

WYKORZYSTANIE SZTUCZNYCH SIECI NEURONOWYCH DO ZMNIEJSZENIA BŁĘDÓW PRZETWORNIKÓW IMPEDANCJI

Maria WRZUSZCZAK¹, Yuriy KHOMA²

1. Politechnika Opolska, Instytut Automatyki i Informatyki
tel.: +48 774008648 e-mail: m.wrzuszczak@po.opole.pl
2. Politechnika Lwowska, Instytut Technologii Komputerowych, Automatyki i Metrologii, Ukraina
e-mail: khomay@gmail.com

Streszczenie: Przetworniki impedancja – napięcie (Z/U) stanowią podstawowy element komputerowych tomografów impedancyjnych. W artykule przedstawiono sposób zmniejszenia błędów przetwarzania przetwornika Z/U z zastosowaniem sztucznej sieci neuronowej wielowarstwowej, perceptronowej (MLP). Dokładność metody porównano z dokładnością uzyskaną w przypadku wyznaczania poprawek dla dwu składowych impedancji: rezystancyjnej i reaktancyjnej na podstawie wzorów analitycznych wyprowadzonych dla schematu zastępczego układu.

Słowa kluczowe: przetwornik impedancja-napięcie, sztuczne sieci neuronowe, korekcja wyników pomiarów.

1. WSTĘP

Metody spektroskopii impedancyjnej są szeroko stosowane do badania obiektów o różnej naturze w wielu dziedzinach nauki i techniki takich jak: fizyka ciała stałego, diagnostyka metali i stopów, nanotechnologie, medycyna i biologia [1-5]. Instrumentem służącym do praktycznej realizacji spektroskopii impedancyjnej jako metody badawczej są analizatory impedancji [6,7]. Dla tych układów pomiarowych ważnym jest osiągnięcie dużej szybkości przetwarzania. W wyniku pomiarów gromadzone są duże ilości danych, złożone z par wartości składowych impedancji uzyskane dla różnych punktów przestrzeni dla różnych wartości częstotliwości. Dlatego analizatory impedancji realizowane są najczęściej z wykorzystaniem metody bezpośredniego porównania. Przyrządy pomiarowe bazujące na tej metodzie charakteryzuje nie tylko duża szybkość, ale również prostota realizacji. Ma to ważne znaczenie pozwalające uzyskać aparaturę pomiarową o mniejszej masie i objętości oraz o mniejszym poborze mocy i otwiera możliwości przeprowadzania badań w warunkach nie tylko laboratoryjnych [8].

W nowoczesnych analizatorach impedancji stosowane są głównie autokompensacyjne przetworniki impedancja-napięcie bazujące na wzmacniaczach operacyjnych (WO), które w dalszej części są nazywane skrótowo - autokompensacyjne przetworniki Z/U [6, 8, 9]. Układy te posiadają szereg zalet, między innymi: liniowość i stabilność funkcji przetwarzania, wysoką czułość i dużą szybkość przetwarzania, możliwość utrzymania zadanych warunków energetycznych na obiekcie badanym (stabilne zadane napięcie lub prąd) oraz umożliwiając pomiary zarówno w

trybie pomiaru impedancji, jak i w trybie pomiaru admitancji.

Podstawową wadą przetworników Z/U są błędy częstotliwościowe związane ze spadkiem wzmocnienia WO wraz ze wzrostem częstotliwości sygnału wymuszającego oraz powstawaniem zwarcia wejścia WO do ziemi poprzez pojemności doziemne. Znane są układowe sposoby eliminacji lub zmniejszenia tego problemu, oparte na wprowadzeniu redundancji sprzętowej do toru pomiarowego (odpowiednie kondensatory) [6,10]. Działanie to jednak nie zawsze jest skuteczne. W celu zmniejszenia błędów dynamicznych autokompensacyjnych przetworników Z/U można wykorzystać procedury korekcji wyników pomiarów, bazujące na wykorzystaniu możliwości obliczeniowych mikroprocesora w torze pomiarowym przetwarzającym sygnał pomiarowy [11,12]. Procedury takie wymagają:

- wyprowadzenia wzorów analitycznych dla schematu zastępczego przetwornika Z/U uwzględniającego niektóre parametry wzmacniacza operacyjnego rzeczywistego i czynniki destabilizujące (np. wpływ zmiany temperatury);
- wyliczenia za pomocą algorytmów korekcji poprawek oraz wprowadzenie ich do surowych wyników przetwarzania.

