

## WYKORZYSTANIE SIECI NEURONOWYCH (FBM) DO MODELOWANIA PROCESU MIESZANIA DWUSKŁADNIKOWYCH UKŁADÓW ZIARNISTYCH

Jolanta Królczyk, Dominika Matuszek, Marek Tukiendorf

*Katedra Techniki Rolniczej i Leśnej, Politechnika Opolska*

**Streszczenie.** W pracy zaprezentowano wyniki badań mieszania składników ziarnistych powszechnie stosowanych w przemyśle spożywczym. Dodatkowo przedstawiono metodykę wykorzystania nowoczesnych metod analizy tego procesu, tj.: komputerową akwizycję obrazu oraz sztuczne sieci neuronowe. Mieszanie prowadzono na drodze kolejnych wysypów (od 1 do 10) materiału z jednego zbiornika do drugiego (system funnel-flow). Jakość uzyskanej mieszanki oceniano przy użyciu komputerowej analizy obrazu. Uzyskane w ten sposób wyniki wariacji rozkładu trasera posłużyły do wykorzystania modelowania procesu przy użyciu sztucznej inteligencji. Uzyskane wyniki zaprezentowano w sposób graficzny i poddano dyskusji.

**Słowa kluczowe:** mieszanie materiałów ziarnistych, sieci neuronowe

### Wstęp

Mieszanie materiałów ziarnistych ma duże znaczenie w wielu branżach przemysłu spożywczego. Jest to jedna z podstawowych operacji w przemyśle zbożowo-młynarskim oraz w przemyśle suchych koncentratów spożywczych i paszowych. Mieszanie komponentów ziarnistych w technologii żywności ma na celu zapewnienie możliwie jednolitego składu oraz zabezpieczenie przed rozdzielaniem się komponentów. Istnieje wiele typów i odmian urządzeń służących do mieszania. Są one przede wszystkim dostosowane do rodzaju mieszanych materiałów. Często stosowaną metodą prowadzenia tego procesu jest mieszanie w przesypie (system funnel-flow). Jest to szybki i tani sposób ujednoczenia większych partii ziarna przed przemiałem lub przy sporządzaniu mąki o odpowiednio ustabilizowanym składzie [Dłużewski, Dłużewska 2001; Pijanowski i in. 1996; Tukiendorf 2003a].

W przemyśle spożywczym bardzo ważnymi parametrami warunkującymi produkcję i jej opłacalność jest ilość oraz jakość surowca. Łatwość zbytu produktu, jego konkurencyjność i cena na rynku w dużym stopniu zależą właśnie od jakości produktu. Podstawową cechą jakości mieszanek ziarnistych jest rozkład jej komponentów w całej objętości złoża. W przypadku układów dwuskładnikowych składnik kluczowy może zajmować różne położenia: począwszy od stanu segregacji, przez stan pierścieniowy, rdzeniowy czy randomowy do stanu idealnego [Królczyk, Tukiendorf 2005; Tukiendorf 2003b].

Istnieje wiele metod analizy jakości uzyskiwanych mieszanek, takich jak: metoda sitowa, przez pobór prób ze złoża za pomocą sond czy metoda bezpośredniego zliczania

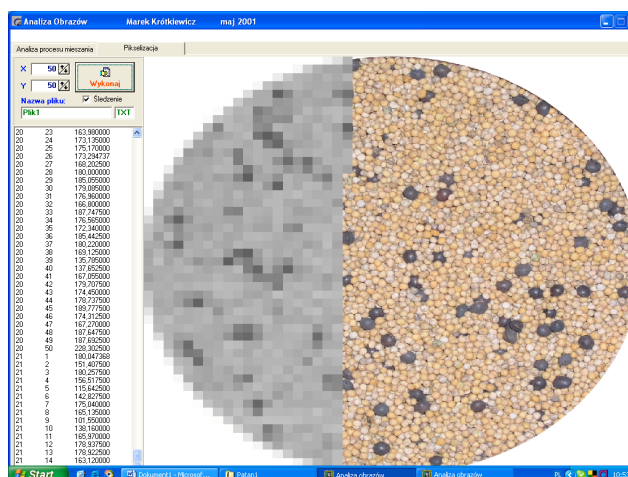
cząstek. W pracy wykorzystano komputerową akwizycję obrazu, która reprezentuje innowacyjne narzędzie oceny jakości. Metoda ta pozwala w szybki i łatwy sposób ocenić rozkład komponentów w złożu, a przez to jakość mieszanki ziarnistej. Komputerowa analiza obrazu jest coraz częściej stosowana również w wielu innych dziedzinach, takich jak przepływy mieszanin dwufazowych – do oceny struktury przepływu [Ulbrich 2002] oraz do oceny jakości produktów spożywczych [Szwedziak, Sobkowicz 2006].

