

Dominika Matuszek, Marek Tukiendorf
Wydział Mechaniczny
Politechnika Opolska

PROGNOZOWANIE ROZKŁADU CZĄSTEK PODCZAS MIESZANIA SYSTEMEM FUNNEL-FLOW

Streszczenie

W pracy przedstawiono wyniki modelowania neuronowego procesu mieszania niejednorodnego układu ziarnistego przy pomocy systemu funnel-flow. W oparciu o komputerową analizę obrazu dokonano oceny rozkładu cząstek obserwowanego składnika kluczowego w poszczególnych przekrojach mieszalnika używając jako miary tego rozkładu wartości wariancji. Modelowanie oparto na prognozowaniu neuronowym. Do uczenia wykorzystano pięć pierwszych kroków mieszania. Następnie w oparciu o wyniki uczenia sieć dokonała predykcji rozkładu koncentracji składnika kluczowego dla następnych pięciu kroków mieszania, to jest aż do osiągnięcia stanu równowagowego. Dokonano statystycznego porównania modeli (empirycznego i predyktowanego) przy pomocy współczynnika przestrzennej korelacji.

Słowa kluczowe: materiały ziarniste, mieszanie, ocena jakości układu ziarnistego, komputerowa analiza obrazu, sieci neuronowe, współczynnik koleracji przestrzennej

Wstęp

System funnel-flow, czyli mieszanie metodą ze zbiornika do zbiornika jest szybkim i wygodnym sposobem uzyskiwania wymaganego stanu zmieszania materiałów ziarnistych. Ziarna zgromadzone w silosie przesypują się przez dno lejowego do kolejnego silosu umieszczonego poniżej. Kilka następujących po sobie wysypów doprowadza do osiągnięcia stanu równowagowego po czym dalsze mieszanie nie powoduje zmian jakościowych układu. W przemyśle system funnel-flow stosowany jest w mieszaniu dużych objętości materiału ziarnistego [Tukiendorf 2003].

Badania prowadzone w warunkach laboratoryjnych ze zbiornikiem zbudowanym z 10 rozbieralnych pierścieni, pozwalają na ocenę udziału objętościowego trasera (składnika kluczowego). Jest to możliwe np. przy pomocy klasycznej analizy sitowej materiału pochodzącego z każdego przekroju. Jednakże w warunkach przemysłowych przy dużych objętościach mieszanego materiału działania takie są raczej niemożliwe. W związku z tym potrzebne jest poszukiwanie nowych metod analizy jakościowej mieszanin ziarnistych [Tukiendorf 2002a].

Komputerowa analiza obrazu zastosowana do analizy procesu mieszania metodą ze zbiornika do zbiornika polega na obserwacji koncentracji traseira w kolejnych przekrojach poprzecznych (pierścieniach) zbiornika.

Boss, Krótkiewicz i Tukiendorf prowadząc obserwacje, nad zachowaniem mieszanin ziarnistych podczas mieszania systemem funnel-flow [Tukiendorf 2002b, c], przy użyciu komputerowej analizy obrazu zaproponowali sklasyfikowanie typowych rozkładów składników na powierzchni kolejnych pierścieni zbiornika. Obok stanu randomowego (losowego) opisali następujące stany zmieszania:

- pierścieniowy,
- rdzeniowy

Stan pierścieniowy charakteryzuje się występowaniem traseira w zewnętrznej części przekroju poprzecznego zbiornika. Natomiast w stanie rdzeniowym składnik kluczowy znajduje się w środkowej części przekroju. Zatem ocena jakości układu ziarnistego tylko w oparciu o metodę analizy sitowej może prowadzić do przedstawiania nieadekwatnego stanu mieszaniny [Tukiendorf 2002c].

Dodatkowych trudności dostarcza zagadnienie modelowania procesu mieszania niejednorodnych układów ziarnistych. Proces mieszania materiałów ziarnistych jest trudny do opisanie sposobami analitycznymi. Dlatego też w tym artykule proponuje się możliwość wykorzystania sztucznej inteligencji do modelowania procesu mieszania takich układów. Stosowanie sieci neuronowych pozwala na symulację bardzo złożonych zależności. Właściwością sieci neuronowych jest ich zdolność uczenia się na podanych wcześniej przykładach aby następnie podać wartości prognozowane [Tukiendorf].

Cel badań

Celem badań była ocena rozkładu koncentracji dwuskładnikowej mieszaniny ziarnistej (wyka-gorczyca) podczas mieszania systemem funnel-flow. Na podstawie uzyskanych informacji o wartościach wariancji na powierzchniach kolejnych przekrojów mieszalnika, po 10 kolejnych przesypach zaproponowano ponadto neuronowy model mieszania.

Metodyka badań pomiarowych

Mieszaniu przy pomocy systemu funnel-flow poddano dwuskładnikowy układ ziarnisty (wyka-gorczyca), którego składniki różniły się między sobą wymiarami średnic i gęstości ziaren. Stosunek gęstości komponentów wynosił $\rho_1/\rho_2 = 0,97$ natomiast stosunek średnic $d_1/d_2 = 1,55$.

Zastosowany do badań mieszalnik składał się z dwóch zbiorników umieszczonych jeden nad drugim w sposób umożliwiający ich łatwą zamianę miejscami. Zbiorniki charakteryzowały się identycznymi wymiarami: wysokość części cylindrycznej – 200 mm, średnica wewnętrzna – 150 mm, oraz rozbieralną konstrukcją złożoną z 10 przekrojów poprzecznych tzw. pierścieni.




