

Piotr ADAMIEC
Kazimierz WITASZEK
Mirosław WITASZEK

ZASTOSOWANIE SIECI NEURONOWEJ DO ROZPOZNAWANIA STRUKTURY ŻELIWA SFEROIDALNEGO UŻYWANEGO NA WALKI ROZRZĄDU

Streszczenie. W pracy opisano przykłady zastosowania sieci neuronowych do rozpoznawania struktury żeliwa sferoidalnego. Rozpoznawano próbki na podstawie siedemnastu parametrów geometrycznych wtrąceń grafitu. Przedstawiono wyniki otrzymane w trzech typach sieci neuronowych różniących się liczbą warstw ukrytych.

USE OF NEURAL NETWORKS AS A TOOL FOR STRUCTURE DETECTION OF SPHEROIDAL GRAPHITE CAST IRON

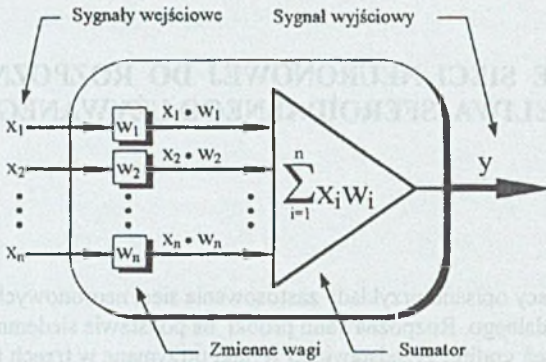
Summary. Article describes an example of use neural network for structure detection of spheroidal graphite cast iron on the basis of 17 parameters of the structure. Three different types of network have been used. For different types different times of learning and different values of errors have been obtained.

1. WPROWADZENIE

Sztuczne sieci neuronowe (SSN) są obecnie wykorzystywane do znajdowania rozwiązań wielu problemów badawczych [1,2,3,4]. Sieci te składają się z połączonych wzajemnymi relacjami sztucznych neuronów. Sztuczne neurony są uproszczonymi modelami komórek nerwowych występujących w przyrodzie [1]. Stanowią one jednostki przetwarzające informacje. Wyróżniamy w nich szereg sygnałów wejściowych x_i oraz jeden sygnał wyjściowy y , który najczęściej jest sygnałem wejściowym dla innych neuronów. Poszczególne sygnały wejściowe nie muszą mieć jednakowego wpływu na sygnał wyjściowy. Wpływ ten określany jest za pomocą współczynnika zwanego wagą (rys. 1).

Każdemu sygnałowi wejściowemu x_i jest przyporządkowana indywidualna waga w_i . Jeżeli wartość bezwzględna wagi jest większa od 1, to mamy do czynienia ze wzmocnionym wpływem danego sygnału wejściowego na wyjściowy. Jeśli wartość ta jest mniejsza od 1, to występuje

„tłumienie” w w. wpływu. Współczynnik wagi może przyjmować wartości dodatnie lub ujemne. W przypadku ujemnej wartości wagi wejście takie nazywa się „hamującym” [2]. Po uwzględnieniu wag sygnały wejściowe są sumowane dając sygnał zwany łącznym pobudzeniem neuronu e [1]. Może być ono traktowane jako sygnał wyjściowy (neurony liniowe) lub podlegać dalszej obróbce wewnątrz neuronu. Sposób tej obróbki określa charakterystykę neuronu, czyli zależność sygnału wyjściowego od łącznego pobudzenia. Charakterystyka neuronu nosi również nazwę funkcji przejścia.



Rys. 1. Schemat komórki neuronowej (neuron liniowy)


Fig. 1. Scheme of neural cell (linear cell)

Najprostsze w budowie są neurony liniowe (rys. 1), dla których obowiązuje zależność

$y = \sum_i^n x_i w_i$. Mają one jednak najskromniejsze możliwości. Neuron nieliniowy przetwarza

informacje wejściowe według zależności $y = \varphi(e)$, gdzie $e = \sum_i^n x_i w_i$. Sieci zbudowane z neuronów o nieliniowej funkcji przejścia mogą rozwiązywać zdecydowanie szerszą klasę problemów [1]. Do budowy sieci często używane są neurony o charakterystyce

sigmoidalnej $y = \frac{1}{1 + \exp(-\beta e)}$. Schemat neuronu nieliniowego przedstawiono na rys. 2.