Jednak nie zawsze jest możliwe uzyskanie wzorów analitycznych do algorytmów korekcji. W takim przypadku wydaje się celowym zastosowanie innych metod korekcji algorytmicznej, na przykład w oparciu o metody sztucznej inteligencji [13,14].


Celem niniejszego artykułu jest badanie możliwości wykorzystania sztucznych sieci neuronowych (SSN) w celu poprawy dokładności przetwarzania składowych impedancji oraz analiza porównawcza skuteczności takiego podejścia w porównaniu z klasycznym, bazującym na zastosowaniu algorytmów korekcji uzyskanych drogą analityczną. W rozważaniach skupiono się wyłącznie na zmniejszeniu błędów przetwarzania samego przetwornika Z/U, nie rozpatrując błędów wnoszonych przez kolejne układy elektronicznego przetwarzania

2. MODEL MATEMATYCZNY AUTOKOMPENSACYJNEGO PRZETWORNIKA IMPEDANCJA-NAPIĘCIE

Autokompensacyjny przetwornik Z/U jest podstawowym elementem w torze pomiarowym analizatora

impedancji. To właśnie w nim pod wpływem wymuszenia harmonicznego dokonuje się przetwarzanie impedancji jako wielkości pasywnej na napięcie proporcjonalne.

Uproszczony schemat przetwornika Z/U z autokompensacją do spektroskopii impedancyjnej przedstawiono na rys 1.



Rys. 1. Uproszczony schemat analizatora impedancji z przetwornikiem Z/U i wykorzystaniem sztucznej sieci neuronowej do zmniejszenia błędów przetwarzania (DF – detektor fazoczuły, A/C – przetwornik analogowo-cyfrowy, SSN – sztuczna sieć neuronowa)

Istota tej metody polega na generowaniu sinusoidalnego prądu I_R o stałej amplitudzie płynącego przez obiekt badany o impedancji Z i uzyskaniu proporcjonalnego napięcia zespolonego

$$\underline{U}_Z = -I_R Z = -\frac{U_0}{R_0} Z = -U_0 \left(\frac{R}{R_0} + j \frac{X}{R_0} \right) \quad (1)$$

gdzie: U_0 – napięcie pobudzenia, R_0 – opór rezystora odniesienia, Z – impedancja badanego obiektu.

Podany wzór (1) odpowiada tak zwanej idealnej funkcji przetwarzania. W praktyce jednak, należy uwzględnić wpływ rzeczywistych parametrów wzmacniacza operacyjnego, przede wszystkim wzmocnienie A oraz współczynnik sprzężenia zwrotnego β , wtedy napięcie wyjściowe przetwornika

$$\underline{U}_Z = -U_0 \left(\frac{R}{R_0} + j \frac{X}{R_0} \right) \frac{1}{1 + 1/\beta A} = U_1 + jU_Q \quad (2)$$

gdzie: U_1 i U_Q - składowa synfazowa i kwadraturowa napięcia wyjściowego przetwornika Z/U (rozdzielone za pomocą detektora fazoczułego).

Tak zwany model małosygnałowy układu pozwala uwzględnić zmniejszanie się wzmocnienia układu ze wzrostem częstotliwości [15], wtedy transmitancję układu można zapisać:

$$H = -\frac{\underline{U}_Z}{\underline{U}_0} = \frac{R}{R_0} + j \frac{X}{R_0} = \frac{-\frac{Z}{R_0} + \left(\frac{1}{A_0} + j \frac{f}{f_U} \right) \frac{R_{WY}}{R_0}}{1 + \left(\frac{1}{A_0} + j \frac{f}{f_U} \right) \left[\left(1 + \frac{Z}{R_0} + \frac{Z}{Z_P} \right) \left(1 + \frac{R_{WY}}{Z_L} \right) + \frac{R_{WY}}{R_0} + \frac{R_{WY}}{Z_P} \right]} \quad (3)$$

gdzie: A_0 – współczynnik wzmocnienia WO dla prądu stałego, f_U – częstotliwość graniczna WO, f – częstotliwość napięcia pobudzenia, R_{WY} – rezystancja wyjściowa WO, Z_L – impedancja obciążenia WO, Z_P – impedancja wejściowa zastępcza $Z_P = Z_D || Z_S$ (Z_D – impedancja wejściowa różnicowa, Z_S – szeregowo impedancja wejściowa).