Ze względu na złożoność procesu mieszania ciała stałych nie można go opisać prostymi sposobami analitycznymi. Charakter i problematyczność zjawisk rządzących tym procesem inspiruje do poszukiwania innych metod modelowania. Autorzy w swojej pracy wykorzystali do tego celu sztuczną inteligencję. Sztuczne sieci neuronowe pozwalają na symulację bardzo złożonych funkcji. Podstawową właściwością jest wyuczenie sieci na poprawnych przykładach do podania potrzebnego modelu bez konieczności zakładania warunków wstępnych.

Celem pracy było zaprezentowanie możliwości i metodyki wykorzystania komputerowej analizy obrazu oraz sztucznych sieci neuronowych w analizie i modelowaniu procesów mieszania materiałów ziarnistych stosowanych w przemyśle spożywczym.

## Metodyka badań

Mieszano układ ziarnisty złożony z dwóch komponentów o stosunkach średnic  $d_1/d_2=1,55$  oraz stosunku gęstości ( $\rho_1/\rho_2=0,97$ ). Mieszanie wykonano metodą kolejnych przesyków. Przedmiotem zainteresowań była obserwacja sposobu rozmieszczenia składnika



Źródło: opracowanie własne

Rys. 1. Obraz przekroju poprzecznego mieszalnika poddany analizie programem PATAN ®. Obraz w czasie pikselizacji.

Fig. 1. Image of a cross section of the agitator analysed with PATAN program. Image during the pixellization

kluczowego mieszaniny różniącego się barwą na powierzchni poszczególnych przekrojów poprzecznych mieszalnika. Do badań wykorzystano laboratoryjny model mieszalnika przesypowego o budowie przedstawionej w poprzednich pracach autorów publikacji [Królczyk, Tukiendorf 2003; Matuszek, Tukiendorf 2005]. Mieszalnik dzięki swojej konstrukcji umożliwiał obserwację rozkładu traseru w kolejnych dziesięciu przekrojach poprzecznych mieszalnika. Traser umieszczano w jednym, środkowym pierścieniu, a następnie dokonywano przesypów. Badano rozkład traseru na powierzchni przekrojów w zależności od ilości przesypów. Mieszanie zakończono po 10 przesypie, gdyż wykazano już wcześniej, iż 10 kolejnych przesypów jest liczbą wystarczającą do osiągnięcia przez układ stanu równowagi dynamicznej [Tukiendorf 2002]. Oceny rozkładu traseru na powierzchni dokonywano za pomocą komputerowej analizy obrazu (rys. 1).

Obrazy cyfrowe zapisano w formacie  $2^8$  bpp (skali szarości). Pikselizacja posłużyła do określenia współrzędnych traseru oraz podania wartości liczbowej w skali szarości.

### **Analiza statystyczna**

Dalszym etapem było przeprowadzenie binaryzacji, a więc przypisanie punktom jasnym wartości 0, a punktom ciemnym wartości 1. Na tej podstawie dokonano dalszej analizy położenia traseru. Oceniano wariancję rozkładu traseru na powierzchni każdego z pierścieni.

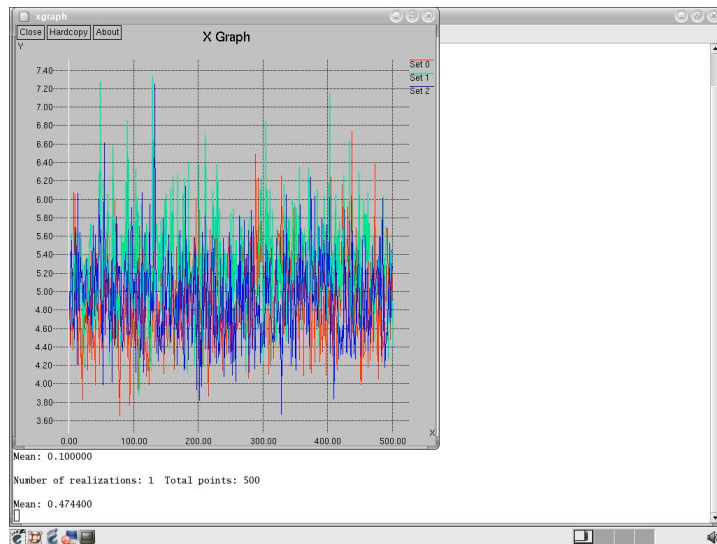
W celu wyprognozowania zmian wariancji w ostatnich przesypach (od 8 do 10) wykorzystano modelowanie neuronowe. Sieć poddano procesowi uczenia wykorzystując dane z pierwszych siedmiu przesypów (kroki od 1 do 7). Zastosowano sieć typu Flexible Bayesian Modeling [Lampin, Vehtari 2001] o 10 warstwach ukrytych.