Rys. 2. Schemat neuronu nieliniowego

Fig. 2. Scheme of non-linear neural cell

W literaturze opisano wiele przykładów wykorzystania sztucznych sieci neuronowych w systemach wnioskowania o właściwościach badanych obiektów [1,2,3]. Należy podkreślić, że zastosowanie SSN w takim systemie może zaowocować znaczną obiektywizacją i automatyzacją procesów wnioskowania i diagnozowania. W ramach niniejszej pracy przedstawiono zastosowanie SSN do budowy systemu rozpoznawania struktury żeliwa sferoidalnego stosowanego na samochodowe wałki rozrządu.


2. SIEĆ NEURONOWA W SYSTEMIE PRZETWARZANIA DANYCH

Sztuczne sieci neuronowe umożliwiają zapis skomplikowanych związków pomiędzy zmiennymi obiektu, którym może być np. odlew z żeliwa sferoidalnego. Zastosowano SSN do rozpoznawania struktury żeliwa sferoidalnego stosowanego na samochodowe wałki rozrządu.

Podstawowe zadania w procesie projektowania sztucznej sieci neuronowej, to [2]:

- ⇒ określenie struktury sieci,
- ⇒ określenie modeli neuronów,
- ⇒ właściwy dobór danych wejściowych i wyjściowych,
- ⇒ dobór metody uczenia sieci,
- ⇒ dobór parametrów uczenia sieci.

W praktyce są najczęściej stosowane wielowarstwowe sztuczne sieci neuronowe, które oprócz warstwy wejściowej i wyjściowej posiadają również warstwy ukryte. Schemat takiej SSN przedstawiono na rysunku 3.



Rys. 3. Schemat wielowarstwowej sztucznej sieci neuronowej

Fig. 3. Scheme of multi-layer artificial neural network

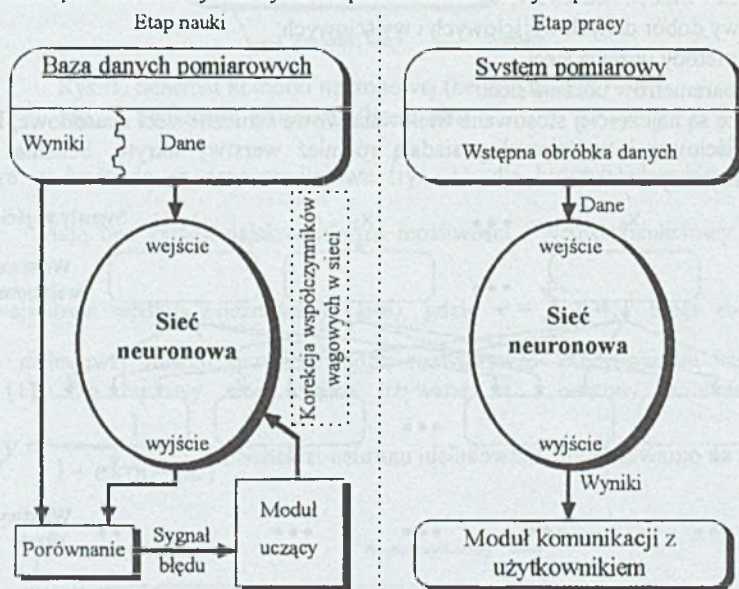
Ilość neuronów w warstwach i sposób połączeń pomiędzy warstwami określają strukturę sieci. Szczególnie ważny jest odpowiedni dobór warstw ukrytych - to głównie one biorą udział w rozwiązywaniu postawionego przed SSN zadania. Zastosowano najprostsze w budowie sieci o

strukturze połączeń typu „każdy z każdym”. Takie postępowanie prowadzi do zwiększenia rozmiarów sieci, ale upraszcza proces technicznej jej realizacji [1]. W procesie uczenia sieci połączenia „nadmiarowe” mogą być logicznie przerwane poprzez ustawienie współczynnika wagi $w_i = 0$. Wielkość sieci można dobrać jedynie eksperymentalnie, stosując wzajemnie sprzeczne kryteria minimalizacji czasu uczenia i minimalizacji błędu popełnianego przez sieć. Należy zauważyć, że sieć o zbyt małej liczbie neuronów nie będzie w stanie rozwiązać postawionego przed nią zadania, natomiast zbyt duże rozmiary sieci źle wpływają na wyniki procesu uczenia. Wprawdzie taka sieć uczy się szybko, lecz wiedza w niej zgromadzona nie ma charakteru uniwersalnego. Wyniki są poprawne tylko dla danych występujących w procesie uczenia. W literaturze taki efekt jest nazywany „uczeniem się na pamięć” [1,2].