W celu uproszczenia zapisu w dalszej części artykułu przyjęto oznaczenia

$$R_C = \frac{R}{R_0}, \quad X_C = \frac{X}{R_0},$$

gdzie: R_C i X_C – wyniki przetwarzania unormowanych składowych impedancji (części rzeczywistej i urojonej) dla modelu uwzględniającego parametry wzmacniacza operacyjnego i wyznaczane jako składowa synfazowa i kwadraturowa napięcia wyjściowego \underline{U}_Z przetwornika Z/U.

Wzór (3) jest dosyć złożony, więc podczas przekształceń dokonuje się szeregu uproszczeń, które jednak istotnie nie wpływają na adekwatność modelu [12]. Ostatecznie dla przetwornika Z/U ze wzmacniaczem operacyjnym nieidealnym składowe impedancji można obliczyć według następujących zależności:

- składową rezystancyjną

$$R_M = \frac{R_C + C \frac{R_C^2 + X_C^2}{K} - X_C \frac{1+D}{K} - \frac{R_C^2 + X_C^2}{K^2}}{1 + 2 \frac{R_C C + X_C}{K} + \frac{R_C^2 + X_C^2}{K^2} (1 + C^2)} \quad (4a)$$

- składową reaktancyjną

$$X_M = \frac{X_C + \frac{R_C^2 + X_C^2}{K} + R_C \frac{1+D}{K} + \frac{D}{K} + C \frac{R_C^2 + X_C^2}{K^2}}{1 + 2 \frac{R_C C + X_C}{K} + \frac{R_C^2 + X_C^2}{K^2} (1 + C^2)} \quad (4b)$$

gdzie: $K = f_U / f$ - stosunek częstotliwości granicznej wzmacniacza operacyjnego do częstotliwości pobudzenia, $D = R_{WY} / R_0$ - stosunek rezystancji wyjściowej WO do rezystancji odniesienia; $C = \omega C_{IN} R_0$, C_{IN} - pojemność wejściowa WO.

Ostatecznie błędy pomiaru składowych impedancji po zastosowaniu korekcji algorytmicznej obliczono według wzorów:

$$\delta_R = \frac{R_M - R}{R} 100\% \quad \text{ i } \quad \delta_X = \frac{X_M - X}{X} 100\% \quad (5)$$


3. ZASTOSOWANIE MODELU SZTUCZNYCH SIECI NEURONOWYCH DO POPRAWY DOKŁADNOŚCI PRZETWARZANIA

Przeprowadzone przez autorów badania pokazały możliwość realizacji korekcji algorytmicznej w oparciu o sztuczne sieci neuronowe (SSN). Korekcja na bazie sztucznych sieci neuronowych polega na pomnożeniu surowych wyników przetwarzania przez odpowiednio dobrane współczynniki sieci a następnie zsumowaniu iloczynów. Na etapie nauczania sieć sama dobiera

odpowiednie współczynniki modelu na podstawie podanych wartości wielkości wejściowych i wyjściowych oraz parametrów toru przetwarzania. Po zsumowaniu sygnały w torach są mnożone przez nieliniową funkcję aktywacji [16, 14].

Wykorzystano sztuczną sieć neuronową wielowarstwową perceptronową (ang. feedforward multi-layer perceptron), która zawiera dwie ukryte warstwy z 50-cioma neuronami w każdej warstwie i z nieliniową funkcją aktywacji typu sigmoidalnego. Warstwa wyjściowa została zbudowana z dwu neuronów z dwoma wyjściami oraz z liniową funkcją aktywacji (rys. 2).

Badania zostały przeprowadzone w środowisku Matlab z wykorzystaniem modułu Neural Network Toolbox.



Rys. 2. Sztuczna sieć neuronowa typu feedforward z dwiema warstwami ukrytymi

Realizacja korekcji algorytmicznej na bazie sztucznych sieci neuronowych składała się z następujących etapów:

- przygotowania danych wejściowych;
- zbudowania sieci neuronowej (doboru struktury sieci, ilości neuronów w warstwach, doboru funkcji aktywacji);
- nauczania sieci (kalibracja);
- badań testowych i oszacowanie dokładności.

Na pierwszym etapie zostały przygotowane dwa zbiory danych - treningowy (do nauczania) i testowy. Zbiory te posiadały identyczną strukturę w postaci wektorów danych wejściowych i wyjściowych. Każdy wektor wejściowy zawiera siedem wielkości f , R_C , X_C , f_U , C_{IN} , R_O , R_{WY} . Z kolei każdy wektor wyjściowy jest reprezentowany przez dwie wielkości R_M oraz X_M .

