

**ZASTOSOWANIE METOD SZTUCZNEJ INTELIGENCJI DO  
KLASYFIKACJI WAD W ODLEWACH ZE STOPÓW Al-Si-Cu**L.A. DOBRZAŃSKI<sup>1</sup>, M. KRUPIŃSKI<sup>2</sup>, J.H. SOKOŁOWSKI<sup>3</sup><sup>1,2</sup>Instytut Materiałów Inżynierskich i Biomedycznych, Politechnika Śląska,  
44-100 Gliwice, ul. Konarskiego 18A, Polska<sup>3</sup>University of Windsor Industrial Research Chair in Light Metals Casting Technology,  
401 Sunset Ave., N9B 3P4, Windsor, Ontario, Kanada

## STRESZCZENIE

Praca dotyczy oceny jakości elementów np. korpusów silników samochodowych ze stopów aluminium wytworzonych metodą Cosworth, przy wykorzystaniu analizy obrazów zdjęć cyfrowych uzyskanych w wyniku rentgenograficznych badań defektoskopowych tych że elementów. Uzyskane wyniki decydują o tym, czy wytworzony produkt jest odpadem poprodukcyjnym czy też nie, co ma na celu zmniejszenie liczby wytwarzanych produktów niespełniających kryteriów kontroli technicznej.

W pracy przedstawiono opracowaną, komputerowo wspomaganą metodę oceny jakości odlewów, na podstawie morfologii wad, przy zastosowaniu narzędzi sztucznej inteligencji.

*Key words:* technological process, Al-Si-Cu, casting defect, neural network

**1. WPROWADZENIE**

W nowoczesnych zastosowaniach jakość odlewów ze stopów aluminium nabiera coraz większego znaczenia, dlatego też jednym z podstawowych celów w przemyśle aluminiowym jest stała praca nad poprawą jakości ciekłego metalu, z którego wykonywane są odlewy w procesach technologicznych. Własności produktów wytworzonych z materiałów inżynierskich są zależne zarówno od ich rodzaju, składu chemicznego jak i rodzaju oraz jakości procesu technologicznego ich wytwarzania i przetwórstwa. Wytwarzanie odlewów wiąże się z dużą różnorodnością operacji

---

<sup>1</sup> dr h. c. prof. zw. dr hab. inż. [leszek.dobrzanski@polsl.pl](mailto:leszek.dobrzanski@polsl.pl)

<sup>2</sup> dr inż., [mariusz.krupinski@polsl.pl](mailto:mariusz.krupinski@polsl.pl)

<sup>3</sup> dr inż., [jerry@uwindsor.ca](mailto:jerry@uwindsor.ca)

technologicznych i zjawisk występujących w stopie podczas wytwarzania, co prowadzi do otrzymania odlewów wykazujących wady, a jako wadliwe określa się odlewy, które wykonane są niezgodnie z ustalonymi normami i warunkami technicznymi [1,3,5-9, 14,15].

Niezwykle istotnym etapem oceny jakości procesu technologicznego jest natomiast pozyskiwanie informacji o zjawiskach i przemianach zachodzących w materiale podczas tych procesów. Coraz powszechniej do tego celu są wykorzystywane nowoczesne narzędzia informatyczne, w tym metody sztucznej inteligencji. Wzrastające zainteresowanie tymi metodami jest uzasadnione przez ich szerokie możliwości aplikacyjne [2,8,10-12].

## 2. METODYKA BADAŃ

W badaniach wykorzystano zdjęcia rentgenowskie odlewów elementów silników samochodowych, tj. bloków oraz głowic wykonanych ze stopu aluminium EN AC-AlSi7Cu3Mg o składzie chemicznym pokazanym w tabeli 1 [6]. Klasyfikację wad odlewniczych identyfikowanych w odlewach elementów silników spalinowych wykonano w oparciu o normę ASTM E155 (tab. 2).

