

ANALIZA OBRAZU W KONTROLI PROCESÓW I OCENIE JEDNORODNOŚCI PODCZAS PRODUKCJI MASY CERAMICZNEJ

Jarosław Cyboron¹ Marcin Skobel², Wojciech Panna³, Magdalena Szumera¹

jcyboron@agh.edu.pl, m_skobel@atar.edu.pl, w_panna@atar.edu.pl,
mszumera@agh.edu.pl

¹Katedra Ceramiki i Materiałów Ogniotrwałych, Akademia Górniczo-Hutnicza im. Stanisława Szaszica w Krakowie, Polska

²Katedra Informatyki, Akademia Tarnowska, Tarnów Polska

³Katedra Technologii i Zarządzania Produkcją, Akademia Tarnowska, Tarnów Polska

Streszczenie

Proces homogenizacji wieloskładnikowych mas ceramicznych stanowi jeden z kluczowych etapów technologicznych, determinujących przebieg przemian fazowych, kinetykę spiekania, rozwój mikrostruktury oraz końcowe właściwości mechaniczne i użytkowe wyrobów. Jego istotą jest możliwie równomierne rozmieszczenie składników różniących się składem chemicznym, uziarnieniem, morfologią oraz gęstością nasypową, co bezpośrednio przekłada się na stabilność i powtarzalność parametrów materiału. W praktyce technologicznej niejednorodności w rozkładzie składników mogą prowadzić do lokalnych różnic w przebiegu procesów termicznych, nierównomiernego zagęszczenia podczas spiekania, powstawania porów oraz defektów

strukturalnych, a w konsekwencji do pogorszenia właściwości mechanicznych i użytkowych wyrobów ceramicznych.

Uzyskanie odpowiedniego stopnia jednorodności realizowane jest przy wykorzystaniu różnych metod technologicznych. Do najczęściej stosowanych należą procesy mieszania mechanicznego (mieszarki łopatkowe, bębnowe i planetarne), mielenie w młynach kulowych i wibracyjnych oraz granulacja, która dodatkowo stabilizuje skład mieszaniny i ogranicza segregację składników. W ostatnich latach coraz większe znaczenie zyskują również techniki intensywnego mieszania, wykorzystujące wysokie energie ścinania, pozwalające na efektywne rozbijanie aglomeratów i poprawę dyspersji faz drobnoziar-

nistych. Skuteczność tych procesów zależy jednak od wielu czynników, takich jak czas mieszania, udział i charakter poszczególnych składników, różnice gęstości oraz ich podatność na aglomerację. W związku z tym zapewnienie odpowiedniego stopnia homogenizacji wymaga nie tylko właściwego doboru technologii, ale również skutecznych metod kontroli jakości.


Pomimo dużego znaczenia procesu homogenizacji, jego ilościowa i obiektywna ocena nadal stanowi istotne wyzwanie. Stosowane metody kontroli jakości, takie jak analiza składu chemicznego (np. XRF), analiza uziarnienia czy obserwacje mikroskopowe, mają często charakter pośredni i nie pozwalają na bezpośrednią ocenę przestrzennego rozmieszczenia poszczególnych składników w materiale. Metody punktowe nie oddają w pełni rzeczywistego stopnia jednorodności w skali całej objętości próbki, natomiast techniki obrazowania wymagają często czasochłonnej analizy eksperckiej. W szczególności brakuje narzędzi umożliwiających szybką, powtarzalną i jednocześnie ilościową ocenę homogenizacji na poziomie makrostrukturalnym [1].

W odpowiedzi na powyższe ograniczenia coraz większe znaczenie zyskują metody oparte na cyfrowej analizie obrazu, które umożliwiają bezpośrednią ocenę rozmieszczenia składników w materiale. W niniejszej pracy zapropono-

nowano podejście wykorzystujące automatyczną segmentację obrazów cyfrowych do ilościowej oceny stopnia jednorodności mieszanin. Analiza opiera się na identyfikacji poszczególnych faz oraz wyznaczeniu ich udziału powierzchniowego, co stanowi bezpośrednią miarę stopnia homogenizacji.

