

Piotr MAKOWSKI, Jerzy ROJ


POLITECHNIKA ŚLĄSKA, INSTYTUT METROLOGII I AUTOMATYKI ELEKTROTECHNICZNEJ

Neuronowa realizacja korekcji błędów dynamicznych w przetworniku próbkującym

Mgr inż. Piotr MAKOWSKI

Studia wyższe magisterskie na Wydziale Elektrycznym Politechniki Śląskiej w Gliwicach ukończył w roku 2002. Obecnie jest doktorantem w Instytucie Metrologii i Automatyki Elektrotechnicznej Politechniki Śląskiej, gdzie przygotowuje rozprawę doktorską poświęconą tematyce sieci neuronowych realizujących odtwarzanie w przetwornikach próbkujących. Jego prace badawcze koncentrują się przede wszystkim na problemie budowy modeli błędów i niepewności sieci neuronowych stosowanych do odtwarzania.

e-mail: Piotr.Makowski@polsl.pl



Dr inż. Jerzy ROJ

Absolwent Wydziału Elektrycznego Politechniki Śląskiej. Od 1989 r. pracownik Instytutu Metrologii i Automatyki Elektrotechnicznej. Stopień doktora nauk technicznych uzyskał w roku 1998. Obecnie obszar jego zainteresowań obejmuje opracowywanie modeli błędów, modeli niepewności przetworników próbkujących, badania metrologiczne właściwości sieci neuronowych oraz możliwości ich stosowania w przyrządach pomiarowych.

e-mail: jerzy.roj@polsl.pl



Streszczenie

W artykule przedstawiono wyniki badań zastosowania sieci neuronowych do korekcji błędów statycznych i dynamicznych wnoszonych przez analogową część toru przetwarzania przetwornika próbkującego opisaną modelem Wienera. Poddano analizie możliwość zastosowania dwóch niezależnych sieci neuronowych realizujących kolejno korekcję błędów statycznych i dynamicznych oraz możliwość zastosowania tylko jednej sieci do rozwiązania obu zadań jednocześnie.

Neural Realisation of Dynamic Errors Correction in Sampling Transducer

Abstract

The paper presents the investigations results of application of neural networks to correction of static and dynamic errors caused by an analog part of the sampling transducer processing chain described by Wiener model. The possibility of using two independent neural networks realising correction of static and dynamic errors in turn as well as the possibility of application of one network only to solving the both tasks simultaneously are analysed.

1. Wprowadzenie

Przetwornik próbkujący jest układem pomiarowym służącym do dostarczania wyników pomiaru wartości chwilowych wielkości zmiennych w czasie [3]. W ostatniej fazie zachodzącego w nim procesu przetwarzania realizowane są działania numeryczne mające na celu wyznaczenie oceny wartości wielkości mierzonej na podstawie skwantowanych wyników przetwarzania A/C oraz znajomości modelu opisującego tor przetwarzania od jego wejścia do wyjścia przetwornika A/C.


Przetwarzanie cyfrowe można więc w takim przypadku rozpatrywać w kategoriach odtwarzania [4, 8], czyli wnioskowania o przyczynie na podstawie znajomości skutku, jaki wywołuje oraz modelu odwrotnego łączącego skutek z przyczyną. W związku z tym, gdy rozpatruje się aspekty metrologiczne odtwarzania, może być ono traktowane jako korekcja błędów systematycznych (statycznych i dynamicznych) powstających w trakcie przetwarzania analogowego wielkości wejściowej [4].

Odtwarzanie cyfrowe realizowane jest najczęściej w sposób programowy (łańcuch algorytmów korekcji statycznej i dynamicznej) przez mikroprocesor. Niezbędna w takim przypadku jest znajomość odwrotnego modelu procesu przetwarzania analogowego, co wiąże się z problemem jego identyfikacji. W wielu wypadkach dostatecznie dokładne modele odwrotne są bądź bardzo złożone, bądź też w ogóle niemożliwe do określenia. W tego typu sytuacjach alternatywą może być zastąpienie wybranych algorytmów (lub ich łańcuchów) przez sieci neuronowe. Można bowiem przyjąć, iż sieć neuronowa w procesie uczenia sama „tworzy” właściwy model odwrotny, co jest konsekwencją jej

podstawowych cech: zdolności uczenia się oraz zdolności do uogólnienia nabytej wiedzy [9].

2. Model przetwarzania analogowego w przetworniku próbkującym

Dla celów eksperymentalnych przyjęto, że przetwarzanie analogowe w przetworniku próbkującym daje się przedstawić w postaci ogólnego nieliniowego modelu pokazanego na rys. 1 (model Wienera [10]).



