

Kazimierz WITASZEK, Mirosław WITASZEK, Stanisław WITASZEK

## MODELOWANIE WŁAŚCIWOŚCI MECHANICZNYCH ŻELIWA SFEROIDALNEGO ZA POMOCĄ SIECI NEURONOWYCH

**Streszczenie.** W artykule przedstawiono zasady zastosowania sieci neuronowych do prognozowania podstawowych właściwości mechanicznych żeliwa sferoidalnego, tj. wytrzymałości na rozciąganie i wydłużenia względnego. Takie modelowanie może znaleźć zastosowanie przy określaniu właściwości materiału odlewów, z których pobranie próbek do badań jest utrudnione.

## MODELLING OF SPHEROIDAL GRAPHITE CAST IRON MECHANICAL PROPERTIES WITH THE AID OF NEURAL NETWORKS

**Summary.** This paper presents rules of neural networks use for forecasting of main mechanical properties of spheroidal graphite cast iron i.e. tensile strength and unit elongation. Such modelling is useful to determine these material properties for castings that machining the tensile test specimens is difficult.

### 1. WPROWADZENIE

Podstawowe wymagania stawiane żeliwu sferoidalnemu są określone w normie PN-EN 1563:2000. Wśród tych właściwości ważną rolę odgrywają wytrzymałość na rozciąganie i wydłużenie względne. Właściwości te są podstawą klasyfikacji żeliwa. Zgodnie z normą wyznacza się je na podstawie badań próbek pobranych ze specjalnych wlewków próbnych. Ze względu na różne warunki krzepnięcia i stygnięcia, a tym samym różną strukturę właściwości takich wlewków, mogą znacznie odbiegać od właściwości rzeczywistych odlewów. W pracy zaproponowano uzupełnienie wyników badań opartych na normie o modelowanie wytrzymałości na rozciąganie i wydłużenia względnego, na podstawie wyników badań przeprowadzonych na próbkach bez przeprowadzania próby wytrzymałości na rozciąganie. Korzystając z prac [1, 2] zaproponowano określanie wytrzymałości na rozciąganie oraz wydłużenia względnego odlewu na podstawie składu chemicznego, twardości oraz cech morfologicznych wydzielen grafitu.

Jednym z nowoczesnych narzędzi wykorzystywanych w tym kierunku w wielu dziedzinach nauki są sztuczne sieci neuronowe (SSN). Znajdują one zastosowanie do rozwiązywania wielu problemów badawczych, szczególnie tam, gdzie brak jest formuł matematycznych lub analityczny opis obiektów czy procesów nie jest możliwy, bądź znacznie utrudniony [3]. Względy te zadecydowały o podjęciu próby zastosowania sieci neuronowych do określania właściwości mechanicznych żeliwa sferoidalnego.

## 2. BUDOWA CIĄGÓW UCZĄCYCH I TESTUJĄCYCH

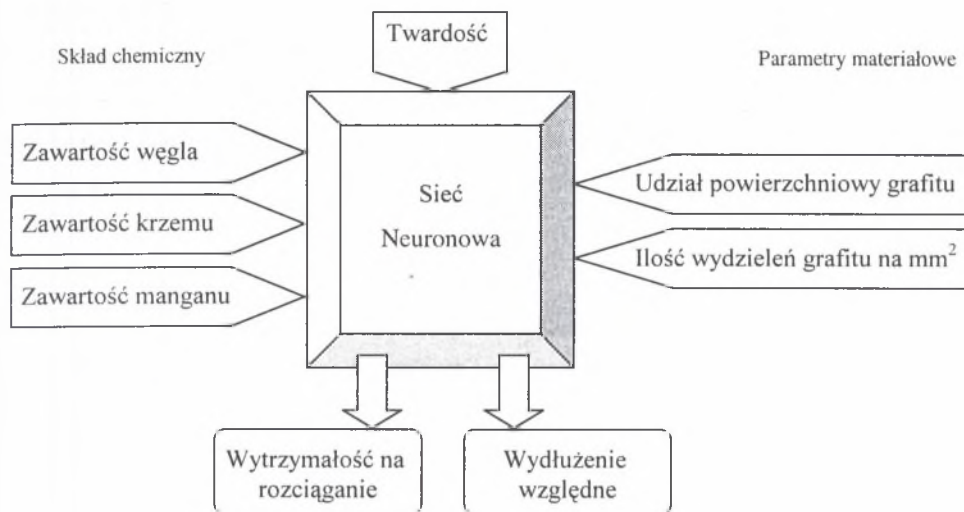
W celu uzyskania neuronowego modelu właściwości mechanicznych żeliwa sferoidalnego konieczne było przeprowadzenie procesu uczenia sieci neuronowych, co wymagało przygotowania zestawu danych tworzących tzw. ciągi uczące i testujące. W tym celu wykorzystano wyniki badań składu chemicznego oraz podstawowych właściwości mechanicznych żeliwa sferoidalnego pozyskane z kilku krajowych odlewni. Wyniki te uzupełniono o cechy morfologii wydzielen grafitu, określone na podstawie analizy obrazów mikrostruktury zglądów nietrawionych. Ze względu na znaczną ilość możliwych składowych wektora wejściowego  $X$  konieczne było dokonanie wyboru czynników najistotniejszych. Wykorzystano w tym celu między innymi informacje zawarte w pracach [1, 2]. Jako parametry wejściowe modelu przyjęto:

- twardość żeliwa określaną metodą Brinella,
- zawartość C, Si, Mn, tj. pierwiastków wywierających istotny wpływ na właściwości mechaniczne żeliwa,
- powierzchniowy udział grafitu,
- liczbę wydzielen grafitu przypadającą na jednostkę powierzchni ( $1 \text{ mm}^2$ ).

Natomiast jako parametry wyjściowe w modelu przyjęto:

- wytrzymałość na rozciąganie  $R_m$ , MPa,
- wydłużenie względne  $A_5$ , %.

Wzajemne zależności pomiędzy parametrami wejściowymi i wyjściowymi rozważanego modelu neuronowego przedstawiono na rys. 1.



Rys. 1. Wielkości wejściowe i wyjściowe modelu neuronowego właściwości mechanicznych żeliwa sferoidalnego

Fig. 1. Input and output quantities of neural model of spheroidal graphite cast iron mechanical properties

Zgromadzona ilość danych badawczych pozwoliła na utworzenie ciągu uczącego o długości 97 przykładów oraz ciągu testującego, obejmującego 31 wzorców.

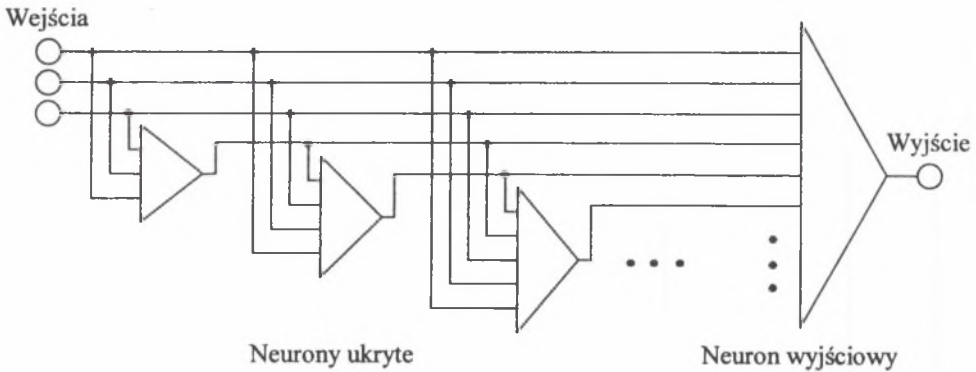
### 3. DOBÓR STRUKTURY I UCZENIE SIECI

Do symulacji sieci neuronowych wykorzystano profesjonalny program - Stuttgart Neural Network Simulator (SNNS v4.2), opracowany przez Uniwersytety w Stuttgarcie i Tübingen [6]. Wybór taki podyktowany był szerokimi możliwościami programu, obejmującymi prawie 40 metod uczenia sieci różnych typów. Ponadto program jest szybki w działaniu, co miało szczególnie znaczenie w przypadku sieci o rozbudowanej strukturze.