Model neuronów tworzących sieć ma również wpływ na uzyskiwanie wyniki. Charakterystyka neuronu musi być funkcją ciągłą i różniczkowalną, co umożliwia przeprowadzenie procesu

uczenia sieci wielowarstwowych. Często stosowana jest funkcja sigmoidy
$$y = \frac{1}{1 + \exp(-\beta e)}$$

Sieć neuronowa jest najczęściej jednym z modułów składowych większego systemu przetwarzania danych. Do poprawnej pracy sieci wymagane są dodatkowe bloki funkcjonalne - szczególnie na etapie nauki. Przykład systemu przetwarzania danych przedstawiono na rys. 4.



Rys. 4. System przetwarzania danych wykorzystujący sieć neuronową


Fig. 4. System of data processing with the aid of neural network

Dane eksperymentalne pogrupowane w tablice są wykorzystywane do uczenia oraz egzaminowania sieci. W procesie uczenia SSN często wykorzystany jest algorytm wstecznej propagacji błędów (backpropagation). W trakcie uczenia następuje stopniowa modyfikacja współczynników wagowych na wejściach neuronów, które początkowo są przydzielane losowo w przedziale $(-0,1 \dots 0,1)$ z wyłączeniem wartości zero. Podkreślić należy, że odpowiednio zmodyfikowane w procesie uczenia współczynniki wag stanowią bazę „wiedzy” sieci neuronowej.

Parametry procesu uczenia należy odpowiednio dobrać tak, aby uzyskać jak największą jego efektywność. Podstawą oceny stopnia wyszkolenia sieci mogą być okresowo przeprowadzane egzaminy na ciągach danych nie występujących w procesie uczenia. Innym sposobem jest śledzenie błędów popełnianych przez sieć. Spadek średniego błędu poniżej przyjętego kryterium może również determinować zakończenie procesu uczenia sieci.


3. ROZPOZNAWANIE STRUKTURY ZA POMOCĄ SIĘCI NEURONOWYCH

W ramach niniejszej pracy wykonano oraz przetestowano sieci neuronowe o różnej budowie i wielkości. Obiektem do rozpoznania dla SSN były zdjęcia metalograficzne zglądów nietrawionych próbek z żeliwa sferoidalnego stosowanego na wałki rozrządu. Przykładowe zdjęcia próbek zamieszczono na rysunkach 5,6,7.




Rys. 5. Przykładowe zdjęcia próbki 1 (pow. ok. 100x)

Fig. 5. An example of photographs of specimen 1 (magnification 100x)



Rys. 6. Przykładowe zdjęcia próbki 2 (pow. ok. 100x)

Fig. 6. An example of photographs of specimen 2 (magnification 100x)



Rys. 7. Przykładowe zdjęcia próbki 3 (pow. ok. 100x)

Fig. 7. An example of photographs of specimen 3 (magnification 100x)

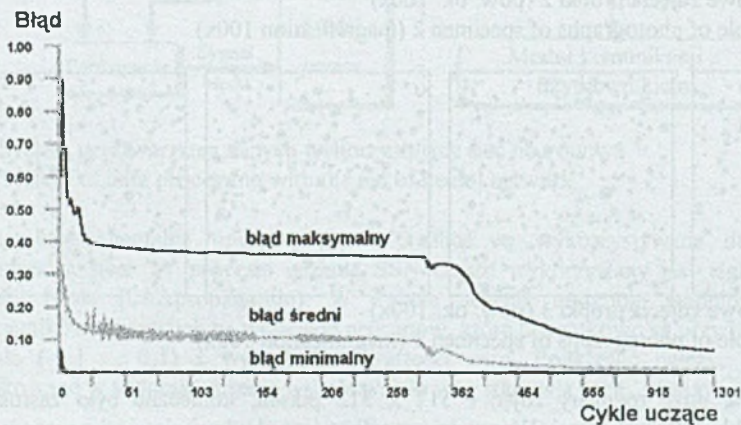
Ze względu na duże rozmiary zdjęć - 512 x 512 pikseli, konieczne było zastosowanie dodatkowej obróbki informatycznej. Wprawdzie możliwe jest zbudowanie sieci neuronowej, dla