Rys.1. Model toru analogowego przetwornika próbkującego
Fig.1. Model of the sampling transducer analog part

Ponadto przyjęto, że element dynamiczny opisany jest równaniem różniczkowym liniowym I-go rzędu o stałych parametrach:

$$\tau \frac{du(t)}{dt} + u(t) = x(t), \quad (1)$$

gdzie stała czasowa $\tau = 0,2$.

Element statyczny opisuje z kolei równanie wykładnicze:

$$y(t) = e^{-5u(t)}. \quad (2)$$

Tego typu modele można stosować min. do opisu właściwości czujników termometrycznych. Pierwszy element (dynamiczny) reprezentuje w takim przypadku proces nagrzewania się struktury czujnika spowodowany zmianą temperatury mierzonej w czasie t . Element drugi (statyczny) opisuje z kolei związaną z tym zmianę jego sygnału wyjściowego. Równanie opisujące element statyczny odpowiada więc charakterystyce statycznej czujnika. Ze względu na założoną postać wykładniczą tego równania, przyjęty model może zatem opisywać właściwości statyczne i dynamiczne np. czujników termistorowych NTC [5].


Badania ograniczono wyłącznie do sytuacji w których wielkość mierzona x zmienia się w sposób skokowy. W takim przypadku odpowiedź elementu dynamicznego przy zmianie wielkości wejściowej od wartości x_p do x_m opisana może być zależnością:

$$u(t) = x_p + (x_m - x_p) \left(1 - e^{-\frac{t}{\tau}} \right) \quad (3)$$

Zgodnie z zasadami odtwarzania [4] na ciąg działań realizowanych w procesie odtwarzania w rozpatrywanym przetworniku próbkującym powinny kolejno składać się: algorytm korekcji statycznej oraz algorytm korekcji dynamicznej. W pierwszej kolejności poddano badaniom możliwość zastąpienia w/w algorytmów odpowiednio przez dwie, niezależne sieci neuronowe – *wariant 1*. Następnie przebadano możliwość zastosowania tylko jednej sieci, która realizowałaby jednocześnie obydwa zadania – *wariant 2*.

3. Odtwarzanie neuronowe – wariant 1

Struktura toru odtwarzania w tym przypadku ma postać przedstawioną na rys. 2.



Rys. 2. Odtwarzanie neuronowe – *wariant 1*, SKS – sieć neuronowa realizująca korekcję statyczną, RSR – rejestr szeregowo-równoległy, SKD – sieć realizująca korekcję dynamiczną


Fig. 2. Neural reconstruction – alternative 1, SKS – neural network realising static correction, RSR – serial-in, parallel-out register, SKD – network realising dynamic correction

Pierwsza sieć (SKS) realizuje korekcję statyczną. Zagadnienia związane z doбором sieci do realizacji tego typu zadań, sposób uczenia oraz ich właściwości metrologiczne były opisywane przez autorów min. w pracach [1, 6, 7]. Dla celów badań symulacyjnych zaimplementowano sieć jednokierunkową o strukturze 1-3-1 (jedno wejście, trzy neurony z sigmoidalną bipolarną funkcją aktywacji w warstwie ukrytej, jeden liniowy neuron wyjściowy). Korzystając z zależności (2) wygenerowano 50-elementowy zbiór uczący składający się z par $[\tilde{y}_i, u_i]$ (gdzie $i=1, \dots, 50$ oznacza numer kolejnego wzorca), przy czym wartości y_i poddano procesowi kwantowania w zamodelowanym 12-bitowym przetworniku A/C. Każdy wzorec uczący jest więc parą dwóch liczb: skwantowanego sygnału wyjściowego czujnika \tilde{y}_i , będącego sygnałem wejściowym sieci, oraz liczby u_i stanowiącej pożądaną jej odpowiedź na zadane wymuszenie \tilde{y}_i . Po przeprowadzeniu procesu uczenia sieci realizowano jej testowanie wykorzystując 100 000-elementowy zbiór testowy otrzymany w analogiczny sposób, przy czym wartości y_i nie poddano kwantowaniu. W wyniku testowania sieci uzyskano zbiór wartości błędów własnych generowanych przez sieć:

$$\delta_{wi} = \hat{x}_{mi} - x_{mi} \quad (4)$$

gdzie $i=1, \dots, 100\ 000$.


Rezultaty testowania w postaci wykresu błędów własnych sieci oraz ich histogramu przedstawiono na rys. 3.



