

Henryk URZĘDNICZOK

**ZASTOSOWANIE SIECI
NEURONOWEJ DO ROZWIĄZANIA
ZADANIA ODWROTNEGO
DLA PRZETWORNIKA
DWUPARAMETROWEGO
NIELINIOWEGO**

Streszczenie. W artykule przedstawiono zagadnienie odtwarzania wartości wielkości mierzonych (tzw. zadanie odwrotne) dla przetwornika dwuparametrowego nieliniowego przy wykorzystaniu sztucznej sieci neuronowej. Założono wprowadzanie wartości wielkości wyjściowych przetwornika na wejścia sieci przy wykorzystaniu przetworników analogowo-cyfrowych 8-bitowych. Opisano strukturę wykorzystanej sieci, wskazano na parametry sieci determinujące dokładność odtwarzania i przeanalizowano ich wpływ przy wykorzystaniu średniokwadratowej miary błędów odtwarzania. Podano wartości parametrów optymalne dla tego typu sieci. Uzyskane błędy odtwarzania nie przekraczają wartości osiąganych innymi metodami dla analogicznego przetwornika.

**1. PRZETWORNIK
WIELOPARAMETROWY
NIELINIOWY**

Przetwornik wieloparametrowy realizuje odwzorowanie wartości wielkości mierzo-

**APPLICATION OF NEURAL
NETWORK TO SOLUTION
OF THE INVERSE PROBLEM
FOR 2-D NON-LINEAR
CONVERTER**

Summary. The problem of reconstruction of converter input quantities is called the inverse problem. Solution of this problem for two-dimensional (2-D) non-linear converter by using artificial neural network is described in this paper. Delivery of converter output values to the network inputs by applying 8-bit A/D converters was assumed. Structure of the applied neural network is described, the important factors determining accuracy of reconstruction are pointed and their influence is analysed. The obtained optimal values of these parameters are given. The obtained errors of reconstruction do not exceed values from the other methods of reconstruction for the same type of converter.

**1. MULTI-DIMENSIONAL NON-
LINEAR CONVERTER**

The term „multi-dimensional sensor” means a sensor realising simultaneously


nych (wejściowych) $\mathbf{X} = [X_1, \dots, X_N]^T$ na wartości wielkości wyjściowych $\mathbf{Y} = [Y_1, \dots, Y_N]^T$. Istotne są przy tym dwie cechy takiego odwzorowania:

- 1) każda z wielkości wyjściowych Y_i ($i = 0, 1, \dots, N$) zależy od wszystkich wielkości wejściowych (w ogólnym przypadku),
- 2) wszystkie wielkości wejściowe są wielkościami mierzonymi, tzn. żadna z nich nie jest wielkością wpływającą, której wpływ na wyniki należy skorygować bądź też zminimalizować.

Obszar (zakres) przetwarzania wyznaczony jest przez wartości $X_i \in (X_{i\min}, X_{i\max})$. Wymagana jest wzajemna jednoznaczność odwzorowania realizowanego przez przetwornik wieloparametrowy w całym zakresie przetwarzania.

Przykład przetwornika dwuparametrowego przedstawiono w pracy [1].

Zadanie odwrotne [2] dla omawianego przetwornika polega na wyznaczeniu estymatorów \mathbf{X}^* wartości wielkości mierzonych w sposób przedstawiony na rys. 1.



Rys.1. Odtwarzanie wartości wejściowych dla przetwornika wieloparametrowego przy wykorzystaniu modelu odwrotnego

W tradycyjnym ujęciu odtwarzanie oparte jest na znajomości modelu przetwornika w chwili realizacji odtwarzania.

the conversion of input (measured) quantities $\mathbf{X} = [X_1, \dots, X_N]^T$ into output quantities $\mathbf{Y} = [Y_1, \dots, Y_N]^T$. Two properties of such a conversion are characteristic:

- 1) each of the output quantities Y_i ($i = 0, 1, \dots, N$) depends on all of the input quantities,
- 2) all of the input quantities are measured – it means that none of them is an influenced quantity, which should be compensated.

The range of conversion is as follows: $X_i \in (X_{i\min}, X_{i\max})$. The unambiguity of the realised conversion is required in the whole range of conversion.

An example of two-dimensional (2-D) converter is presented in the paper [1].

