



Wykorzystanie metod sztucznej inteligencji do wizyjnej analizy właściwości warstw wierzchnich

TOMASZ WÓJCICKI

PIB w Radomiu, Instytut Technologii Eksploatacji,
26-600 Radom, ul. Pułaskiego 6/10, tomasz.wojcicki@itee.radom.pl

Streszczenie. W artykule zaprezentowano wybrany fragment realizowanych prac badawczych dotyczących możliwości automatycznego prognozowania właściwości materiałowych na podstawie analiz zdjęć cyfrowych. Przedstawiono oryginalny, holistyczny model prognozowania właściwości warstw wierzchnich oparty na wieloetapowym procesie obejmującym wybrane metody przetwarzania i analiz obrazów, inferencji z wykorzystaniem baz wiedzy apriorycznej i wielowartościowej logiki rozmytej, a także symulacji metodami elementów skończonych. Omówiono charakterystykę warstw wierzchnich oraz podstawowe technologie ich wytwarzania obejmujące: procesy mechaniczne, cieplne, cieplno-mechaniczne, cieplno-chemiczne, elektrochemiczne, fizyczne. Przedstawiono wykorzystane w opracowanym modelu metody klasyfikacji obrazów warstw wierzchnich. Opisano cele stosowania wybranych metod przetwarzania i analizy obrazów cyfrowych, w tym techniki: poprawy jakości obrazów, segmentacji, transformacji morfologicznych, rozpoznawania obrazów oraz symulacji zjawisk fizycznych w strukturach materiałowych.

Słowa kluczowe: analiza obrazów, warstwa wierzchnia, sztuczna inteligencja, logika rozmyta

DOI: 10.5604/12345865.1131495

1. Charakterystyka warstw wierzchnich

Warstwa wierzchnia to część materiału ograniczona z jednej strony rzeczywistą powierzchnią ciała stałego lub powłoką ochronną, z drugiej materiałem rdzenia. Strukturę warstwy stanowią strefy charakteryzujące się różną grubością, właściwościami fizycznymi oraz chemicznymi. Zagadnienia dotyczące zjawisk i technologii wytwarzania warstw wierzchnich obejmują obszar nauki zwany inżynierią materiałową, którą zajmują się liczne ośrodki naukowe zlokalizowane w Polsce [1, 2]

oraz na całym świecie [3, 4]. Dobierając właściwą metodę wytwarzania warstw wierzchnich do charakterystyki materiału bazowego, można w istotnym zakresie zmienić właściwości materiału, tak aby w jak największym stopniu odpowiadał przyjętym przez projektanta założeniom (np. określona twardość, odporność na wysokie temperatury itp.). Wykorzystywanych jest wiele technologii wytwarzania warstw wierzchnich, w skład których wchodzi: procesy mechaniczne (nagniatanie, nanoszenie detonacyjne), cieplne (hartowanie, odpuszczanie, wyżarzanie, nadtapianie, napawanie, natapianie), cieplno-mechaniczne (nasywanie, stopowanie), cieplno-chemiczne (natryskiwanie, nadtapianie natryskowe, platerowanie, utwardzanie detonacyjne), elektrochemiczne (osadzanie bezpośrednie, osadzanie elektrolityczne, osadzanie konwersyjne), fizyczne (osadzanie z fazy gazowej, implantowanie jonów itp.). Istnieje również szereg sposobów klasyfikacji metod kształtowania struktur i własności powierzchni materiałów. Przykładem może być klasyfikacja metod nanoszenia powłok z fazy gazowej w oparciu o temperaturę T_s i parametr Knudsena określony równaniem:

$$K_n = \frac{\lambda_f}{D_r}, \quad (1)$$

gdzie: λ_f — długość swobodnej drogi atomów lub jonów biorących udział w tworzeniu powłoki, D_r — rozmiar reaktora, w którym powłoka jest wytwarzana. Właściwości eksploatacyjne powłok zależą od ich składu chemicznego, struktury metalograficznej oraz stopnia adhezji do podłoża. Skład chemiczny, struktura i adhezja zależą natomiast od rodzaju oraz proporcji substratów biorących udział w procesie wytwarzania. Takie same powłoki wykonane w różnych technologiach mogą charakteryzować się różnymi właściwościami użytkowymi. W związku z powyższym zastosowanie wizyjnej analizy właściwości materiałowych jest interesującym od strony naukowej zagadnieniem charakteryzującym się wysokim stopniem złożoności.

