, $\mathbf{c}^{(2)} = [-1, 1]$ przy zmiennym stopniu rozmycia ($0,4 < \sigma < 0,8$)

Fig. 6. The shape of the function DRFB for centers $\mathbf{c}^{(1)} = [1, -1]$ and changeable spread parameter $\sigma (0,4 < \sigma < 0,8)$

3.1. Architektura sieci z funkcjami DRFB

Architektura klasyfikatora neuronowego z funkcjami DRFB pokazana jest na rys. 7. W warstwie ukrytej znajduje się jeden neuron RBF, z centrum w punkcie odpowiadającym nominalnemu stanowi układu, oraz neurony realizujące funkcje DRFB przyporządkowane rozproszonym krzywym identyfikacyjnym. Neurony w warstwie wyjściowej realizują funkcję maksimum (M), która przenosi na wyjście sygnał o największej wartości wyjściowej. Połączenia między warstwą ukrytą i wyjściową spełniają rolę grupowania neuronów DRFB w klasy uszkodzeń.




Rys. 7. Architektura klasyfikatora neuronowego z funkcjami DRFB
Fig. 7. Architecture of neural network classifier with DRFB functions

Klasyfikacja stanu UT przez sieć DRFB polega na wskazaniu neuronu wyjściowego o największej wartości wyjściowej. Jeśli największą wartość ma górny neuron o numerze 0, wówczas układ jest w stanie nominalnym. W pozostałych przypadkach neuron o maksymalnym wyjściu determinuje numer uszkodzenia.

Klasyfikator z funkcjami DRFB można wykorzystać zarówno do lokalizacji uszkodzeń parametrycznych z identyfikacją ich znaku, jak również do zgrubej identyfikacji uszkodzeń. W drugim przypadku krzywą identyfikacyjną należy odwzorować kilkoma funkcjami DRFB i z każdym neuronem DRFB skojarzyć neuron w warstwie wyjściowej, który oprócz lokalizacji uszkodzenia zgrubnie je zidentyfikuje (małe, średnie, duże, katastroficzne).

4. Przykład zastosowania sieci DRFB

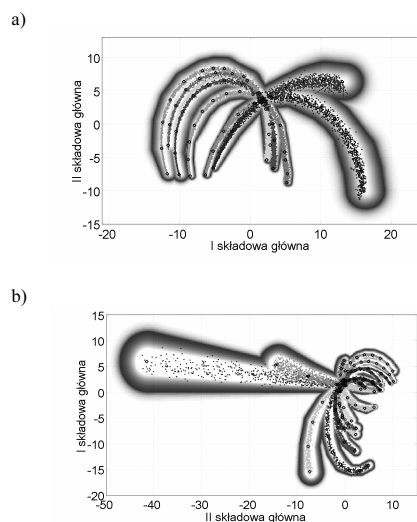
Klasyfikator z funkcjami DRFB wykorzystano do lokalizacji pojedynczych uszkodzeń parametrycznych 2 obiektów: prostego układu z rys. 1, oraz bardziej złożonego filtra 4-go rzędu z rys. 8.



Rys. 8. Układ filtra dolnoprzepustowego 4-go rzędu
Fig. 8. Low-pass 4-th order filter

Dla obu metod konstrukcji słownika uszkodzeń utworzono klasyfikatory z funkcjami DRFB oraz (dla porównania) klasyfikatory z funkcjami RFB. W metodzie transformacji biliniowej TB na wejście sieci podawano wektor zawierający unormowane do przedziału $[-1, 1]$ wartości funkcji układowych dla zoptymalizowanych częstotliwości pomiarowych, natomiast w metodzie ASG – wektor składowych głównych. W metodzie TB dla filtra Butterwortha wykorzystano 3 funkcje układowe: część rzeczywistą i urojoną transmitancji oraz moduł admitancji wejściowej, dla częstotliwości 755 Hz. Dla filtra 4-go rzędu uwzględniono natomiast część rzeczywistą i urojoną transmitancji we/wy dla trzech częstotliwości pomiarowych (365, 470 i 700 Hz). W metodzie ASG uwzględniono 3 składowe główne dla filtra Butterwortha oraz cztery dla filtra 4-go rzędu.

Rozpatrzono pojedyncze uszkodzenia parametryczne elementów R i C, obejmujące zmiany wartości parametrów względem wartości nominalnych w zakresie od $0,2p_{nom}$ do $5p_{nom}$. Każde uszkodzenie symulowano 5000 razy, zakładając logarytmicznie rozłożone wartości uszkodzeń parametrycznych oraz losując wartości elementów nieuszkodzonych z rozkładu równomiernego dla tolerancji: $tol.R = 2\%$, $tol.C = 5\%$.