The inverse problem [2] for the considered converter means finding the best estimators \mathbf{X}^* of the measured quantity values, in the way shown in Fig. 1.

Fig.1. Reconstruction of input quantities values for multi-dimensional converter using the inverted model

The traditional methods of reconstruction require the inverted mathematical model to be known. Such an inverted

Model matematyczny przetwornika wyznaczany jest najczęściej na podstawie danych uzyskanych w procesie kalibracji. W ogólnym przypadku model analityczny zapisywany jest jako układ równań nieliniowych

$$Y_i = f_i(X_1, X_2, \dots, X_N); \quad i = 1 \dots N. \quad (1)$$

Odtwarzanie wartości wielkości mierzonych w sposób zilustrowany na rys.1 wymaga znajomości modelu odwrotnego

$$X_i^* = \varphi_i(Y_1, Y_2, \dots, Y_N); \quad i = 1 \dots N, \quad (2)$$

otrzymywanego przez rozwiązanie układu równań (1) ze względu na wielkości wejściowe X_i . Wyznaczenie modelu analitycznego przetwornika wieloparametrowego (lub też bezpośrednio modelu odwrotnego) wymaga stosowania zaawansowanych metod regresji nieliniowej, co nastręcza trudności obliczeniowe i jest przyczyną znacznych niepewności uzyskiwanych wyników.

Wykorzystanie aproksymacji liniowej w przedziałach (ściślej obszarach) wyznaczonych przez punkty kalibracji [3, 4] oparte jest na modelu w postaci tabelarycznej. Jak wykazano w pracy [4], przy stosowaniu tej metody odtwarzania możliwe jest uzyskanie niejednoznacznych wyników, co stwarza konieczność stosowania dodatkowych procedur weryfikacji. Niepewność uzyskanych wyników jest znaczna przy przetwornikach silnie nieliniowych. Zmniejszenie tej niepewności wymaga zwiększenia ilości punktów kalibracji, co w przypadku przetworników wieloparametrowych jest zadaniem pracochłonnym.

model can be determined by using data obtained in the calibration procedure. In general case, this mathematical model has a form of the system of non-linear equations


Reconstruction of the measured quantities values in the way illustrated in Fig.1 requires knowledge of the inverted model

which can be obtained by solving the system of equations (1) in relation to the input quantities X_i . The advanced methods of non-linear regression should be used to obtain the model (1) or (2), which causes computational difficulties and is the source of significant uncertainties.

Applying the linear approximation in the range between the calibration points [3, 4] is based on the tabular model. As it is shown in [4], it is possible to obtain ambiguous results. In this case it is necessary to use additional verification methods of the results. The uncertainty of the obtained results is significant when converter transfer functions are very non-linear. Reduction of this uncertainty is possible by increasing the number of calibration points, but this is very laborious.

2. ODTWARZANIE PRZY WYKORZYSTANIU SZTUCZNYCH SIECI NEURONOWYCH

Możliwe jest również odtwarzanie wielkości mierzonych bez znajomości jawnej postaci modelu przetwornika - przez zastosowanie sztucznych sieci neuronowych [2]. Wykorzystanie sztucznej sieci neuronowej do realizacji zadania odwrotnego dla przetworników wieloparametrowych pokazano na rys.2.



Rys.2. Odtwarzanie wartości wejściowych dla przetwornika wieloparametrowego przy wykorzystaniu sieci neuronowej

2. APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO RECONSTRUCTION

Application of artificial neural networks makes reconstruction of the measured values possible without knowing the analytical form of converter inverted model [2]. The idea of reconstruction by using neural networks is explained in Fig.2.

Fig.2. Reconstruction of measured quantities value by applying neural networks

Najistotniejsza zaleta stosowania sieci neuronowej do realizacji zadania odwrotnego dla przetworników pomiarowych wynika ze zdolności tego typu sieci do „uczenia się”. Dane uzyskane w procesie kalibracji przetwornika stanowią zbiór uczący, wykorzystywany w procesie uczenia sieci, który to proces realizowany jest według standardowych algorytmów uczenia. Po zakończeniu procesu uczenia sieć ma zdolność realizacji przetwarzania według modelu odwrotnego. Nie jest zatem konieczna znajomość jawnej postaci tego modelu.