Ilość wejść i wyjść sieci została ustalona przy wyborze wielkości wejściowych i wyjściowych. Rozpatrzono dwa możliwe warianty:

- modelowanie wytrzymałości na rozciąganie oraz wydłużenia żeliwa za pomocą jednej sieci,
- modelowanie dwóch oddzielnych sieci; jednej dla wytrzymałości na rozciąganie, a drugiej dla wydłużenia.

Strukturę sieci dobierano przy wykorzystaniu algorytmu kaskadowej korelacji Fahlmana (CC) [4]. W wyniku jego zastosowania otrzymano sieci, w których połączenia neuronów tworzyły rozwijającą się kaskadę (rys. 2). Każdy neuron wyjściowy był połączony z wszystkimi neuronami ukrytymi i z wejściami sieci. Algorytm korelacji kaskadowej dobierał wielkość sieci w sposób automatyczny, na podstawie obserwacji wyników procesu jej uczenia [4].



Rys. 2. Schemat sieci kaskadowej  
Fig. 2. Scheme of cascade network

W ramach badań wstępnych dokonano szerokiego przeglądu prób zastosowania różnych metod uczenia sieci. Spośród zastosowanych algorytmów uczenia najlepsze wyniki uzyskano dla algorytmu heurystycznego Riedmillaera i Brauna, zwanego RPROP (ang. Resilient backPROPagation). W porównaniu z klasycznymi algorytmami gradientowymi, metoda RPROP umożliwia znaczne przyspieszenie procesu uczenia, szczególnie w tych obszarach, w których nachylenie funkcji celu jest niewielkie.

Jako podstawę do oceny prawidłowości działania sieci stosowano średni błąd kwadratowy wartości znormalizowanych ( $RMS_n$ ,  $RMSE_n$  – ang. root mean square error), obliczany według wzoru [5]:

$$RMS_n = \sqrt{\frac{\sum_{k=1}^q \sum_{j=1}^m (y_{nj}(k) - d_{nj}(k))^2}{m \cdot q}}, \quad (1)$$

gdzie:

- $y_{nj}(k)$  – obliczona wartość sygnału na wyjściu  $j$  sieci dla  $k$ -tej pary uczącej,
- $d_{nj}(k)$  – żądana wartość sygnału na wyjściu  $j$  sieci dla  $k$ -tej pary uczącej,
- $q$  – liczba przykładów w ciągu uczącym,
- $m$  – liczba wyjść z sieci.

## 4. ANALIZA WYNIKÓW

W tabelach 1 do 3 przedstawiono wyniki testów kaskadowych sieci neuronowych modelujących właściwości wytrzymałościowe i plastyczne żeliwa sferoidalnego. Z tabel tych wynika, że struktura sieci wywierała znaczny wpływ na jakość modelowania właściwości mechanicznych żeliwa sferoidalnego.

Tabela 1  
Wyniki testu kaskadowych sieci neuronowych modelujących  
wytrzymałość na rozciąganie żeliwa sferoidalnego

Lp.	Struktura sieci	Metoda uczenia (*)	Ilość połączeń	Błąd $RMS_n$ dla ciągu testującego
1	6-9-1	CC + RPROP	99	0,06159
2	6-10-1	CC + RPROP	115	0,04635
3	<b>6-11-1</b>	<b>CC + RPROP</b>	<b>132</b>	<b>0,03685</b>
4	6-13-1	CC + RPROP	169	0,04068
5	6-14-1	CC + RPROP	189	0,04782
6	6-16-1	CC + RPROP	232	0,05288

(\*) – CC + RPROP – algorytm kaskadowej korelacji z uczeniem metodą RPROP

Tabela 2  
Wyniki testu kaskadowych sieci neuronowych modelujących  
wydłużenie względne żeliwa sferoidalnego

Lp.	Struktura sieci	Metoda uczenia	Ilość połączeń	Błąd $RMS_n$ dla ciągu testującego
1	6-11-1	CC + RPROP	132	0,07049
2	6-12-1	CC + RPROP	150	0,05864
3	6-13-1	CC + RPROP	169	0,05567
4	6-14-1	CC + RPROP	189	0,04759
5	<b>6-15-1</b>	<b>CC + RPROP</b>	<b>210</b>	<b>0,03432</b>
6	6-16-1	CC + RPROP	232	0,39034

Tabela 3  
Wyniki testu kaskadowych sieci neuronowych modelujących  
wytrzymałość na rozciąganie i wydłużenie względne żeliwa  
sferoidalnego