Rys. 3. Błędy własne sieci realizującej korekcję statyczną: a) wykres błędów, b) histogram

Fig. 3. Own errors of the network realising static correction: a) diagram, b) histogram

Druga sieć (SKD) w układzie z rys. 2 realizuje korekcję dynamiczną. Zastosowano tu jeden neuron liniowy o dwóch wejściach. W rejestrze szeregowo – równoległym (RSR) gromadzone są dwie próbki z wyjścia sieci realizującej korekcję statyczną: $\hat{u}(t_{k-1})$, $\hat{u}(t_k)$ pobrane w dwóch kolejnych, ściśle określonych, chwilach czasowych (t_{k-1} , t_k) trwania stanu nieustalonego. Następnie próbki te wprowadza się jednocześnie na wejścia sieci SKD, której zadaniem jest generacja poprawnej oceny wartości wielkości mierzonej \hat{x}_m . W celu przeprowadzenia procesu uczenia sieci SKD utworzono 100-elementowy zbiór uczący korzystający z zależności (3) oraz przyjmując $t_{k-1} = 0,1$ s, $t_k = 0,2$ s (od momentu zadania skoku). Każdy wzorec uczący składa się więc z wektora sygnałów wejściowych $\hat{u}_j = [\hat{u}_j(t_{k-1}); \hat{u}_j(t_k)]$, oraz liczby x_{mj} , która jest jej pożądaną odpowiedzią na zadane wymuszenie. W ostatnim etapie badań przystąpiono do testowania toru odtwarzania rozpatrywanego jako całość. Wykorzystując do tego celu 100 000-elementowy zbiór testowy wyznaczono wartości całkowitych błędów własnych δ_c generowanych przez tor oraz ich histogram, które przedstawiono na rys. 4.



Rys. 4. Błędy własne neuronowego toru odtwarzania (*wariant 1*): a) wykres błędów, b) histogram

Fig. 4. Own errors of the neural reconstruction chain (alternative 1): a) diagram, b) histogram

Analogiczne badania przeprowadzono zmniejszając okres dyskretyzacji $T_d = t_k - t_{k-1}$. W tabeli 1 zestawiono wartości szerokości przedziału niepewności własnej Δ_{w1} [1] rozpatrywanego toru odtwarzania w zależności od ilorazu T_d / τ (gdzie $\tau = 0,2$).


Tab. 1. Wartość szerokości przedziału niepewności własnej toru odtwarzania Δ_{w1} w zależności od T_d / τ , $t_{k-1} = 0,1$ s

Tab. 1. Values of the interval range of the reconstruction chain own uncertainty Δ_{w1} as a function of T_d / τ , $t_{k-1} = 0,1$ s

t_k [s]	T_d / τ	Δ_{w1}
0,20	0,50	0,016
0,15	0,25	0,023
0,12	0,10	0,100
0,11	0,05	0,510

4. Odtwarzanie neuronowe – wariant 2


W kolejnym etapie badań założono, że korekcja błędów statycznych i dynamicznych będzie realizowana przez jedną sieć neuronową o strukturze 2-5-2. Struktura toru odtwarzania w tym przypadku ma postać przedstawioną na rys. 5.



Rys. 5. Odtwarzanie neuronowe – wariant 2, RSR-rejestr szeregowo-równoległy, SKSD – sieć neuronowa realizująca korekcję statyczną i dynamiczną

Fig. 5. Neural reconstruction – alternative 2, RSR – serial-in, parallel-out register, SKSD – neural network realising static and dynamic correction

Korzystając z zależności (2) i (3) wygenerowano 100-elementowy zbiór uczący składający się z par $[y_i(t_k), y_i(t_{k-1})]$, podawanych na wejścia sieci oraz par $[x_{mi}, x_{pi}]$ stanowiących postulowaną odpowiedź sieci, przy czym $i = 1, \dots, 100$. Elementy y_i zbioru uczącego poddano procesowi 12-bitowego kwantowania. Testowanie zasymulowanej sieci przeprowadzono za pomocą 100 000-elementowego zbioru testowego w wyniku czego uzyskano wartości błędów własnych sieci oraz ich histogram, które przedstawiono na rys. 6.



Rys. 6. Błędy własne neuronowego toru odtwarzania (wariant2): a) wykres błędów, b) histogram

Fig. 6. Own errors of the neural reconstruction chain (alternative 2): a) diagram, b) histogram

W tabeli 2 zestawiono wartości szerokości przedziału niepewności własnej sieci Δ_{w2} dla różnych wartości okresu dyskretyzacji T_d .