Poniżej przedstawiono wyniki uzyskane przy zastosowaniu sieci opisanej skrótowo w pkt. 3.1, dobranej do realizacji

The possibility of „training” is the most important advantage of the neural network applied to solution of the inverse problem. The data obtained during the calibration procedure are the „training set” used during the training process which is realised according to the standard algorithms. After the training process is completed the network has ability to reconstruct the input values. The explicit form of the inverted model is not necessary.

The main goal of investigations was to verify the thesis, that it is possible to apply neural networks to reconstruction of the measured values of a 2-D non-linear converter with A/D converters at its out-

przedstawionego zadania na podstawie studiów literaturowych [5, 6]. Zasadniczym celem tych badań była weryfikacja tezy dotyczącej możliwości zastosowania sztucznych sieci neuronowych do realizacji odtwarzania wartości wielkości wejściowych przetwornika dwuparametrowego nieliniowego, w sytuacji gdy na wyjściach tego przetwornika zastosowano przetworniki analogowo-cyfrowe.

Badania przeprowadzono metodą symulacyjną, tzn. zarówno dane uczące jak i dane testowe uzyskane zostały na podstawie obliczeń według przyjętego modelu. Podejście takie pozwoliło na eliminację w trakcie badań wstępnych wpływu wielu czynników istotnych w omawianym zagadnieniu, przede wszystkim niepewności, którymi obarczone są wartości wielkości wejściowych i wyjściowych uzyskane w procesie kalibracji. Badania wpływu tych czynników przeprowadzone zostaną w toku dalszych prac nad omawianym zagadnieniem.

3. STRUKTURA TORU POMIAROWEGO Z PRZETWORNIKIEM DWUPARAMETROWYM

Na rysunku 3 przedstawiono strukturę toru pomiarowego, dla którego przeprowadzono badania możliwości wykorzystania sieci neuronowej do odtwarzania wartości mierzonych.

Założono zastosowanie przetworników A/C na wyjściach przetwornika i wprowadzanie danych do sieci neuronowej w postaci kodów binarnych. Ma to praktyczne uzasadnienie, ponieważ sieci neuronowe modelowane są najczęściej w postaci algo-

puts. The applied neural network is described in Section 3.1 and the obtained results are presented in Section 4.


The numerical simulation was used; it means that training data as well as testing data were calculated basing on the assumed analytical model. Such a method makes it possible to eliminate, during initial investigations, all additional influences existing in the physical model. However during further investigation these influences will be taken into consideration.

3. STRUCTURE OF THE MEASURING CHAIN WITH A 2-D CONVERTER

Fig.3 shows the structure of the considered measuring chain with a 2-D converter.

Applying A/D converters at the 2-D converter outputs was assumed, so the input data of the neural network are binary coded. This assumption is practically justified because neural networks are most often modelled as numerical algorithms which are realised by computers or microprocessors.

rytmów numerycznych realizowanych w urządzeniach cyfrowych (komputery, mikroprocesory). Przy takim rozwiązaniu nie jest zatem konieczne stosowanie procedur przetwarzania kodu binarnego na wyjściu przetworników analogowo-cyfrowych na liczby dziesiętne ani liczb dziesiętnych na wyjściu sieci na kod binarny.



Rys.3. Tor pomiarowy z przetwornikiem dwuparametrowym i siecią neuronową o binarnych wejściach

Fig.3. Measuring chain with 2-D converter and neural network with binary coded inputs

3.1. Opis zastosowanej sieci neuronowej

Każda z wielkości wyjściowych przetwornika Y_1 i Y_2 reprezentowana jest przez osiem bitów. Analogicznie przedstawiane są wielkości wyjściowe sieci X_1^* i X_2^* . W rezultacie sieć neuronowa posiada po 16 wejść i wyjść. Zastosowano odmianę sieci Hecht-Nielsen, określaną w literaturze nazwą Counter-Propagation. Jak wynika z opisów w literaturze [5, 6], sieć taka zdolna jest do uczenia się odwzorowań według zależności funkcyjnych między wektorami wyjściowymi i wejściowymi. Ze względu na dopuszczalne w przypadku przetworników dwuparametrowych znaczne wartości czułości skrośnych [2, 3], stosowana sieć musi mieć połączenia pełne,