Tabela 1. Stężenie masowe poszczególnych pierwiastków w stopie według PN-EN 1706:2001  
Table 1. Chemical composition of aluminum alloy according to PN-EN 1706:2001

Stężenie masowe pierwiastka, %							
Si	Cu	Mg	Mn	Fe	Ti	Zn	Ni
6,5-8	3-4	0,3-0,6	0,2-0,65	≤ 0,8	≤ 0,25	≤ 0,65	≤ 0,3

Tabela 2. Typy i klasy wad odlewniczych uwzględnionych w badaniach wg ASTM E155  
Table 2. Types of the defects taken into consideration in classification

Symbol	Rodzaj wady	Liczba klas
GH	Jama gazowa	1 ÷ 8
PR	Porowatość	1 ÷ 8
SC	Jama skurczowa	1 ÷ 8
SP	Rzadzizna	1 ÷ 8


W celu zapewnienia poprawnego wykrywania wad odlewniczych oraz ich klasyfikacji, wykorzystano metody sztucznej inteligencji, a głównie sztuczne sieci neuronowe. Dla zapewnienia właściwej identyfikacji wad zastosowano analizę obrazów rentgenowskich.

Metodyka opracowania informacji zawartych na obrazach przedstawiających badane odlewy bloków oraz głowic silników (rys. 1), przy użyciu opracowanego programu komputerowego, obejmuje [7]:

- ujednoczenie parametrów opisujących obrazy odlewów (rozmiar, skala),
- wykonanie analizy obrazów cyfrowych przedstawiających sekcje bloków silników oraz głowic w celu wykstrahowania z obrazu wad odlewniczych,

- wykonanie obliczeń pól i odwodów oraz współczynników geometrycznych wad odlewniczych,
- obliczenie wartości geometrycznych wad odlewniczych zastosowanych jako zmienne niezależne do trenowania sieci neuronowych.

Zastosowano estymację przedziałową, aby oszacować przedział, w którym powinny mieścić się wartości współczynników geometrycznych opisujących morfologię wad odlewniczych. W ten sposób określono, które obiekty na obrazie po zastosowaniu analizy obrazu i obliczeniu współczynników geometrycznych stanowią wady odlewnicze.



Rys.1. Zdjęcie rentgenowskie sekcji bloku silnika spalinowego wraz z powiększonym obrazem wady odlewniczej

Fig.1. The fragment of a picture showing a section of car engine block and casting defect

Do zagadnień klasyfikacyjnych wad powstałych w odlewach w trakcie procesu technologicznego zastosowano sieci neuronowe, a do obliczeń wykorzystano program Statistica Neural Network 4.0 F.

Zbiór danych (1200 wektorów), wykorzystany do budowy modelu przy użyciu sieci neuronowych podzielono na trzy podzbiory: uczący, walidacyjny oraz testowy. Dane podzielono na poszczególne zbiory w sposób losowy, jednak przy założeniu, że wszystkie klasy wad muszą być reprezentowane w każdym ze zbiorów (uczącym, walidacyjnym oraz testowym).

Zastosowano następujące typy sieci dla zadań klasyfikacyjnych:

- perceptron wielowarstwowy MLP (Multilayer Perceptron),
- sieć o radialnych funkcjach bazowych RBF (Radial Basis Function),
- probabilistyczną sieć neuronową PNN (Probabilistic Neural Networks),
- sieć o algorytmie adaptacyjnego kwantowania wektorowego LVQ (Learning Vector Quantization).

Dane wykorzystywane w procesie uczenia i testowania sieci poddano normalizacji [13]. Ostateczną liczbę zmiennych wejściowych ustalano po zastosowaniu algorytmów genetycznych. Algorytmy genetyczne zastosowano do przeszukiwania łańcuchów binarnych, które reprezentują morfologię wad odlewniczych.

### 3. WYNIKI BADAŃ

Uzyskane wyniki wskazują na istotną zależność pomiędzy klasom wady a wartościami poszczególnych współczynników geometrycznych opisującymi wady odlewnicze, takimi jak: obwód, pole, średnice Fereta, bezwymiarowy współczynnik kształtu, współczynniki cyrkuralności oraz współczynnik okrągłości. Uzyskane wyniki wskazują również na brak zależności pomiędzy klasom wady a współczynnikiem Fereta i centrycznością (tab. 3).

Spośród zastosowanych różnych rodzajów sieci neuronowych, najlepsze wyniki klasyfikacji wad uzyskano przy zastosowaniu perceptronu wielowarstwowego (MLP), dla którego uzyskano najlepsze wskaźniki oceny jakości (tab. 4).