2. Model prognozowania właściwości warstw wierzchnich na podstawie analizy wizyjnej

W literaturze opisano wiele prób wykorzystania technik komputerowych do analizy struktur materiałowych [5, 6, 7], jednak nie obejmowały one zagadnienia w sposób całościowy, zazwyczaj ograniczając się do metod wydzielania struktur materiałowych z obrazów lub samej symulacji zjawisk fizycznych z manualnym przypisaniem właściwości materiałowych do poszczególnych elementów uwidocznionych na obrazach. Oryginalność zaproponowanego przez autora rozwiązania polega na holistycznym podejściu do zagadnienia poprzez zminimalizowanie ingerencji czynnika ludzkiego w proces analizy przebiegający automatycznie od momentu akwizycji do uzyskania wyników symulacji dzięki zastosowaniu metod sztucznej inteligencji.

Opracowany holistyczny model prognozowania właściwości warstw wierzchnich stanowi wieloetapowy, złożony proces, którego wynik zależny jest od analizy odwzorowanych w postaci zdjęć cyfrowych struktur materiałowych. Ogólny model formalny opracowanego procesu analizy jest następujący:

$$F_M : X_M \rightarrow Y_M, \quad (2)$$

gdzie: F_M — operator działania modelu;
 X_M — przestrzeń wielkości wejściowych;
 Y_M — przestrzeń wielkości wyjściowych.

Przestrzeń wielkości wejściowych X_M charakteryzuje zbiór danych o charakterze dyskretnym:

$$X_M = \{X^Z, X^D\}, \quad (3)$$

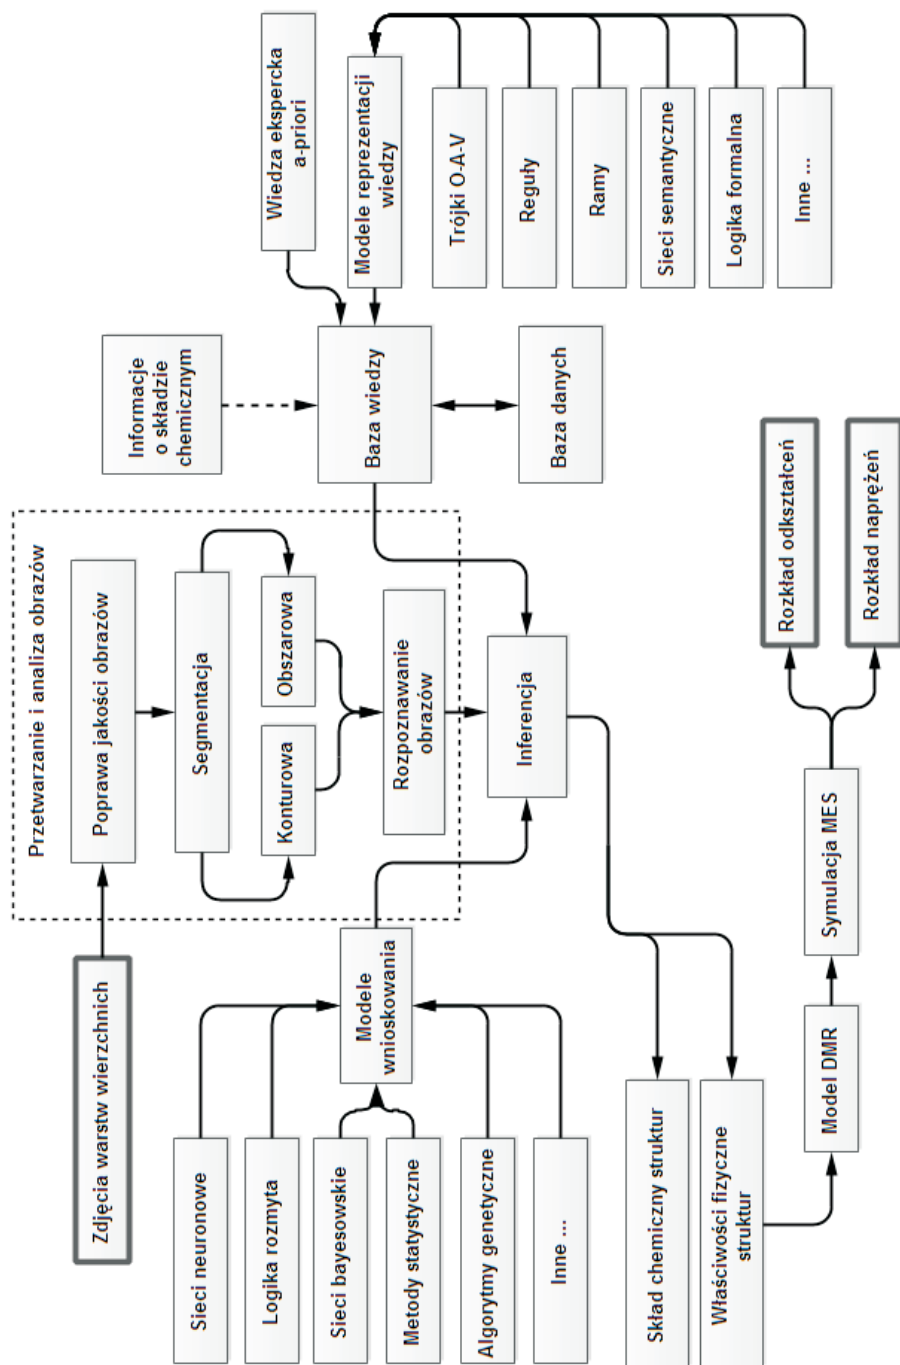
gdzie: $X^Z = \{x_1^z, x_2^z, \dots, x_i^z\}$ — zbiór zdjęć cyfrowych zglądów analizowanych próbek materiałowych;
 $X^D = \{X^S, X^M\}$ — zbiór danych charakteryzujących zdjęcia cyfrowe i zglądy próbek materiałowych;
 $X^S = \{x_1^s, x_2^s, \dots, x_i^s\}$ — zbiór danych parametryzujących zdjęcia cyfrowe;
 $X^M = \{x_1^m, x_2^m, \dots, x_i^m\}$ — zbiór danych charakteryzujących metody przygotowania zglądów próbek materiałowych.