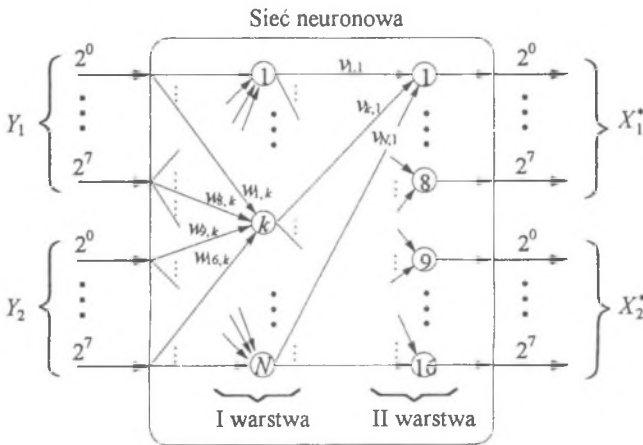
3.1. Description of the applied neural network

Both of the converter output quantities Y_1 and Y_2 and both of the network output values X_1^* and X_2^* are represented by 8 bits binary codes. So, the network has 16 inputs and 16 outputs. A type of Hecht-Nielsen network called Counter-Propagation was applied. As it is stated in [5, 6], such a network has ability to train the functional dependence between the input and output vectors. Because of possible large values of the cross-sensitivity [2, 3] the applied network must be full connected. The described network was modelled by using program MatLab with Neural Network Toolbox.

tn. każdy neuron warstwy wejściowej jest połączony z każdym wejściem. Do modelowania opisanej struktury sieci neuronowej zastosowano program Matlab z przybornikiem Neural Networks Toolbox.

Strukturę stosowanej sieci przedstawiono na rys.4. Sieć ta składa się z dwóch warstw. Pierwsza z nich (nazywana warstwą wejściową lub ukrytą) realizuje w procesie uczenia algorytm Kohonena [5, 6, 7], natomiast druga (wyjściowa) uczona jest według reguły „gwiazdy wyjść”. Symbole $w_{j,k}$ i $v_{k,n}$ oznaczają wartości wag kolejnych neuronów odpowiednio pierwszej i drugiej warstwy. Wartości te tworzą macierze oznaczane dalej \mathbf{W} i \mathbf{V} .

The structure of the applied network is shown in Fig.4 in details. It consists of two layers. In the training phase the first one (called a hidden layer) realises the Kohonen algorithm [5, 6, 7], whereas the second one (output) – the „output star” algorithm. The symbols $w_{j,k}$ and $v_{k,n}$ denote the weight values of the neurons in the first and second layers, respectively. These values compose matrices \mathbf{W} and \mathbf{V} .



Rys.4. Wewnętrzna struktura wykorzystanej sieci neuronowej

Fig.4. Structure of the applied neural network

Przygotowanie sieci do realizacji postawionego przed nią zadania (aproxymacji funkcji) wymaga poprawnego doboru wartości współczynników wagowych zawartych w macierzach \mathbf{W} i \mathbf{V} . Dokonywane to jest automatycznie w trakcie procesu ucze-

Preparation of the network to proper realisation of its job (approximation of a function) requires the proper choice of the weight coefficients in the matrices \mathbf{W} and \mathbf{V} . It is automatically made during the training process using the calibration

nia. Dane uczące uzyskane są w trakcie kalibracji prowadzonej dla wybranych punktów obszaru przetwarzania przetwornika dwuparametrowego. Nauka w całej sieci CP odbywa się pod nadzorem („z nauczycielem”). Wraz z każdym wektorem wejściowym \mathbf{Y} podawany jest oczekiwany wektor wyjściowy \mathbf{X} . Ciąg uczący przyjmuje zatem postać

$$\{ \langle \mathbf{Y}_1, \mathbf{X}_1 \rangle, \langle \mathbf{Y}_2, \mathbf{X}_2 \rangle, \dots, \langle \mathbf{Y}_p, \mathbf{X}_p \rangle \}, \quad (3)$$

gdzie p oznacza liczbę prezentowanych par wektorów (liczbę punktów wzorcowania).