Do oceny jakości opracowanych w pracy sieci neuronowych do zagadnień klasyfikacyjnych wad odlewniczych niewystarczające jest rozpatrywanie tylko pierwiastków sum kwadratów błędów poszczególnych przypadków wyznaczanych przez funkcję błędu sieci, ponieważ niemożliwe jest w takim przypadku określenie rozkładu błędu klasyfikacji dla poszczególnych klas. W tym celu dla zastosowanych sieci klasyfikujących jako miarę jakości wykorzystano przede wszystkim proporcję poprawnie zaklasyfikowanych przypadków. Wykresy jakości klasyfikacji wad przy zastosowaniu sieci neuronowej opisanej w tabeli 4., zamieszczono na rys.2.

Aby dokonać oceny jakości w sposób automatyczny wykonano w tym celu program komputerowy. Na rys. 3 pokazano obraz analizowanego odlewu w oknie „obraz oryginalny” i obraz zidentyfikowanej wady odlewniczej w oknie „obraz wynikowy” oraz obliczone wartości współczynników geometrycznych wady.

Tabela 3. Zestawienie wyników testów nieparametrycznych istotności korelacji dla klasy wady i obliczonych współczynników geometrycznych wad odlewniczych

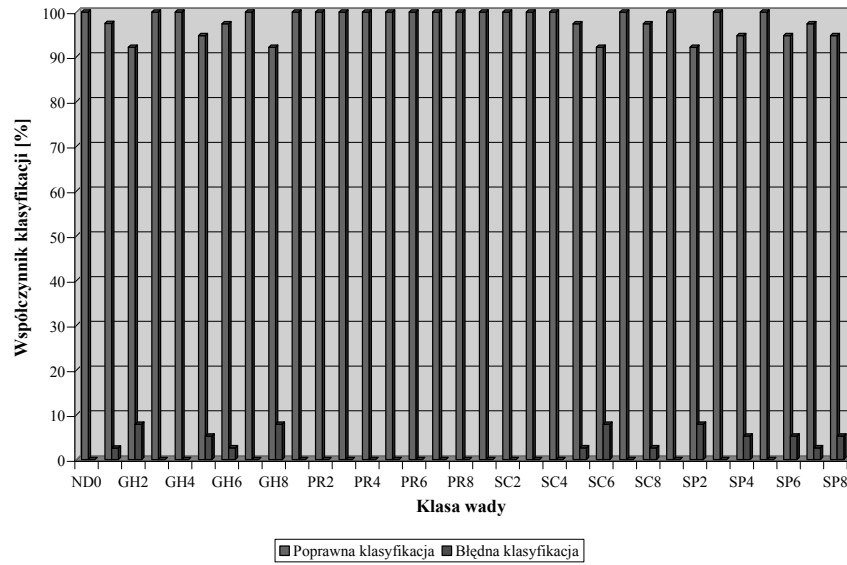
Table 3. List of results of nonparametric tests of the significance of correlation for the defect class and calculated geometrical parameters of casting defects

Rodzaj współczynnika geometrycznego	Liczność próby N	Korelacja	Wartość testu t/Z	Poziom istotności dla testu t	Wynik testu
Korelacja r Spearmana					
Obwód wady (L)	320	0,525869	11,02512	0,00	Istotny
Pole wady (S)	320	0,607049	13,62239	0,00	Istotny
Średnica Fereta pozioma wady ( $S_{Fx}$ )	320	0,478379	9,714393	0,00	Istotny
Średnica Fereta pionowa wady ( $S_{Fy}$ )	320	0,494237	10,13830	0,00	Istotny
Współczynnik Fereta wady (WF)	320	-0,057951	-1,03515	0,301387	Nieistotny
Bezwymiarowy współczynnik kształtu wady (BWK)	320	0,360129	6,883903	0,00	Istotny
Współczynnik cyrkuralności wady ( $R_{c1}$ )	320	0,608366	13,66929	0,00	Istotny
Współczynnik cyrkuralności wady ( $R_{c2}$ )	320	0,526268	11,03669	0,00	Istotny
Współczynnik okrągłości wady (WM)	320	0,360129	6,883903	0,00	Istotny
Centryczność wady ( $C_t$ )	320	0,054391	0,971364	0,332105	Nieistotny