Przestrzeń wielkości wyjściowych stanowi rozkład odkształceń oraz naprężeń:

$$Y_M = \{X^O, X^N\}, \quad (4)$$

gdzie: $X^O = \{x_1^o, x_2^o, \dots, x_p^o\}$ — zbiór danych opisujących odkształcenia struktur reprezentowanych na analizowanych zdjęciach cyfrowych;
 $X^N = \{x_1^n, x_2^n, \dots, x_p^n\}$ — zbiór danych opisujących naprężenia w strukturach reprezentowanych na analizowanych zdjęciach cyfrowych.

Schemat opracowanego procesu prognozowania właściwości warstw wierzchnich z wykorzystaniem analizy wizyjnej przedstawiono na rysunku 1.



Rys. 1. Schemat procesu prognozowania właściwości warstw wierzchnich z wykorzystaniem analizy wizyjnej i metod sztucznej inteligencji

Operator F_{M_b} , którego zadaniem jest transformacja zbioru wielkości wejściowych X_M w zbiór wielkości wyjściowych Y_{M_b} , realizuje swoje funkcje w oparciu o przyjęty model prowadzenia procesów przekształceń i analiz reprezentowany zbiorem obejmującym następujące elementy:

$$F_M = \{F^P, F^S, F^R, F^W, F^A, F^E\}, \quad (5)$$


gdzie: $F^P = \{f_1^p, f_2^p, \dots, f_b^p\}$ — zbiór przekształceń realizujących zadania poprawy jakości obrazów cyfrowych;
 $F^S = \{f_1^s, f_2^s, \dots, f_h^s\}$ — zbiór przekształceń realizujących zadania segmentacji;
 $F^R = \{f_1^r, f_2^r, \dots, f_k^r\}$ — zbiór metod rozpoznawania obrazów;
 $F^W = \{f_1^w, f_2^w, \dots, f_q^w\}$ — zbiór metod inferencji;
 $F^A = \{f_1^a, f_2^a, \dots, f_l^a\}$ — zbiór metod generowania modeli DMR;
 $F^E = \{f_1^e, f_2^e, \dots, f_v^e\}$ — zbiór metod symulacji zjawisk fizycznych.