Proces uczenia w rozpatrywanej sieci przebiega równocześnie w obu warstwach. Po zakończeniu uczenia sieć CP staje się optymalnie dobraną tablicą odwrotnej funkcji przetwarzania przetwornika dwuparametrowego $\mathbf{X}^* = \varphi(\mathbf{Y})$.

3.2. Model dwuparametrowego przetwornika nieliniowego

Badania odtwarzania z wykorzystaniem opisanej wyżej sieci neuronowej przeprowadzono przy założeniu następującej postaci modelu przetwornika nieliniowego dwuparametrowego:

$$\begin{cases} Y_1 = \text{int} \left[256 \left(0,7 X_1^2 + 0,3 \sqrt{X_2} \right) \right] \\ Y_2 = \text{int} \left[256 \left(0,4 \sqrt{X_1} + 0,6 X_2^2 \right) \right] \end{cases} \quad (4)$$

Operator $\text{int}(\dots)$ oznaczający wyznaczenie części całkowitej z wyrażenia w nawiasie i stała $256 = 2^8$ zostały przyjęte ze względu na założenie binarnego kodowania (8 bitów) wartości wyjściowych przetwornika. Unormowane względem zakresu wielkości wyjściowych charakterystyki przetwarzania pokazane są na rys.5.

points as the training data. The training of CP network is realised with a “trainer”, it means that with each input vector \mathbf{Y} the expected output vector \mathbf{X} is delivered. The training sequence has the following form:


where p is the number of the presented pairs of the vectors \mathbf{Y} and \mathbf{X} (number of the calibration points).

For the considered network the training process runs simultaneously in the both layers. Having finished this process the CP network becomes an optimally adjusted table of the inverted transfer function $\mathbf{X}^* = \varphi(\mathbf{Y})$ of the 2-D converter.

3.2. Model of a 2-D non-linear converter

The following form of a 2-D non-linear converter was assumed when making investigations:

The operator $\text{int}(\dots)$ means that the integer part of the expression in brackets is taken. This operation and constant $256 = 2^8$ were assumed considering 8-bit coding of the converter output values. In Fig.5 the normalised transfer plots are shown.



Rys.5. Unormowane charakterystyki przetwarzania modelu przetwornika przyjętego do badań

Na podstawie przyjętego modelu analitycznego wyliczano wartości wielkości wyjściowych dla założonych punktów wzorcowania (X_k, Y_k) . Liczba punktów wzorcowania była zmieniana.

4. WYNIKI BADAŃ

4.1. Metoda badań

Dokładność realizacji przez sieć neuronową zadania odtwarzania wartości wielkości wejściowych przetwornika zależy od efektywności procesu uczenia, a ta zależy od wielu czynników, z których najważniejsze to:

- odpowiedni dobór wielkości zbioru danych uczących (liczby punktów wzorcowania, ich ułożenia w obszarze przetwarzania),
- ustalenie optymalnej liczby neuronów warstwy ukrytej,




Fig.5. Normalised transfer plots of the assumed 2-D non-linear converter

Basing on the model (4) the values of the output quantities were calculated for the assumed points of calibration (X_k, Y_k) . The number of calibration points was changed.

4. RESULTS OF INVESTIGATION

4.1. The method of investigation

The accuracy of the input value reconstruction depends on the training process efficiency of the applied neural network. The most important factors influencing this efficiency are as follows:

- proper choice of the calibration points number (of the set of training data) and location of these points in the conversion range,
- choice of the optimal number of neurons in the hidden layer,

- określenie wartości parametrów charakteryzujących sieć (współczynników uczenia pierwszej i drugiej warstwy, początkowych wartości wag neuronów, postaci funkcji aktywacji),
- ustalenie czasu trwania nauki tzn. liczby prezentacji wektorów wejściowych (liczby iteracji).
- opracowanie kryteriów oceny procesu uczenia.

Badania symulacyjne prowadzono w celu sprawdzenia wpływu tych czynników na dokładność realizacji zadania odtwarzania dla przetwornika dwuparametrowego.

Błędy odtwarzania zdefiniowano w następujący sposób

$$\Delta_{X_i}(\mathbf{X}_t) = X_{ii}^* - X_{ii}, \quad (5)$$

przy $i = 1, 2$.