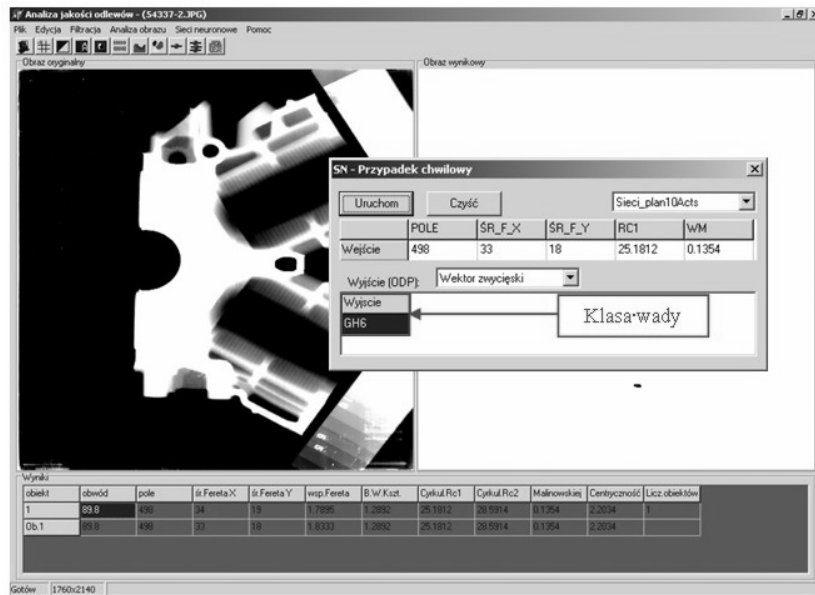
Tabela 4. Charakterystyka sieci neuronowej zastosowanej do klasyfikacji wad odlewniczych

Table 4. Characteristics of neural network applied for the classification of casting defect

Lp.	Współczynniki geometryczne wad odlewniczych zastosowane do uczenia sieci neuronowej	Struktura sieci	Metoda uczenia	Liczba epok treningowych
1.	pole wady (S), średnica Fereta pozioma wady ( $S_{Fx}$ ), średnica Fereta pionowa wady ( $S_{Fy}$ ), współczynnik cyrkuralności wady ( $R_{c1}$ ), współczynnik okrągłości wady (WM)	MLP 5-27-108	wstecznej propagacji, gradientów sprzężonych	465



Rys.2. Wykres błędów oraz poprawnych klasyfikacji dla sieci MLP 5-27-108  
 Fig.2. The plot of defects and correct classifications in particular classes of MLP 5-27-108



Rys.3. Okno programu z obrazem analizowanej sekcji odlewu bloku silnika  
 Fig.3. The program window for the assessment of class of casting defects

## PODSUMOWANIE

Opracowany system komputerowy, w którym wykorzystano sztuczne sieci neuronowe oraz metody analizy obrazu pozwala zapewnić identyfikację i klasyfikację wad występujących w odlewach ze stopów typu Al-Si-Cu typu EN AC-AISi7Cu3Mg, wspomagając w ten sposób decyzje o eliminacji odlewów, niespełniających ustalonych wymagań jakościowych, a zatem zapewniając równocześnie powtarzalność i obiektywizm wyników oceny jakości odlewów wykonanych z tych stopów. Poprawnie określona jakość produktów umożliwia z kolei takie sterowanie procesem technologicznym, aby liczba wad powstających w odlewach zmniejszyć poprzez odpowiednią korektę procesu. Sterowanie procesem technologicznym na podstawie informacji pozyskanej z systemu komputerowego wykonanego w celu określenia jakości produktów pozwala na optymalizację tegoż procesu i w ten sposób na zmniejszenie udziału odlewów wadliwych, a w konsekwencji na zmniejszenie kosztów oraz zanieczyszczenia środowiska.