Istotnym zagadnieniem powiązaniem z wynikami analizy jest wykorzystywana metoda przygotowania próbek, która powinna w jak najlepszy sposób wyeksponować charakterystyczne cechy materiałowe. Istnieje wiele metod uwidaczniania struktur materiałowych, np. trawienie, odparowanie czy barwienie nalotowe [8]. Odczynniki do trawienia wpływają efektywnie przede wszystkim na granice ziaren, ale również same ziarna mogą wytrawiać się silniej lub słabiej. Gdy trawiona próbka składa się z kilku faz, wtedy również zostają one w różnym stopniu uwidocznione, co umożliwia prowadzenie ich identyfikacji na zdjęciach. Istotne zatem jest, aby takie same struktury poddawane analizie przygotowywane były identycznymi metodami.

Etapem poprzedzającym właściwy proces przetwarzania i wizyjnej analizy próbek materiałowych jest ustalenie obszaru zainteresowań — ROI (*Region of Interests*) [9], stanowiącego fragment obrazu podlegający dalszemu przetwarzaniu ze względu na zawartość istotnych z punktu widzenia realizowanego zadania informacji. Ważne są także dane o wielkości fizycznego obszaru próbki wchodzącego w skład ROI. Po ustaleniu ROI realizowane są procesy związane z poprawą jakości obrazu F^P , w skład których wchodzi:

- skalowanie w dwuwymiarowej przestrzeni,
- poprawa kontrastu z wykorzystaniem jednej z funkcji typu: $1 - e^{-C}$, $\ln(1 + C)$, $\tanh(C)$, gdzie: C — poprzednia wartość kontrastu,
- filtracja, której zadaniem jest kompensacja niedoskonałości procesu akwizycji obrazu lub nieefektywnej ekspozycji obiektu badań (filtry: medianowy [10], Gaussa [11]).

Kolejnym etapem opracowanego modelu jest segmentacja konturowa oraz obszarowa [12] F^S (rys. 2), prowadzone w celu wyłonienia granic i obszarów reprezentowanych na zdjęciach struktur, w oparciu o które prowadzone jest rozpoznawanie obrazów F^R .



Rys. 2. Wynik segmentacji: a) konturowej; b) obszarowej

Zaproponowany model przetwarzania wykorzystywany do segmentacji krawędziowej bazuje na operatorze Canny'ego [13], opartym o analizę gradientu jasności pikseli. Model ten charakteryzuje się małą wrażliwością na szum w postaci odseparowanych, pojedynczych pikseli oraz znaczącą efektywnością w śledzeniu konturów reprezentowanych na obrazach obiektów. Do segmentacji obszarowej wykorzystano metodę progowania [14].

Rozpoznawanie obrazów F^R w opracowanym modelu to ustalenie rodzaju materiału reprezentowanego na analizowanym zdjęciu cyfrowym oraz kształtu ziaren. Obraz traktowany jest jak fragment tekstury, dla której wyznaczane są cechy charakterystyczne z wykorzystaniem modelu Harlicka [15]. Cechy te tworzą wektor wejściowy dla sieci neuronowej w postaci perceptronu wielowartościowego [16] pełniącej funkcję klasyfikatora, trenowanej metodą wstecznej propagacji błędów [17]. Wektor wejściowy zdefiniowano jako:

$$f_x^r = \{k_f, m_f, a_f, h_f, v_f, c_f\}, \quad (6)$$

gdzie: k_f — kontrast;
 m_f — moment II rzędu (miara homogeniczności obrazu);
 a_f — współczynnik autokorelacji;
 h_f — entropia;
 v_f — wariancja;
 c_f — moment różnicowy.

Wynik klasyfikacji umożliwia przypisanie rodzaju materiału do zdjęcia badanej próbki, co stanowi podstawę wnioskowania w procesach inferencji F^W . Kolejną operacją związaną z rozpoznawaniem obrazów jest ustalenie współczynnika kształtu ziaren odwzorowanych na analizowanych zdjęciach. W literaturze opisano wiele modeli charakteryzujących kształty, np. współczynnik Malinowskiej, Blaira-Blissa, Danielssona, Harlicka, Fereta itp. [18]. W opracowanym rozwiązaniu przyjęto wykorzystanie tzw. bezwymiarowego współczynnika kształtu reprezentowanego równaniem:

$$K = \frac{L^2}{4\pi \cdot S}, \quad (7)$$

gdzie: L — obwód obiektu;
 S — pole powierzchni obiektu.