Wartości tak zdefiniowanych błędów zależą od wyboru punktu testowego $\mathbf{X}_t = [X_{1t}, X_{2t}]^T$ w obszarze przetwarzania. Nie jest celowe porównywanie wartości błędów dla pojedynczych punktów tego obszaru. Z tego względu przedstawione w dalszym ciągu wartości błędów dotyczą miary średniokwadratowej dla wszystkich punktów testowania \mathbf{X}_t wybranych równomiernie w całym obszarze przetwarzania, zdefiniowanej następująco

$$\bar{\Delta}_{X_i} = \sqrt{\frac{1}{T} \sum_{t=1}^T (X_{ii}^* - X_{ii})^2}, \quad (6)$$

przy $i = 1, 2$.

gdzie t jest numerem punktu testowania, a T oznacza ilość punktów testowania.

- proper determination of the network parameters (training coefficients of the first and second layers, initial weight of neurons, form of the activation function),
- training time (the number of input vector presentations, the number of iterations),
- criterion of the training process evaluation.

Influence of the above given factors on the accuracy of the inverse problem solution for a 2-D non-linear converter was investigated.

The reconstruction errors were defined as follows

for $i = 1, 2$.

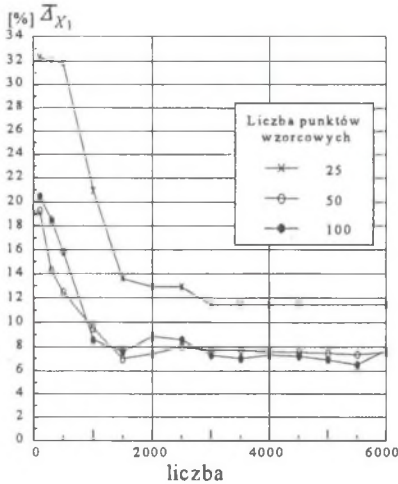
The values of such defined errors depend on the testing point $\mathbf{X}_t = [X_{1t}, X_{2t}]^T$ location in the conversion range. It is not purposeful to compare the values of errors for particular points in this range, so the rms measure of errors was taken into consideration. The definition of this measure was as follows

for $i = 1, 2$.

where t is an index of a testing point and T is the number of testing points.

4.2. Omówienie wyników

Na rysunkach 6 i 7 pokazano zależność przyjętej miary błędów odtwarzania w funkcji liczby iteracji przy różnej liczbie neuronów i danych uczących.



Rys. 6. Miary średniokwadratowe błędów odtwarzania w zależności od liczby iteracji dla 25 neuronów przy różnej liczbie punktów wzorcowych

Obliczenia te zostały przeprowadzone dla stałych i równych współczynników uczenia obu warstw sieci $\eta_1 = \eta_2 = 0,1$ oraz dla równomiernie wybranych punktów wzorcowych. Stosując 25 neuronów (rys. 6) wartość średniokwadratowa ustaliła się na poziomie 8% przy 50 punktach wzorcowych biorących udział w procesie uczenia. Zwiększając liczbę tych punktów do stu praktycznie nie uzyskano poprawy wyników. Natomiast zbyt mała liczba punktów wzorcowych (25) powoduje, że sieć nie potrafi się prawidłowo zorganizować, tzn.

4.2. Discussion of the results

Figs. 6 and 7 show the rms measure of the reconstruction errors the versus the number of iteration, for different numbers of neurons and testing points.


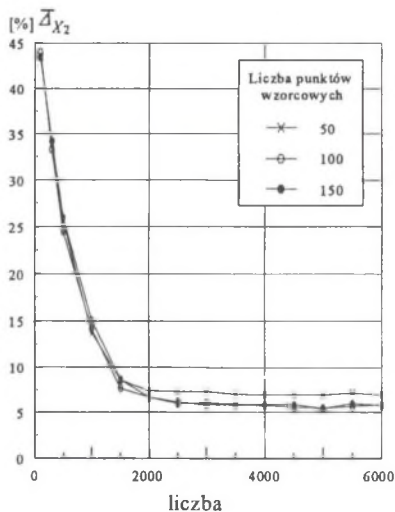



Fig. 6. Rms values of the reconstruction errors versus the number of iteration for 25 neurons and different number of calibrating points

The calculations were performed under assumption that the training coefficients in the both network layers are constant ($\eta_1 = \eta_2 = 0,1$) and the calibrating points are regularly located in the conversion range. If 25 neurons were used (Fig. 6) the rms. measure of the errors became established at the level of 8% when 50 calibrating points were taken to train the network. Increase in the number of calibration points up to 100 did not lead to improvement of the results. However, if there are too few calibrating points (25)

wagi neuronów nie są w procesie uczenia dobrane w sposób optymalny, co powoduje, że błędy odtwarzania są wyraźnie większe.

the network is not able to organise itself correctly, i.e. the weights of neurons are not optimally chosen during the training process, which causes greater reconstruction errors.