Tab. 2. Wartość szerokości przedziału niepewności własnej sieci Δ_{w2} w zależności od T_d / τ , $t_{k-1} = 0,1s$

Tab.2. Values of the interval range of the network own uncertainty Δ_{w2} as a function of T_d / τ , $t_{k-1} = 0,1s$

t_k [s]	T_d / τ	Δ_{w2}
0,20	0,50	0,033
0,15	0,25	0,035
0,12	0,10	0,036
0,11	0,05	0,042

5. Uwagi końcowe

Na podstawie przeprowadzonych badań można sformułować następujące spostrzeżenia. Dla małych odległości czasowych pomiędzy kolejnymi próbkami wprowadzanymi na wejścia sieci neuronowych lepszymi właściwościami metrologicznymi charak-

teryzuje się tor odtwarzania nazwany w artykule *wariantem 2*, czyli korekcja błędów statycznych i dynamicznych realizowana przez jedną sieć neuronową. Porównując wyniki zestawione w tabelach 1 i 2 można zauważyć, że wraz ze zmniejszaniem okresu dyskretyzacji gwałtownie rośnie wartość niepewności własnej toru odtwarzania w *wariancie 1*, czyli w sytuacji gdy korekcje błędów: statycznych i dynamicznych realizowane są kolejno przez dwie sieci. Jest to spowodowane tym, że do nauki sieci odtwarzania dynamicznego wykorzystywane są dane z wyjścia sieci odtwarzania statycznego, obarczone jej błędami własnymi oraz wzmocnionymi błędami kwantowania. Zatem wpływ błędów zbioru uczącego sieci odtwarzania dynamicznego na jej niepewność własną ujawnia się tym bardziej im bliżej, w sensie czasowym, znajdują się kolejne próbki podawane na jej wejście.

Z kolei w przypadku, gdy odległości czasowe pomiędzy kolejnymi próbkami są odpowiednio duże, lepszymi właściwościami metrologicznymi charakteryzuje się tor odtwarzania w *wariancie 1*. Powyższe spostrzeżenia nie mają charakteru ogólnego, jednak wskazują na pewne prawidłowości, które warto wziąć pod uwagę w sytuacjach stosowania sieci neuronowych do korekcji błędów dynamicznych.

6. Literatura

- [1] Jakubiec J., Makowski P., Roj J.: Sieć neuronowa jako element przetwornika próbkującego. Zeszyty Naukowe Politechniki Śląskiej, seria Elektryka, zeszyt Nr 195., Gliwice 2005, ss.75-90.
- [2] Jakubiec J., Roj J.: Model błędów sieci neuronowej jako ogniwa przetwarzania próbkującego. PAK, 7-8/2002, ss.33-36.
- [3] Jakubiec J., Roj J.: Pomiarowe przetwarzanie próbkujące. Podręcznik akademicki. Wydawnictwo Politechniki Śląskiej, Gliwice 2000.
- [4] Jakubiec J.: Bieżące programowe odtwarzanie wartości chwilowych dynamicznych przebiegów wejściowych nieliniowych przetworników pomiarowych. Zeszyty Naukowe Politechniki Śląskiej, zeszyt Nr 964, Gliwice 1988.
- [5] Kuma E.: Termistory - Parametry i Charakterystyki. Instytut Podstawowych Problemów Techniki PAN. Warszawa 1964.
- [6] Makowski P., Roj J.: Wpływ procesu uczenia na właściwości metrologiczne sieci neuronowej. XXXVII Międzynarodowa Konferencja Metrologów, Zielona Góra, 5-7 września 2005, Materiały konferencyjne, ss.225-232.
- [7] Makowski P.: Metrologiczne właściwości sieci neuronowej realizującej odtwarzanie w przetworniku próbkującym. XXXVII Międzynarodowa Konferencja Metrologów, Zielona Góra, 5-7 września 2005, Materiały konferencyjne, ss.233-242.
- [8] Morawski R. Z.: Zadania odwrotne w metrologii. Podstawowe Problemy Metrologii. Prace Komisji Metrologii Oddziału PAN w Katowicach. Seria: Konferencje, Nr 1. Gliwice-Ustroń, 1998, ss.37-49.
- [9] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT. Warszawa 1996.
- [10] Zakrzewski J.: Pomiary dynamiczne. XXXVII Międzynarodowa Konferencja Metrologów, Zielona Góra, 5-7 września 2005, Materiały konferencyjne, ss.9-28.