Wyprognozowane wyniki porównano następnie z danymi empirycznymi.

### **Wyniki analizy statystycznej**

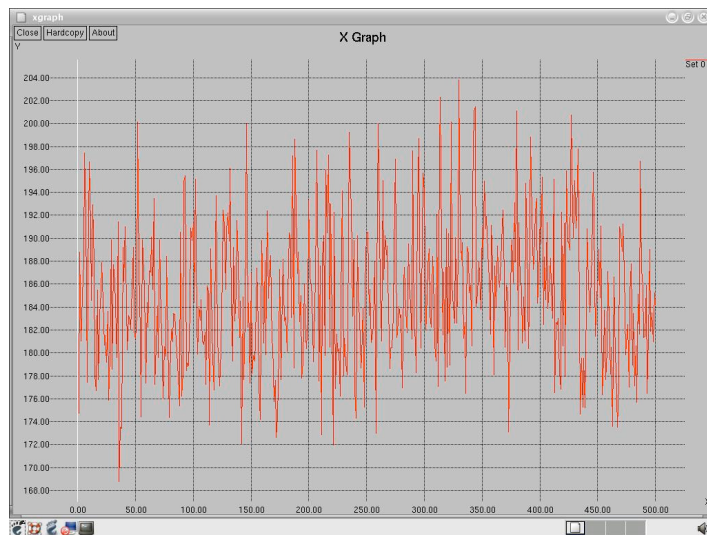
W czasie modelowania kontrolowano parametry uczenia sieci tak, aby uzyskać wartość współczynnika „rejection rate” dla inicjacji w granicach 0,1–0,3, zaś dla biegu produkcyjnego od 0,2 do 0,8. Element ten jest jednym z parametrów sieci wskazujących na poprawne wymodelowanie danych. Wartości współczynników wyniosły odpowiednio: 0,1 oraz 0,4744. Dodatkowym elementem określającym właściwie przyjęte wartości algorytmu sieci jest obserwacja przebiegu wykresów: wykres hiperparametrów uczenia oraz wykres rozkładu energetycznego. Otrzymane wykresy zaprezentowane są na rys. 2 oraz rys. 3.

Na wykresie (rys. 4) zaprezentowano porównanie danych empirycznych z danymi wymodelowanymi za pomocą sieci neuronowych. Średni błąd kwadratowy wyniósł  $33,77691 \pm 4,54938$ .



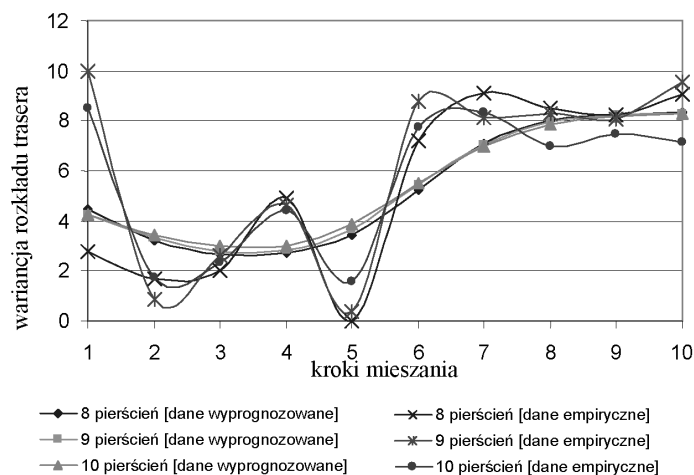
Źródło: opracowanie własne

Rys. 2. Wykres hiperparametrów uczenia  
Fig. 2. Graph of teaching hyperparameters



Źródło: opracowanie własne

Rys. 3. Wykres rozkładu energetycznego  
Fig. 3. Graph of the energy distribution