której danymi wejściowymi są bezpośrednio obrazy graficzne w formie bitmapy, lecz sieci te charakteryzują się znacznymi rozmiarami. W rozpatrywanym przypadku tylko warstwa wejściowa musiałaby składać się z $512 \times 512 = 262\,144$ neuronów. Tak duże sieci charakteryzują się bardzo powolnym działaniem oraz jeszcze powolniejszym przebiegiem procesu uczenia się. Aby zminimalizować rozmiary sieci, postanowiono jako dane wejściowe podawać cechy geometryczne grafitu sferoidalnego. Do przetworzenia obrazu graficznego na zbiór cech geometrycznych grafitu użyto specjalistycznego oprogramowania „Met-ilo” autorstwa dr inż. J. Szali. W wyniku obróbki zdjęć otrzymano następujące 17 parametrów wtrąceń grafitu w próbce: liczba, pole, obwód, udział objętościowy, wskaźnik kształtu, wydłużenie, pole wypukłe, obwód wypukły, kształt wypukły, średnice Fereta w kierunkach 0° , 45° , 90° , 135° , 180° , średnica minimalna, średnica maksymalna, nachylenie średnicy maksymalnej oraz minimalnej. Dzięki temu warstwa wejściowa sieci składa się z siedemnastu neuronów. Warstwę wyjściową tworzą 3 neurony, każdy odpowiedzialny za detekcję próbki, z której pochodzą dane. Pomiedzy warstwami wejściową i wyjściową mogą znajdować się warstwy ukryte. Tak skonstruowane sieci były poddane procesowi uczenia po wstępnej optymalizacji parametrów tego procesu. Nauka sieci kończyła się automatycznie w momencie osiągnięcia zakładanego minimum średniego błędu popełnianego przez sieć $d_{SR} < 0,01$.

Najprostsza sieć została pozbawiona warstw ukrytych, składa się więc tylko z warstwy wejściowej i wyjściowej. Jest więc to sieć w konfiguracji 17-3 (17 neuronów w warstwie wejściowej i 3 neurony w warstwie wyjściowej). Stwierdzono, że jest możliwe pomyslnie zakończenie procesu nauki nawet dla tak małej sieci, jednak proces ten jest długi (ok. 1300 cykli uczących), a maksymalny błąd generowany przez sieć jest na poziomie prawie 7%.

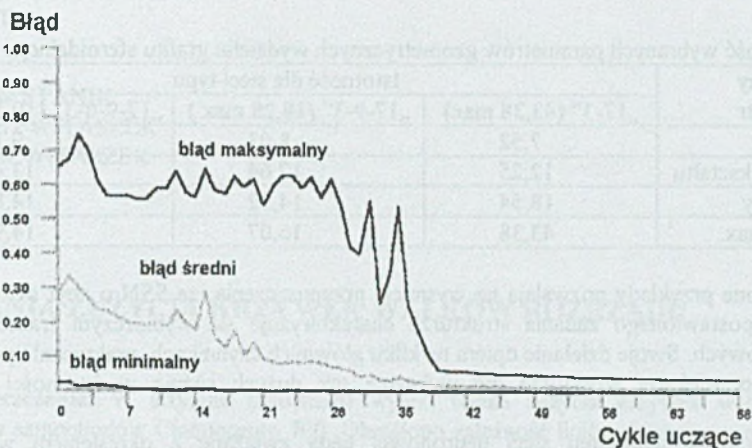
Procesowi uczenia o tych samych parametrach poddano również SSN z jedną warstwą ukrytą składającą się z dziewięciu neuronów. Ich liczba została dobrana eksperymentalnie. Sieć w konfiguracji 17-9-3 uczyła się znacznie sprawniej. Do zakończenia procesu uczenia wystarczyło niecałe 70 cykli uczących. Maksymalny błąd generowany przez sieć był na poziomie 3,5%. Na tym przykładzie można zaobserwować korzyści płynące ze stosowania warstw ukrytych w SSN.