Dane do badania sieci neuronowej pozyskano drogą symulacji komputerowej. Dla wielkości wejściowych sieci wygenerowano zbiory o wartościach pseudolosowych według rozkładu jednostajnego z ograniczeniem zakresu zmienności.

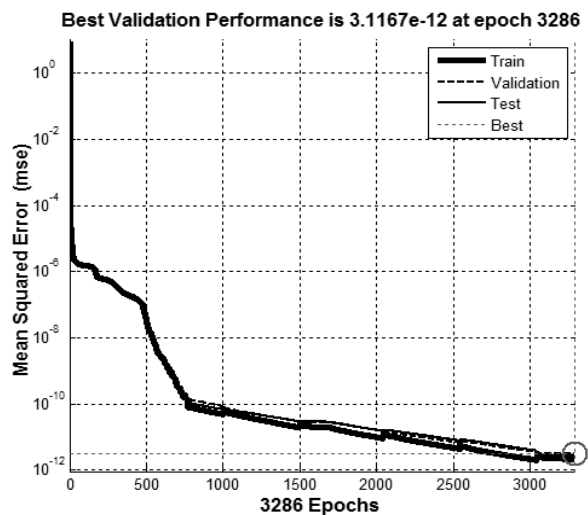
Podczas inicjalizacji sztucznej sieci neuronowej SSN wartościom parametrów przypisano liczby losowe. W trakcie fazy treningu zastosowano metodę regularyzacji bayesowskiej [17]. Dodatkowo przyjęto następujące parametry:

1. liczba iteracji: 500 dla każdego pakietu danych;
2. maksymalny błąd cross-walidacji: 10;
3. minimalny gradient: 10^{-8} ;
4. estymator dokładności nauczania: błąd średniokwadratowy.

Zmianę wartości błędu średniokwadratowego podczas procesu uczenia pokazano na rysunku 3.

4. ANALIZA PORÓWNAWCZA WYNIKÓW KORECJI ALGORYTMICZNEJ

Po etapie uczenia przeprowadzono weryfikację modelu sieci neuronowej na zbiorze testowym. Postanowiono również porównać dokładność uzyskaną za pomocą SSN z dokładnością uzyskiwaną na podstawie wzorów analitycznych dla modelu układu ze wzmacniaczem operacyjnym nieidealnym.



Rys. 3. Wykresy nauczania SSN analizatora impedancji

Jako miarę dokładności wybrano estymator błędu średniokwadratowego z poziomem ufności 0,997. Wyniki analizy porównawczej zestawiono w tabeli 1.

Tabela 1. Porównanie dokładności uzyskanej z wykorzystaniem modelu SSN i modelu analitycznego

	błąd średniokwadratowy ($P = 0.997$), %	
	model SSN	model analityczny
R	0.0022	0.0037
X	0.0016	0.0032

Jak widać z tabeli 1 korekcja surowych wyników przetwarzania składowych impedancji w oparciu o SSN daje trochę większą dokładność w porównaniu z korekcją zwyczajowo stosowaną (analityczną).

Wykorzystany model SSN jest stosunkowo prosty. Jego rozbudowa (większa liczba warstw i neuronów) oraz wstępne przetwarzanie danych, normalizacja, lub zastosowanie skali logarytmicznej może pozwolić na dodatkowe zwiększenie dokładności przetwarzania przetwornika Z/U .

Czas niezbędny na przeprowadzenie korekcji algorytmicznej jest prawie jednakowy dla obu przedstawionych metod i wynosi kilkadziesiąt mikrosekund. W obu metodach wykonuje się operacje mnożenia i dodawania, więc można je stosunkowo łatwo zastosować na takich platformach obliczeniowych jak procesory sygnałowe (DSP) bądź układy (FPGA).

5. PODSUMOWANIE

W skład nowoczesnych analizatorów impedancji zawsze wchodzi pewne układy analogowe, w tym zbudowane w oparciu o wzmacniacze operacyjne. Komponenty te są źródłem błędów, a ich redukcja jest możliwa poprzez korekcję algorytmiczną.

Badania wykazały możliwość realizacji korekcji algorytmicznej w oparciu o sztuczne sieci neuronowe. Przedstawiono wyniki badań uzyskane z zastosowaniem sztucznej sieci neuronowej typu feedforward z dwiema warstwami ukrytymi.