Rys. 9. Odwzorowanie krzywych identyfikacyjnych funkcjami DRFB:

a) dla filtra Butterwortha; b) dla filtra dolnoprzepustowego 4-go rzędu
Fig. 9. Mapping identification curves by DRFB functions:
a) for Butterworth filter; b) for low-pass 4-th order filter

Ze względu na pokrywanie się niektórych krzywych identyfikacyjnych zdefiniowano dla obu UT klasy uszkodzeń ekwiwalentnych. Ograniczono w ten sposób liczbę wyjść sieci do: 10 dla filtra Butterwortha (9 klas uszkodzeń i stan nominalny), oraz 14 dla filtra 4-go rzędu (13 klas uszkodzeń i stan nominalny).

W zależności od metody konstrukcji słownika oraz kształtu krzywych wybrano 2 do 9 centrów, co implikowało liczbę 1 do 8 neuronów przyporządkowanych poszczególnym krzywym.

Na rys. 9 przedstawiono zarys obszaru odwzorowania krzywych identyfikacyjnych przez neurony warstwy ukrytej dla obu UT. Porównując rys. 2 i 9a widać dobre odwzorowanie rozproszonych krzywych identyfikacyjnych funkcjami DRFB. Z kolei na rys. 9b wyraźnie widać, iż do odwzorowania krzywej identyfikacyjnej zbliżonej do linii prostej wystarczy jedna funkcja DRFB.

Wyniki klasyfikacji uszkodzeń dla obu UT przedstawiono w tab. 1. Numery nieparzyste dotyczą klasyfikatorów DRFB, natomiast parzyste klasyfikatorów RFB. Błąd klasyfikacji zdefiniowano jako procent wadliwych decyzji.

Tab. 1. Wyniki klasyfikacji uszkodzeń.
Tab. 1. Classification results.

Układ testowy	filtr Butterwortha				filtr 4-go rzędu				
	TB		ASG		TB		ASG		
Konstrukcja słownika									
Numer klasyfikatora	1	2	3	4	5	6	7	8	
Liczba funkcji DRFB	$\sigma = \text{const}$	51	-	45	-	60	-	61	-
	$\sigma \neq \text{const}$	10	-	16	-	34	-	23	-
	łącznie	61	-	61	-	94	-	84	-
Liczba funkcji RB	1	121	1	121	1	221	1	221	
Liczba neuronów	62	121	62	121	95	221	85	221	
Błąd klasyfikacji [%]	0,38	2,5	1,91	3,33	1,24	2,85	5,53	8,28	

Z tabeli 1 wynika, iż dla obu układów testowych i obu metod konstrukcji słownika mniejsze błędy klasyfikacji osiągnięto dla sieci DRFB. Uzyskane rezultaty pokazują, iż sieć RFB posiada gorsze zdolności prawidłowej detekcji stanu układu pomimo uwzględnienia w architekturze sieci dwukrotnie większej liczby neuronów w porównaniu z siecią zawierającą funkcje DRFB.

Z porównania obu metod konstrukcji słownika w tab. 1 wynika, iż dla obu układów oraz wszystkich wariantów badanych klasyfikatorów lepszą efektywność diagnostyki wykazuje metoda TB.

5. Wnioski

Przedstawiona w pracy nowa, specjalizowana sieć neuronowa DRFB oraz oparta na niej słownikowa metoda diagnostyki uszkodzeń parametrycznych AUE wykazały przewagę nad znaną z literatury siecią RFB (lepsze odwzorowanie słownika uszkodzeń przy istotnie mniejszej liczbie neuronów) oraz większą odporność metody na tolerancje UT. Metoda może być przydatna do diagnostyki innych niż AUE obiektów technicznych.

6. Literatura

- [1] R. Zielonko, M. Kowalewski: Diagnostyka uszkodzeń analogowych układów elektronicznych z zastosowaniem specjalizowanej sieci neuronowej. W: Z. Kowalczyk, S. Wiszniewski (pod redakcją) Inteligentne wydobywanie informacji. PWNT, Gdańsk 2007.
- [2] M. Aminian, F. Aminian: A Modular Fault-Diagnostic System for Analog Electronic Circuits Using Neural Networks With Wavelet Transform as a Preprocessor. IEEE Trans. on Instr. and Meas., vol. 56, no. 5, pp. 1546-1554, 2007.
- [3] Z. Czaja, R. Zielonko: Fault diagnosis in electronic circuits based on bilinear transformation in 3-D and 4-D spaces. IEEE Trans. on Instr. and Meas., vol. 52, no. 1, pp. 97-102, 2003.
- [4] M. Catelani, A. Fort: Soft Fault Detection and Isolation in Analog Circuits: Some Results and a Comparison Between a Fuzzy Approach and Radial Basis Function Networks. IEEE Trans. on Instr. and Meas., vol. 51, no. 2, pp. 196-202, 2002.