Materiał badawczy stanowiło 29 obrazów próbek o rozdzielczości 1200×1600 pikseli. Obrazy te poddano procesowi segmentacji semantycznej, w ramach którego wyróżniono cztery klasy: obszar próbki, faza ciemna (identyfikowana jako wapień), faza jasna (identyfikowana jako siarka) oraz tło. Na etapie przygotowania danych referencyjnych przeprowadzono ręczną segmentację z wykorzystaniem tabletu graficznego, a wyodrębnione obszary zapisano w postaci plików ROI (Region of Interest). Ze względu na ograniczoną liczbę próbek kluczowym aspektem było ograniczenie ryzyka przeuczenia modelu.

Do budowy modelu segmentacji wykorzystano architekturę U-Net [2] z enkoderem opartym na sieci ResNet-18 [3]. Wybór tej architektury pozwolił na zachowanie równowagi pomiędzy zdolnością modelu do ekstrakcji cech a jego generalizacją. Proces uczenia wspomagano poprzez augmentację danych wejściowych oraz zastosowanie walidacji krzyżowej typu K-fold, co umożliwiło stabilniejszą ocenę jakości modelu. Trening przeprowa-



Rysunek 1. Zestawienie obrazu oryginalnego, maski ręcznej oraz wyniku automatycznej segmentacji sieciowej.

Figure 1. Comparison of the original image, the manual mask, and the result of automatic network-based segmentation.

dzono z wykorzystaniem optymalizatora Adam przy niskim współczynniku uczenia.

Do oceny jakości segmentacji zastosowano wskaźnik IoU (Intersection over Union), będący miarą zgodności pomiędzy maską przewidywaną przez model a maską referencyjną przygotowaną ręcznie. Uzyskane wartości IoU dla kolejnych iteracji walidacji krzyżowej mieściły się w zakresie od 0,76 do 0,82, co wskazuje na wysoką skuteczność modelu w identyfikacji i separacji poszczególnych składników. Wizualna analiza wyników potwierdziła poprawne odwzorowanie

struktur oraz skuteczne oddzielenie obiektów od tła [4].

Zastosowane podejście umożliwia wyznaczenie udziału powierzchniowego poszczególnych faz oraz ich przestrzennego rozmieszczenia, co stanowi podstawę do ilościowej oceny stopnia homogenizacji mieszanin. Otrzymane wyniki wskazują, że analiza obrazu wspomaganą metodami uczenia maszynowego może stanowić skuteczne narzędzie wspierające kontrolę jakości w procesach technologicznych, umożliwiając szybkie, obiektywne i powtarzalne monitorowanie jednorodności materiałów.

Słowa kluczowe: homogenizacja, masa ceramiczna, kontrola jakości, segmentacja, sieci neuronowe

Keywords: homogenization, ceramic body, quality control, segmentation, neural networks

Bibliografia/References:

- [1] Kielski A. Ogólna technologia ceramiki. Akademia Górniczo-Hutnicza w Krakowie, Wydział Ceramiczny. Katedra technologii i materiałów ogniotrwałych. Skrypty uczelniane nr 153. Kraków 1969.
- [2] Ronneberger, Olaf, Philipp Fischer and Thomas Brox. 2015. „U-Net: Convolutional Networks for Biomedical Image Segmentation”. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, redakcja Nassir Navab, Joachim Hornegger, William M. Wells i Alejandro F. Frangi, 234–241. *Lecture Notes in Computer Science*, vol. 9351. Cham: Springer. https://doi.org/10.1007/978-3-319-24574-4_28.
- [3] He, Kaiming, Xiangyu Zhang, Shaoqing Ren and Jian Sun. 2016. „Deep Residual Learning for Image Recognition”. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. Las Vegas, NV: IEEE. <https://doi.org/10.1109/CVPR.2016.90>
- [4] Kingma, Diederik P. i Jimmy Ba. 2014. „Adam: A Method for Stochastic Optimization”. *arXiv preprint arXiv:1412.6980*. <https://doi.org/10.48550/arXiv.1412.6980>.