Współczynnik ten charakteryzuje się dużą dyspersją przy jednoczesnej niewrażliwości na obroty obiektów względem przyjętego układu współrzędnych, co jest korzystne w procesach identyfikacji dedykowanych do opracowanego modelu. Dla obiektów o wydłużonych kształtach wartości współczynnika dążą do 0, podczas gdy dla obiektów o charakterystykach zbliżonych do okręgów wartość współczynnika dąży do 1. Znaczną zmiennością charakteryzują się również współczynniki Fereta oraz Danielssona, ale badania empiryczne na zbiorze testowym wykazały, że w przypadku identyfikacji struktur materiałowych bezwymiarowy współczynnik kształtu daje najlepsze rezultaty.

Kolejnym krokiem jest określenie gęstości ziaren struktury materiałowej i ich zróżnicowania. W tym celu wyznaczana jest liczba ziaren N^Z w obszarze ROI oraz zakres zmienności ich pola powierzchni, a także zakres zmienności współczynnika kształtu. Przyjęto, że ziarna ze względu na rozmiar ich pola powierzchni mogą przynależeć do jednego z 10 zakresów $Z_1^S \dots Z_{10}^S$. Analogiczne założenia wykonano dla współczynnika kształtu ziaren, dla których zakresy oznaczono jako $Z_1^K \dots Z_{10}^K$. Wartości te stanowią podstawę procesu inferencji F^W dotyczącej składu chemicznego ziaren, a także krzywych umocnienia, które zostały wstępnie zdefiniowane. Inferencja może być realizowana z wykorzystaniem różnych modeli wnioskowania, wśród których najpopularniejsze to metody statystyczne [19], algorytmy genetyczne [20], sieci probabilistyczne [21], sztuczne sieci neuronowe [22] itp. W opracowanym modelu zaproponowano wykorzystanie logiki rozmytej, której zaletą jest brak konieczności prowadzenia procesów uczenia, jak ma to miejsce w przypadku sieci neuronowych, oraz brak czynnika losowego, jak w przypadku algorytmów genetycznych, co ogranicza jego heurystyczny charakter. Przesłanki reguł rozmytych stanowi liczba ziaren N^Z w obszarze ROI, liczba ziaren przynależących do poszczególnych zakresów zmienności ich pola powierzchni i kształtu, a także numer przedziału zmienności kształtu i pola powierzchni analizowanego ziarna. Konkluzję stanowi

skład chemiczny ziarna oraz charakterystyka krzywej umocnienia. Obydwa te parametry mogą przyjmować zdefiniowane *a priori* zbiory wartości.

Zapis reguł rozmytych wg przyjętego modelu wnioskowania Mamdaniego [23], znajdującego również zastosowanie w systemach regulacji, jest następujący:

$$\mathfrak{R} : \text{IF } (x_1 \text{ is } A_1) \text{ AND } (x_2 \text{ is } A_2) \text{ AND } \dots \text{ AND} \\ \text{AND } (x_{24} \text{ is } A_{24}) \text{ THEN } (y_1 \text{ is } B_1) \text{ AND } (y_2 \text{ is } B_2), \quad (8)$$

gdzie: x_1 – liczba ziaren w obszarze ROI (N^Z);
 x_2 – rodzaj materiału reprezentowanego na analizowanym zdjęciu cyfrowym;
 $x_3 \dots x_{12}$ – liczba ziaren w poszczególnych przedziałach zakresów zmienności pola powierzchni;
 $x_{13} \dots x_{22}$ – liczba ziaren w poszczególnych przedziałach zakresów zmienności kształtu;
 x_{23} – numer przedziału zakresów zmienności pola powierzchni dla analizowanego ziarna;
 x_{24} – numer przedziału zakresów zmienności kształtu dla analizowanego ziarna;
 y_1 – numer zbioru danych opisującego skład chemiczny analizowanego ziarna;
 y_2 – numer zbioru danych opisującego krzywą umocnienia analizowanego ziarna;
 $A_1 \dots A_{24}$ – zbiory rozmyte w przestrzeni wejściowej;
 B_1, B_2 – zbiory rozmyte w przestrzeni wyjściowej.

Zbiory rozmyte modelu wnioskowania stanowią sigmoidy, których funkcje przynależności opisuje równanie:


$$\mu_A(x) = \frac{1}{1 + e^{-a(x-c_1)}} + \frac{1}{1 + e^{a(x-c_2)}}. \quad (9)$$

Wyniki procesu inferencji F^W wraz z geometrią ziaren uzyskaną podczas segmentacji F^S stanowią podstawę generowania modelu strukturalnego DMR (*Digital Material Representation*) [24] warstwy w postaci elementów skończonych F^A (rys. 3).