Źródło: opracowanie własne

Rys. 4. Porównanie danych empirycznych z danymi wymodelowanymi za pomocą sieci neuronowych  
Fig. 4. Comparing empirical data to data modeled with the use of neural network

## Wnioski

1. Sztuczne sieci neuronowe (FBM) pozwalają na modelowanie zmian jakości układów ziarnistych w czasie mieszania.
2. Wykorzystanie sieci neuronowych pozwoliło na wychwycenie trendu zmian wariacji w kolejnych krokach mieszania, dzięki czemu przebieg procesu został „wygładzony”.
3. Zarówno w przypadku danych empirycznych, jak i wyprognozowanych zaobserwowano stabilizację wariacji począwszy od 7 kroku mieszania, co może stanowić podstawę do skrócenia czasu mieszania.



Praca powstała przy współfinansowaniu ze środków Europejskiego Funduszu Społecznego Unii Europejskiej oraz ze środków budżetu państwa

## Bibliografia

Dłużewski M., Dłużewska A. 2001. Technologia Żywności. Wydawnictwa Szkolne i Pedagogiczne, Warszawa. s. 98.

- Królczyk J., Tukiendorf M.** 2005. Using the methods of geostatic function and Monte Carlo in estimating the randomness of distribution of a two-component granular mixture during the flow mixing. *EJPAU* 2005, Volume 8, Issue 4, [dostęp 27-03-2007]. Dostępny w internecie: <http://www.ejpau.media.pl/volume8/issue4/art-78.html>
- Lampin J., Vehtari A.** 2001. Bayesian approach for neural networks-review and case studies. *Neural Networks* 14. s. 257-274.
- Matuszek D., Tukiendorf M.** 2005. Komputerowa analiza obrazu i modelowanie neuronowe w ocenie i prognozowaniu rozkładu cząstek dwuskładnikowego układu ziarnistego podczas mieszania systemem funnel-flow. *Inżynieria Rolnicza* Nr 14(74). Kraków. s. 229-235.
- Pijanowski E., Dłużewski M., Dłużewska A., Jarczyk A.** 1996. *Ogólna Technologia Żywności*. Wydawnictwa Naukowo-Techniczne. Warszawa. ISBN 83-204-2502-6.
- Szwedziak K., Sobkowicz J.** 2006. Określenie zanieczyszczeń w mące za pomocą komputerowej analizy obrazu. *Postęp Techniki Przetwórstwa Spożywczego*. s. 24-25.
- Tukiendorf M.** 2002. Sposoby oceny jakości mieszanin ziarnistych w zbiornikach. *Acta Scientiarum Polonorum, Technica Agraria* 1 (2). s. 51-59.
- Tukiendorf M.** 2003a. Modelowanie neuronowe procesów mieszania niejednorodnych układów ziarnistych. *Rozprawy Naukowe Akademii Rolniczej w Lublinie. Zeszyt 272* Lublin.
- Tukiendorf M.** 2003b. Characteristics of mixing granular materials achieved by using methods of variance analysis and geostatistical function. *EJPAU*, Vol. 6, Issue 1, 2003, [dostęp 27-03-2007]. Dostępny w internecie: <http://www.ejpau.media.pl/series/volume6/issue1/engineering/art-03.html>
- Ulbrich R.** (red.) 2002. *Rozpoznawanie obrazu w zastosowaniach do badań przepływu mieszanin dwufazowych*. Wyd. Polit. Opol., Pr. zbior., *Studia i monografie* 138, ISBN 83-88492-85-3.

## USING NEURAL NETWORKS (FBM) FOR MODELLING OF THE PROCESS INVOLVING MIXING OF TWO-COMPONENT GRANULAR SYSTEMS

**Abstract.** The paper presents results of tests on mixing of granular components commonly used in food industry. Additionally, the work presents the procedures of using modern methods for analysis of this process, that is: image acquisition by computer and artificial neural networks. Mixing process involved successive pouring out (from 1 to 10 times) of material from one container to another (system funnel-flow). The quality of obtained mix was evaluated using image analysis by computer. Marker distribution variance results obtained in this way allowed to use process modelling with an artificial intelligence. Obtained results were shown graphically and were subject to discussion.

**Key words:** mixing of granular materials, neural networks

**Adres do korespondencji:**

Jolanta Królczyk; e-mail [jolantakrolczyk@wp.pl](mailto:jolantakrolczyk@wp.pl)  
Katedra Techniki Rolniczej i Leśnej  
Politechnika Opolska  
ul. Mikołajczyka 5  
45-271 Opole