Jak wynika z przeprowadzonych badań, nawet wykorzystanie stosunkowo prostej sztucznej sieci neuronowej zapewniło porównywalne lub nawet nieco

lepsze wyniki poprawy dokładności pomiaru składowych impedancji w porównaniu z podejściem analitycznym. Komplikowanie SSN w celu dalszego zmniejszenia błędów nie jest uzasadnione, ponieważ istnieją błędy instrumentalne, które pozostają poza działaniem korekcyjnym sieci.

Podsumowując uzyskane wyniki należy podkreślić, że SSN mają przewagę w takich przypadkach, gdy:

- nie jest możliwe uzyskanie wzorów do algorytmów korekcji w sposób analityczny;

- nie jest znany model analityczny toru pomiarowego, a są dostępne jedynie dane eksperymentalne.

Zastosowanie sieci neuronowych może również być przydatne w procesie projektowania przyrządów pomiarowych.

6. BIBLIOGRAFIA

1. Barsoukov E., MacDonald J.R. Impedance spectroscopy: theory, experiment and application. - N.Y.: Wiley, pp. 2005. - 595.
1. Sze S.M., Kwok K.Ng. Physics of Semiconductor Devices. - Wiley Interscience, pp. 2007, p. 815.
2. Ramos P.M., Janeiro F.M. Gene expression programming for automatic circuit model identification in impedance spectroscopy: Performance evaluation, Measurement 46 (2013) pp. 4379–4387.
3. Grimnes S., Martinsen O. G. Bioimpedance & Bioelectricity Basics. Second Edition: Academic Press, Elsevier, 2008, pp. 471.
4. Tobiszewski M. T., Arutunow A., Darowicki K.: Application of dynamic impedance spectroscopy to scanning probe microscopy. Microscopy and Microanalysis, Vol. 20 Issue 02, April 2014, pp. 582-585.
5. Agilent Impedance Measurement Handbook. A guide to measurement technology and techniques: 4-th Edition. Agilent Technologies, Inc. (2009), 5950-3000, p.140.
6. Hoja J., Lentka G. An analysis of a measurement probe for a high impedance spectroscopy analyzer, Measurement 41 (2008), pp. 65–75.
7. Hoja J., Lentka G., 2013, A family of new generation miniaturized impedance analyzers for technical object diagnostics, Metr. & Meas. Syst., Vol. 20, No. 1, pp.43-52.
8. AD5933. 1 MSPS, 12-Bit Impedance Converter, Network Analyzer //http://www.analog.com
9. Khoma V., Wrzuszcak M. Kompensacyjny miernik impedancji, Przegląd Elektrotechniczny, R. 84 NR 5/2008, str. 33-36.
10. Dutta M., Chatterjee A., Rakshit A. Intelligent phase correction in automatic digital ac bridges by resilient backpropagation neural network, Measurement 39 (2006), pp. 884–891.
11. Smolczyk A., Khoma V. Algorytm korekcji błędów dynamicznych autokompensacyjnego miernika admitancji, Przegląd Elektrotechniczny, R. 84 NR 11/2008, str. 80-84.
12. Roj J., Neural Network Based Real-time Correction of Transducer Dynamic Errors, Measurement Science Review, Volume 13, No. 6, 2013, pp. 286 – 291.
13. Wrzuszcak M., Wrzuszcak J. Eddy current flaw detection with neural network application. Measurement 38 (2005) pp. 132-136.
14. Dostal J. Operational Amplifiers, Second Edition, Butterworth-Heinemann, 1993, p. 381.
15. Smith S. W. Digital Signal Processing: A Practical Guide for Engineers and Scientists, Elsevier Science, Burlington, MA, USA, 2003, p.650.
16. Burden F, Winkler D, Bayesian regularization of neural networks, Methods in Molecular Biology, 2008.

ERROR CORRECTION OF IMPEDANCE-VOLTAGE CONVERTER WITH NEURAL NETWORK APPLICATION

Impedance – voltage transducer (Z/U) are fundamental circuits in Impedance Tomography devices. In the paper the transducer error reducing method for resistance and reactance components of impedance with Multi-Layer Perceptron artificial neural network application is presented. The accuracy of the method is compared with the values calculated with analytical formulas derived for equivalent circuit of the transducer. The consideration presented in the paper focuses only on decreasing the processing error of the impedance/voltage transducer (Z/U), neglecting errors being introduced by following electronic processing stages i.e. phase detector and analog /digital converter.

Keywords: impedance to voltage converter, artificial neural network, measurement error correction.