## LITERATURA

- [1] Anson J. P., Gruzleski J. E.: The quantitative discrimination between shrinkage and gas microporosity in cast aluminum alloys using spatial data analysis, *Materials Characterization* 43, pp. 319–335 (1999), Elsevier Science Inc., 1999.
- [2] Anijdan S.H. Mousavi, Bahrami A., Hosseini Madaah H.R., Shafyei A.: Using genetic algorithm and artificial neural network analyses to design an Al–Si casting alloy of minimum porosity, *Materials and Design*, 27, 2006, pp. 605–609.
- [3] Asim Tewari, Manish Dighe, Arun M. Gokhale: Quantitative Characterization of Spatial Arrangement of Micropores in Cast Microstructures, Elsevier, *Materials Characterization* 40, (1998), pp.119–132. Dobrzański L.A.: Podstawy nauki o materiałach i metaloznawstwo. Materiały inżynierskie z podstawami projektowania materiałowego, Wydawnictwa Naukowo-Techniczne, Warszawa, 2002.
- [4] A Valle M., Belingardi G., Cavatorta M.P., Doglione R.: Casting defects and fatigue strength of a die cast aluminium alloy: a comparison between standard specimens and production components, *International Journal of Fatigue* 24 (2002), pp.1–9.
- [5] Caceres C.H., Djurdjevic M.B., Stockwell T.J., Sokolowski J.H.: The effect of Cu content on the level of microporosity in Al-Si-Cu-Mg casting alloys, Elsevier Science, *Scripta Materialia*, Vol. 40, No. 5, (1999), pp. 631–637.
- [6] Dobrzański L.A.: Podstawy nauki o materiałach i metaloznawstwo. Materiały inżynierskie z podstawami projektowania materiałowego, Wydawnictwa Naukowo-Techniczne, Warszawa, 2002.
- [7] Dobrzański L.A., Krupiński M., Sokolowski J.H.: Computer aided classification of flaws occurred during casting of aluminum, *Journal of Materials Processing Technology*, Vol. 167, Is. 2-3, 2005, pp. 456-462.

- [8] Dobrzański L.A., Trzaska J.: Application of neural networks for prediction of critical values of temperatures and time of the supercooled austenite transformations, *Journal of Materials Processing Technology*, Vol. 155–156, 2004, pp.1950–1955.
- [9] Dolan K.W.: *Design and Produkt Optimization for Cast Ligot Metals*, Livermore, 2000
- [10] Jiahe A., Jiang X., Huiju G., Yaohe H., Xishan X.: Artificial neural network prediction of the microstructure of 60Si2MnA rod based on its controlled rolling and cooling process parameters, *Materials Science and Engineering*, A344, 2003, pp. 318-322.
- [11] Krupińska B., Szewieczek D.: Analysis of technological process on the basis of efficiency criterion, *Journal of Achievements in Materials and Manufacturing Engineering 2006*, Vol. 17, July-August 2006.
- [12] Kozłowski J., Biernacki R., Myszka D., Perzyk M., Kochański A.: Zastosowanie systemów uczących się do przewidywania własności materiałów odlewanych, *Archiwum odlewnictwa*, nr 14, 2004, s. 249-257.
- [13] Nałęcz M., *Biocybernetyka i inżynieria biomedyczna, Sieci neuronowe*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [14] Polmear I.J., *Light Alloys, Metallurgy of the Light Metals*, Second edition, 1989.
- [15] Desaki Toru, Kamiya Soji: Development of a new aluminum alloy bearing for small-sized diesel engines, *JSAE Review* 21, 2000, pp. 143-147.

## **APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS FOR CLASSIFICATION OF DEFECTS OF Al-Si-Cu ALLOYS CASTINGS**

### **SUMMARY**

This paper presents the analysis of automotive alloy castings of engine heads and blocks. The technological process applied for these Al-Si alloy castings, EN AC- $\text{AlSi7Cu3Mg}$  type, was Cosworth. Also, it includes the development of the methodology of image analysis of casting defects. They were achieved by the defectoscopic X-ray analysis of Al-Si-Cu alloy elements, EN AC- $\text{AlSi7Cu3Mg}$  type. Besides, it contains both the manner of classification of casting defects by means of artificial intelligence, including neural networks and the application of the developed methodology in the form of a system of computer programmes for quality control.

Recenzował: Prof. Jan Szajnar