Lp.	Struktura sieci	Metoda uczenia	Ilość połączeń	Błąd $RMS_n$ dla ciągu testującego
1	6-8-2	CC + RPROP	104	0,11051
2	6-10-2	CC + RPROP	137	0,09136
3	<b>6-14-2</b>	<b>CC + RPROP</b>	<b>215</b>	<b>0,07184</b>
4	6-15-2	CC + RPROP	237	0,07738
5	6-18-2	CC + RPROP	309	0,08864
6	6-23-2	CC + RPROP	449	0,09807

Zwiększenie liczby ukrytych neuronów powodował początkowo spadek błędów testu konstruowanych sieci. W odróżnieniu od klasycznych sieci o strukturach warstwowych dodanie kolejnego neuronu ukrytego wiązało się ze znacznym zwiększeniem liczby połączeń między neuronami sieci, zwanych połączeniami wagowymi. Połączenia te są odpowiedzialne za gromadzenie wiedzy przez sieć [3, 4]. Sieci o bardzo rozbudowanych strukturach wykazywały znaczne błędy wynikające z braku uogólniania zdobytej wiedzy. Z tabel 1 i 2 wynika, że optymalna struktura sieci modelującej wytrzymałość na rozciąganie różni się od struktury najlepszej sieci modelującej wydłużenie względne. Zdecydowało to o zastosowaniu oddzielnych sieci do modelowania rozważanych właściwości. Celowość użycia oddzielnych sieci modelujących wytrzymałość na rozciąganie i wydłużenie względne potwierdziły słabe wyniki testów sieci określających jednocześnie te parametry (tab. 3).

## 5. UWAGI KOŃCOWE I WNIOSKI

Neuronowy model właściwości mechanicznych żeliwa sferoidalnego pozwala na prognozowanie jego wytrzymałości na rozciąganie i wydłużenia względnego na podstawie składu chemicznego, twardości i wybranych cech morfologii wydzieleni grafitu. Model składa się z dwóch kaskadowych sieci neuronowych. Pierwsza o strukturze 6-11-1 określała wytrzymałość na rozciąganie, a druga sieć w układzie 6-15-1 modeluje wydłużenie względne. Większa liczba neuronów drugiej z omawianych sieci wskazuje na bardziej złożoną zależność wydłużenia względnego od parametrów wejściowych niż występuje to w przypadku wytrzymałości na rozciąganie.

Modelowanie właściwości mechanicznych żeliwa sferoidalnego oparte na sieciach neuronowych nie ma na celu zastąpienia badań wytrzymałościowych wymaganych normą PN-EN 1563:2000, a jedynie ich uzupełnienie. Ma to istotne znaczenie w przypadkach, gdy określenie wytrzymałości na rozciąganie i wydłużenia względnego odlewów jest utrudnione lub w pewnych przypadkach niemożliwe ze względu na trudności w pobieraniu próbek do badań.

## Literatura

1. Perzyk M., Kochański A.: Prediction of ductile cast iron quality by artificial neural networks. *Journal of Materials Processing Technology* 109, 2001, s. 305-307.

2. Podrzucki C. Żeliwo. Struktura, właściwości, zastosowanie. Wydawnictwo ZG STOP. Kraków 1991.
3. Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza, PLJ, Warszawa 1998.
4. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
5. Ćwiczenia laboratoryjne z fizyki w Politechnice. Praca zbiorowa pod redakcją T. Rewaja. PWN, Warszawa 1978.
6. Zell A., Mamier G.: Stuttgart Neural Network Simulator User Manual, Version 4.2.

Recenzent: Dr hab. inż. Franciszek Binczyk

Profesor nzw. Politechniki Śląskiej

### **Abstract**

According to PN-EN 1563:2000 standard, selected mechanical properties of spheroidal graphite cast iron are determined with the aid of test coupons. Dimensions of these coupons are enough to machine tensile specimens from them. But mechanical properties of their material can differ from the properties of machine part castings. In this paper a method of modelling tensile strength and unit elongation has been presented. These properties are modelled on the basis of results of chemical composition, hardness, and graphite inclusions parameters measurements. As models two cascade neural networks have been used. These networks have been trained with heuristic algorithm RPROP.