Główną operacją w tym procesie jest meshowanie. Jej celem jest wytworzenie siatki elementów skończonych stanowiących podstawę procesu symulacji F^E . Uwzględniając charakterystyki poszczególnych ziaren, możliwe jest wyznaczanie naprężeń oraz przemieszczeń występujących w analizowanych próbkach materiałowych według przyjętego modelu reologicznego Hansela-Spittela [25]:


$$\sigma = A e^{m_1 T} T^{m_8} \varepsilon^{m_2} e^{m_4/\varepsilon} (1 + \varepsilon)^{m_5 T} e^{m_6 \varepsilon} \dot{\varepsilon}^{m_3} \dot{\varepsilon}^{m_7 T}, \quad (10)$$

gdzie: ε — odkształcenie;
 $\dot{\varepsilon}$ — prędkość odkształcenia;
 T — temperatura;
 $A, m_1, m_2, m_3, m_4, m_5, m_6, m_7, m_8$ — współczynniki regresji.



Rys. 3. Cyfrowy model fragmentu struktury warstwy wierzchniej: a) granice ziaren; b) struktura po procesie meshowania

Symulacja MES dostarcza informacji na temat rozkładu naprężeń i odkształceń (rys. 4).



Rys. 4. Rozkład naprężeń wyznaczony z wykorzystaniem metody elementów skończonych

W przypadku warstw wierzchnich złożony problem stanowią niejednorodności mikrostruktury powiązane układem płaszczyzn poślizgu, w związku z czym odkształcenia plastyczne zależą m.in. od liczby tych płaszczyzn, ich układu, rotacji siatki krystalograficznej oraz gęstości dyslokacji.

Podsumowanie

Przedstawione w artykule rozwiązanie opisuje metodykę predykcji właściwości warstw wierzchnich na podstawie automatycznej analizy zdjęć zglądów próbek materiałowych i jest znaczącym krokiem w kierunku eliminacji czynnika ludzkiego w procesach badawczych. Poprzez wykorzystanie zaproponowanego rozwiązania możliwa jest redukcja nakładów czasowych (w szczególności procesów złożonych analiz struktur materiałowych charakteryzujących się znaczną dyspersją uzyskiwanych wyników), a także zadań związanych ze szkoleniem kadry pracowniczej. Wykorzystanie opracowanego rozwiązania w warunkach przemysłowych może przyczynić się do zapewnienia utrzymania wysokiej jakości produkowanych wyrobów oraz wzrostu wydajności opracowywania nowych pokryć materiałowych wpływających w znaczącym zakresie na poprawę wybranych właściwości wytwarzanych produktów. Metoda ma charakter otwarty, co oznacza, że może podlegać dalszym modyfikacjom, których celem jest zwiększenie jej efektywności dla szerokiego zakresu struktur odwzorowanych z wykorzystaniem zdjęć cyfrowych. Potencjalne zwiększenie liczby wymiarów wektorów wejściowych modelu, a także uwzględnienie danych z akwizycji realizowanych w trybie on-line może w przyszłości posłużyć do prowadzenia zaawansowanych procesów łączących analizę wizyjną z funkcjami sterowania procesami konstituowania warstw wierzchnich. Na szczególną uwagę zasługuje również czynnik edukacyjny rozwiązania umożliwiający wspomaganie kształcenia pracowników związanych z obszarem inżynierii materiałowej.

Artykuł wpłynął do redakcji 1.07.2014 r. Zweryfikowaną wersję po recenzji otrzymano 11.07.2014 r.

Artykuł opracowany na podstawie referatu wygłoszonego na X Szkole-Konferencji „Metrologia Wspomagana Komputerowo — MWK’2014” Waplewo, 27-30 maja 2014.

LITERATURA

- [1] DYZEK E., *Badania warstwy wierzchniej w aluminium i stopach aluminium za pomocą anihilacji pozytonów i metod komplementarnych*, Instytut Fizyki Jądrowej im. Henryka Niewodniczańskiego, Kraków, 2008.
- [2] KULA P., *Inżynieria warstwy wierzchniej*, Wydawnictwo Politechniki Łódzkiej, Łódź, 2000.
- [3] HERMANN K., *Crystallography and Surface Structure*, Wiley, Germany, 2011.
- [4] VICKERMAN J., GILMORE I., *Surface Analysis. The Principal Techniques*, Wiley, UK, 2011.