Dla sieci w konfiguracji 17-9-6-3 (o dwóch warstwach ukrytych) konieczna była modyfikacja parametrów procesu uczenia. Pomimo zastosowaniu łagodniejszego uczenia sieć osiągała dobre wyniki już po ok. 120 cyklach uczących. Błąd maksymalny generowany przez taką sieć nie przekraczał 2,5%. Dalsze zwiększanie liczby warstw ukrytych lub liczby neuronów w warstwie owocowało niewielkimi spadkami błędów maksymalnych. Pociągało za sobą jednak przedłużenie procesu uczenia, wyrażonego w liczbie cykli uczących, oraz znaczny wzrost czasu uczenia. Wykresy przebiegu procesu uczenia sieci przedstawiono na rysunkach 8, 9, 10.




Rys. 8. Przebieg procesu uczenia sieci w konfiguracji 17-3

Fig. 8. Learning process of network type 17-3



Rys. 9. Przebieg procesu uczenia sieci w konfiguracji 17-9-3

Fig. 9. Learning process of network type 17-9-3



Rys. 10. Przebieg procesu uczenia sieci w konfiguracji 17-9-6-3

Fig. 10. Learning process of network type 17-9-6-3

4. UWAGI KOŃCOWE

Sztuczne sieci neuronowe stanowią nowe i atrakcyjne narzędzie informatyczne, które może służyć do wspomagania procesu rozpoznawania struktury żeliwa sferoidalnego. Ich zalety polegają na możliwościach równoległego rejestrowania i przetwarzania danych w procesie uczenia bez konieczności programowania.

Powstałe w wyniku badań sieci neuronowe potrafiły w sposób zadowalający rozpoznać strukturę żeliwa sferoidalnego stosowanego na wałki rozrządu. Umożliwiły ocenę parametrów geometrycznych grafitu, min. jego udział, średnicę wydzielin, współczynnik kształtu, które zestawiono w tablicy 1.

Tablica 1

Istotność wybranych parametrów geometrycznych wydzielin grafitu sferoidalnego

Wybrany parametr	Istotność dla sieci typu		
	„17-3” (43,38 max)	„17-9-3” (18,28 max)	„17-9-6-3” (19,15 max)
Udział W [%]	7,52	8,03	9,16
Współczynnik kształtu	12,25	17,64	13,48
Pole wydzielin	18,54	14,52	14,80
Kąt średnicy max.	43,38	16,07	14,99

Przedstawione przykłady pozwalają na wysnucie przypuszczenia, że SSN o zbyt skromnej w stosunku do postawionego zadania strukturze charakteryzuje się wybiórczym traktowaniem danych wejściowych. Swoje działanie opiera na kilku głównych czynnikach, praktycznie pomijając resztę. Sieci o większej strukturze nie wykazują tak dużych różnic w istotności danych wejściowych.

Kolejne kroki w nauczaniu sieci neuronowej będą związane z określeniem własności użytkowych żeliw sferoidalnych przeznaczonych na wałki rozrządu i ich optymalizacją.

Literatura

1. Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza, PL, Warszawa 1998.
2. Adamiec P.: Sieci neuronowe jako wspomaganie komputerowe oceny połączeń spawanych w energetyce. XI Międzynarodowa Konferencja Spawanie w Energetyce. Trnava - Opole 1999, s.123 - 127.
3. Piecha J., Kopicera K.: Sieć neuronowa dla wspomagania diagnozy patologii narządów ruchu. Praca Instytutu Informatyki UŚI., Katowice 1999.
4. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
5. PN-78/H-83142. Żeliwo sferoidalne niskostopowe i średniostopowe. Gatunki.

Recenzent: Dr hab. inż. Jan Piecha

Abstract

Artificial neural networks are new and attractive informatic tools, which can be used for solving wide range of scientific problems. In this work neural networks have been used for detection of structure of spheroidal graphite cast iron. Three types of networks with different number of hidden layers have been used. As input data 17 parameters of iron structure have been taken. All used networks can detect properly the structure of specimens.