Rys.7. Miary średniokwadratowe błędów odtwarzania w zależności od liczby iteracji dla 75 neuronów przy różnej liczbie punktów wzorcowych


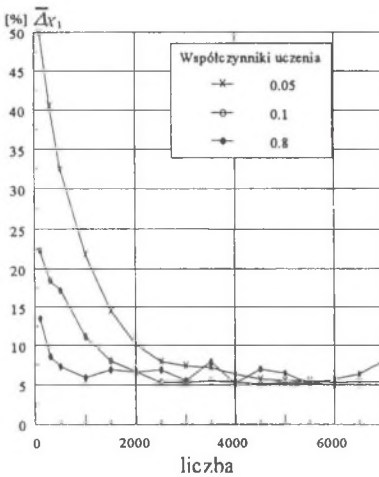
Fig.7. Rms values of the reconstruction errors versus the number of iteration for 75 neurons and different number of calibrating points

Wyniki uzyskane dla 75 neuronów przedstawiono na rys.7. Większa liczba neuronów umożliwia zauważalne zmniejszenie błędów odtwarzania - są one rzędu 5-6%. Wzrost liczby punktów wzorcowych z 50 do 100 daje zauważalną różnicę, w przeciwieństwie do sytuacji widocznej na rys.6. Dalsze zwiększanie liczby neuronów nie powoduje istotnego zmniejszenia błędów, nawet przy większej liczbie punktów wzorcowych.

The results obtained for 75 neurons are shown in Fig.7. It can be stated that in this case increase in the calibration points number from 50 to 100 makes the errors decrease noticeably (to the level of 5-6%) – in contrast to the case shown in Fig.6. Further increase in the neuron number does not cause significant decrease of the errors, even when the number of calibration points grows.

Kolejnym czynnikiem wpływającym na proces optymalizacji są wartości współczynników uczenia η_1 i η_2 . Dobór zbyt dużych współczynników (np. 0,8) powoduje, że przy zwiększaniu liczby iteracji nie uzyskuje się asymptotycznego zmniejszania błędów odtwarzania (rys.8). Zbyt małe współczynniki (np. 0,05) wymagają większej liczby iteracji, co wydłuża czas nauki, nie poprawiają przy tym rezultatów.

The next factor which influences the training process optimisation is the values of the training coefficients η_1 , η_2 . If these coefficients are too large (e.g. 0,8), then increase in the iteration number does not lead to asymptotic decrease of the errors (see Fig.8). If the training coefficients are too small, the greater number of iterations is required – this extends the time of training, but the results are not better.




Rys.8. Wpływ współczynników uczenia na zbieżność procesu uczenia dla 50 neuronów i 100 punktów wzorcowych

Fig.8. Influence of „training” coefficient on the convergence of training process for 50 and 100 neurons

Przeprowadzone badania wskazują również na znaczący wpływ sposobu wyboru danych uczących na przebieg procesu uczenia i w efekcie błędy odtwarzania. Równomierny wybór punktów wzorcowych pozwala uzyskać lepsze wyniki niż wybór przypadkowy. Typową sytuację, która potwierdza powyższe stwierdzenie, pokazano na rys.9

The investigations show that the method of choice of the training data has significant influence on the training process results and the reconstruction errors. The uniform choice of the calibration points leads to better results than the random one. This statement is illustrated in Fig.9.