-
- [5] KURZYDŁOWSKI K., RALPH B., *The Quantitative Description of the Microstructure of Materials*, CRC Press, USA, 1995.
- [6] SZALA J., *Zastosowanie metod komputerowej analizy obrazu do ilościowej oceny struktury materiałów*, Zeszyty Naukowe Politechniki Śląskiej — Hutnictwo, Katowice, 2001.
- [7] GHOSH S., DIMIDUK D., *Computational Methods for Microstructure Property Relationships*, Springer, USA, 2011.
- [8] RYŚ J., *Metalografia ilościowa*. Wydawnictwa AGH, Kraków, 1982.
- [9] BURGER W., BURGE M., *Digital Image Processing*, Springer, USA, 2009.
- [10] BAI X., ZHOU F., LIU Z., JIN T., XUE B., *Multi Scale Adaptive Median Filter for Impulsive Noise Removal*, International Conference ICICIS, China, 2011.
- [11] ADAMS A., *High-Dimensional Gaussian Filtering For Computational Photography*, Stanford University, USA, 2011.
- [12] ACTON S., RAY N., *Biomedical Image Analysis: Segmentation*, Morgan & Claypool, USA, 2009.
- [13] DERICHE R., *Using Canny's criteria to derive an optimal edge detector recursively implemented*, Int. J. Computer Vision, vol. 1, USA, 1987.
- [14] EL-SAYED M., *Algorithms for Image Thresholding*, LAP Lambert Academic Publishing, Germany, 2012.
- [15] MIRMEHDI M., XIE X., SURI J., *Handbook of Texture Analysis*, Imperial College Press, London, 2008.
- [16] ZABOROWICZ M., BONIECKI P., PRZYBYŁAK A., *Sieć neuronowa typu MLP jako narzędzie w komputerowej analizie obrazów*, Journal of Research and Applications in Agricultural Engineering, vol. 55, nr 2, Poznań, 2010.
- [17] STATECZNY A., *Sztuczne sieci neuronowe ze wsteczną propagacją błędów w filtracji pomiarów nawigacyjnych*, Zeszyty Naukowe Wyższej Szkoły Morskiej, Szczecin, 1998.
- [18] LUCIANO DA FONTOURA C., CESAR R., *Shape Analysis and Classification*, CRC Press, USA, 2001.
- [19] THOMPSON B., *Canonical Correlation Analysis, Uses and Interpretation*, SAGE Publications, California, 1984.
- [20] GREFENSTETTE J., *Genetic Algorithms for Machine Learning*, Kluwer Academic Publishers, USA, 1993.
- [21] KOCH K., *Introduction to Bayesian Statistics*, Springer-Verlag, Berlin, 2007.
- [22] YEGNANARAYANA B., *Artificial Neural Networks*, PHI, Delhi, 2009.
- [23] PEGAT A., *Modelowanie i sterowanie rozmyte*, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2003.
- [24] RAUCH Ł., MADEJ Ł., PAWŁOWSKI B., *Numerical Simulations of Hypoeutectoid Steel under Loading Conditions, Based on Image Processing and Digital Material Representation*, Second International Symposium CompIMAGE2010, USA, 2010.
- [25] MALKIN A., ISAYEV A., *Rheology, Concepts, Methods & Applications*, Chemtec Publishing, USA, 2006.

T. WÓJCICKI

**The use of artificial intelligence methods for visual analysis
of properties of surface layers**

Abstract. The article presents a selected area of research on the possibility of automatic prediction of material properties based on the analysis of digital images. Original, holistic model of forecasting properties of surface layers based on a multi-step process that includes the selected methods of processing and analysis of images, inference with the use of a priori knowledge bases and multi-valued fuzzy logic, and simulation with the use of finite element methods is presented. Surface layers characteristics and core technologies of their production processes such as mechanical, thermal, thermo-mechanical, thermo-chemical, electrochemical, physical are discussed. Developed methods used in the model for the classification of images of the surface layers are shown. The objectives of the use of selected methods of processing and analysis of digital images, including techniques for improving the quality of images, segmentation, morphological transformation, pattern recognition and simulation of physical phenomena in the structures of materials are described.

Keywords: image analysis, surface layer, artificial intelligence, fuzzy logic