IMAGE ANALYSIS FOR PROCESS CONTROL AND HOMOGENEITY ASSESSMENT IN CERAMIC CLAY BODY PRODUCTION

Abstract

The homogenization of multi-component ceramic bodies is one of the key technological stages determining phase transformations, sintering kinetics, microstructure development, and the final mechanical and functional properties of ceramic products. Its essence lies in achieving the most uniform pos-

sible distribution of components differing in chemical composition, particle size, morphology, and bulk density, which directly translates into the stability and reproducibility of material parameters. In technological practice, compositional inhomogeneities may lead to local variations in thermal processes,

non-uniform densification during sintering, the formation of pores and structural defects, and consequently to the deterioration of mechanical and functional properties of ceramic products.

The desired degree of homogeneity is achieved using various technological methods. The most commonly applied include mechanical mixing (e.g., paddle, drum, and planetary mixers), milling in ball and vibratory mills, and granulation processes, which additionally stabilize the composition and reduce component segregation. In recent years, increasing attention has been given to intensive mixing techniques employing high shear forces, enabling effective agglomerate breakdown and improved dispersion of fine-grained phases. However, the efficiency of these processes depends on multiple factors, such as mixing time, the proportion and nature of individual components, density differences, and their tendency to agglomerate. Therefore, achieving an adequate degree of homogenization requires not only the proper selection of processing methods but also reliable quality control approaches.

Despite the technological importance of homogenization, its quantitative and objective evaluation remains a significant challenge. Commonly used quality control methods, such as chemical composition analysis (e.g., XRF), particle

size analysis, or microscopic observations, are often indirect and do not allow for direct assessment of the spatial distribution of individual components within the material. Point-based methods do not fully reflect the actual degree of homogeneity at the scale of the entire sample volume, while imaging techniques often require time-consuming expert analysis. In particular, there is a lack of tools enabling rapid, repeatable, and quantitative evaluation of homogenization at the macrostructural level [1].

In response to the aforementioned limitations, increasing attention has been directed toward methods based on digital image analysis, which enable direct assessment of the spatial distribution of components within the material. In this study, an approach based on automatic segmentation of digital images was proposed for the quantitative evaluation of mixture homogeneity. The analysis relies on the identification of individual phases and the determination of their surface fraction, which constitutes a direct measure of the degree of homogenization.

The research material consisted of 29 images of samples with a resolution of 1200×1600 pixels. The images were subjected to semantic segmentation, in which four classes were distinguished: the sample area, a dark phase (identified as limestone), a bright phase (identi-

fied as sulfur), and the background (clay-based matrix). At the stage of reference data preparation, manual segmentation was performed using a graphics tablet, and the extracted regions were stored as Region of Interest (ROI) files. Due to the limited number of samples, a key aspect of the study was to minimize the risk of model overfitting.

The segmentation model was developed using the U-Net architecture [2] with an encoder based on the ResNet-18 network [3]. The selection of this architecture ensured a balance between the model's feature extraction capability and its generalization performance. The training process was supported by data augmentation and the application of K-fold cross-validation, which enabled a more reliable evaluation of model performance. The model was trained using the Adam optimizer with a low learning rate.

The quality of segmentation was evaluated using the Intersection over Union (IoU) metric, which

measures the agreement between the predicted mask and the reference mask prepared manually. The obtained IoU values for individual cross-validation iterations ranged from 0.76 to 0.82, indicating high effectiveness of the model in identifying and separating individual components. Visual inspection of the results confirmed accurate representation of structures and effective separation of objects from the background [4].

The proposed approach enables the determination of the surface fraction of individual phases as well as their spatial distribution, providing a basis for the quantitative assessment of the degree of homogenization in mixtures. The obtained results demonstrate that image analysis supported by machine learning methods can serve as an effective tool for quality control in technological processes, enabling fast, objective, and repeatable monitoring of material homogeneity.