Rys.9. Wpływ sposobu wyboru punktów wzorcowych w obszarze przetwarzania na wartości błędów odtwarzania

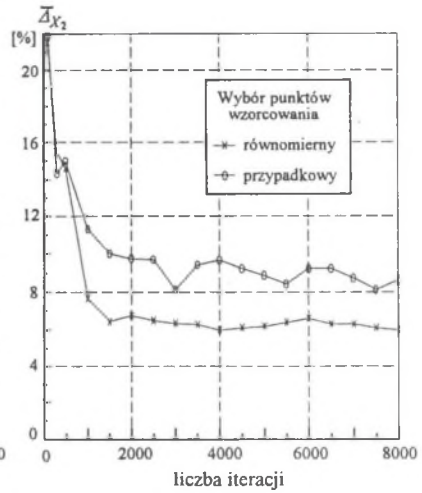


Fig.9. Influence of the method of calibration points choice onto reconstruction errors

5. PODSUMOWANIE

Zastosowanie sieci neuronowej opisanej w p. 3.1, o strukturze wejść przystosowanej do przyjmowania kodów binarnych 8-bitowych, do odtwarzania wielkości wejściowych nieliniowego przetwornika dwuparametrowego umożliwia osiągnięcie błędów odtwarzania wg miary średniokwadratowej (zał. 6) na minimalnym poziomie rzędu 5%. Możliwe to jest przy optymalnym doborze szeregu parametrów wymienionych w punkcie 4.1.

Z przeprowadzonych badań wynika, że optymalna ilość neuronów w warstwie wejściowej jest rzędu 75, ilość punktów wzorcowania 100, wybranych równomiernie w obszarze przetwarzania, liczba iteracji w

5. CONCLUSIONS

Application of the neural network described in Section 3.1 to reconstruction of the values of 2-D non-linear input quantities allows to reach the minimum error (6) at the level of 5%. The optimal choice of parameters mentioned in Section 4.1 is necessary.

For the investigated type of the network the optimal values of the investigated factors are as follows:

- the number of neurons in the input layer – about 75,
- the number of calibration points - about 100, uniformly located in the conversion range,

procesie uczenia sieci 2000-4000, przy współczynnikach uczenia $\eta_1 = \eta_2 = 0,1$.

Podana wartość średniokwadratowej miary błędu jest dość znaczna, lecz zastosowanie innych metod, np. opisanej w [4] metody aproksymacji funkcjami liniowymi w obszarach pomiędzy punktami wzorcowania daje podobne rezultaty. Istotny wpływ na wartość tych błędów ma prawdopodobnie założona niewielka rozdzielczość przetworników A/C na wyjściach przetwornika dwuparametrowego – szczególnie wobec znacznej złożoności obliczeniowej procedur odtwarzania, niezależnie od ich rodzaju. To zagadnienie wymaga dalszych badań.

- the number of iterations 2000-4000,
- the training coefficients –
 $\eta_1 = \eta_2 \approx 0,1$.

The above given minimum value of the rms error measure is on comparable level with the results of other methods i.e. the method of linear approximation described in [4]. Relatively high value of this measure is probably caused by the assumption of the 8-bit resolution of A/D converters at the outputs of a 2-D converter - especially because of the computational complication of the reconstruction procedures. This problem should be further investigated.

LITERATURA

REFERENCES

1. Zakrzewski J.: A new magnetoelastic transducer for Torque and force measurement. IEEE Instrumentation and Measurement Technology Conference, Brussels, June 4-6, 1996.
2. Morawski R.: Zadania odwrotne w metrologii. Mat. konferencji „Podstawowe problemy metrologii”, Gliwice-Ustroń, 1998, ss.37-49.
3. Urzędniczek H.: Ograniczenia metrologiczne związane z wrażliwością wzajemną czujników wieloparametrowych, Referat na Sympozjum nt. Elektryczne pomiary dokładne, Gliwice 1997 (mat. niepublikowane).
4. Urzędniczek H.: Odtwarzanie wartości wielkości wejściowych przetwornika dwuparametrowego nieliniowego, ZN Politechniki Śląskiej, ser. Elektryka, z. 165, Gliwice 1999.
5. Tadeusiewicz R.: Sieci neuronowe, Akademicka Oficyna Naukowa, Warszawa, 1993.
6. Ossowski S.: Sieci neuronowe w ujęciu algorytmicznym, WNT, Warszawa 1996.
7. Neural Networks Toolbox For use with Matlab. Users Guide, The Math Works Inc.

Recenzent: Dr hab. inż. Janusz GAJDA

Wpłynęło do Redakcji dnia 2 czerwca 1999 r.