Rys. 1. Mieszalnik laboratoryjny do systemu funnel-flow
Fig. 1. Laboratory mixing device used for funnel-flow system

Stosunek objętościowy traseira do składnika, w którym był rozpraszany wynosił 1/9. Składnik kluczowy zawsze przed rozpoczęciem procesu mieszania umieszczano w piątym pierścieniu zbiornika. Po napełnieniu mieszalnika rozpoczęto proces mieszania. Liczba kolejnych przesypów wynosiła od 1 do 10.

Metodyka badań statystycznych

Przekroje ziarniste pierścieni podczas mieszania fotografowano. Następnie obraz poddawano analizie komputerowej przy pomocy programu PATAN [Boss, Krótkiewicz, Tukiendorf, 2001]. Naturalne odcienie nasion wyki i gorczycy za pomocą skali (RedGreenBlue) RGB – 256 zamieniono na czerń i biel ustalając między nimi poziom graniczny. Następnie dokonywano pikselizacji obrazu a uzyskanym punktem czarnym przydzielano liczbę 1 natomiast punktom białym – 0. Pozwoliło to na wyznaczenie wartości wariancji dla poszczególnych przekrojów poprzecznych zbiornika po kolejnych etapach mieszania.



Rys. 2. Obraz wybranego przekroju mieszalnika, a) w zapisie cyfrowym, b) po pikselizacji 50 x 50 komórek.


Fig. 2. The picture of a selected mixing device cross section, a) digital recording, b) after unit pixelization 50x50

Kolejnym etapem badań było zastosowanie modelowania neuronowego. Sieć poddano procesowi uczenia wykorzystując dane z pierwszych pięciu przesypów (kroki od 1 do 5). Zastosowano sieć typu Flexible Bayesian Modeling [Lampinen, Veh-tari 2001] o 50 warstwach ukrytych. Wyprognozowane w ten sposób wyniki wartości wariancji dla kolejnych pięciu przesypów (kroki 6 do 10) posłużyły do sprawdzenia wiarygodności modelu neuronowego przy zastosowaniu podobieństwa przestrzennego Morana [Moran 1948]. Trójwymiarową przestrzeń badawczą określały osie: liczba przesypów, numer pierścienia i wariancja.

Wyniki

Wyniki badań pokazano na wykresach obrazujących wartości wariancji w odcieniach szarości dla rozkładów empirycznych i wyprognozowanych przez sieć neuronową (rys. 3a i 3b).

Dla uzyskanych rozkładów przestrzennych wariancji (Rys. 3a i 3b) po 5 (6-10) krokach mieszania i dla kolejnych 10 pierścieni, dokonano analizy podobieństwa przestrzennego wartości predykowanych oraz empirycznych używając metody współczynnika korelacji przestrzennej Morana. W oparciu o procedurę obliczeniową w programie S+SPATIALSTAT 1.0 [Kaluzny, Vega, Cardso, Shelly, 1996] uzyskano następujące wyniki współczynnika korelacji przestrzennej: 0,4786 dla $p=3,013e-6$. Wyniki te świadczą o istotnym podobieństwie analizowanych rozkładów przestrzennych.



Rys. 3. Wartości wariancji dla pierścieni zbiornika po kolejnych krokach mieszania, a) empiryczne, b) wyprognozowane przez sieć

Fig. 3. Variation values for container rings after successive mixing steps, a) empirical, b) forecasted by the network

Wnioski

1. Wykorzystanie komputerowej analizy obrazu jest praktycznym i wygodnym sposobem oceny rozkładu traseru podczas mieszania systemem funnel – flow.
2. Zmiana wartości wariancji świadcząca o rozkładzie powierzchniowym składnika kluczowego może być parametrem oceny stopnia zmieszania układu ziarnistego.
3. Sieć neuronowa poddana uczeniu jest w stanie wyprognozować prawdopodobne obrazy rozkładu traseru.
4. Ocena statystyczna obrazu empirycznego z obrazem predyktowanym przez sieć w ujęciu przestrzennym oparta na współczynniku korelacji Morana daje podstawy do stwierdzenia wysokiej wiarygodności stosowanej metody prognozowania.

Bibliografia

Boss J., Krótkiewicz M., Tukiendorf M. 2001. Porównanie metod jakości stanu mieszaniny ziarnistej podczas mieszania w przesypie. Krynica 2001.

Kaluzny S.P., Vega S.C., Cardso T.P., Shelly A.A. 1996. S+Spatialstats User's Manual, Version 1.0. Mathsoft, Inc. Seattle 1996.

Lampinen J., Vehtari A. 2001. Bayesian approach for neural networks-review and case studies. Neural Networks 14, 257-274.

Moran P.A.P. 1948. The interpretation of statistical maps. Journal of the Royal Statistical Society, Series B37, 243-51.

Tukiendorf M. 2002a. Ocena jakości mieszaniny ziarnistej w przekrojach poprzecznych podczas mieszania według systemu funnel –flow. Problemy Inżynierii Rolniczej, 3 (37), Warszawa.

Tukiendorf M. 2002b. Zagadnienie rozkładu koncentracji składników niejednorodnej mieszaniny ziarnistej podczas mieszania w przesypie. Inżynieria i Aparatura Chemiczna 4, Olsztyn.

Tukiendorf M. 2002c. Sposoby oceny jakości mieszania ziarnistych w zbiornikach. Technika Agraria 1(2)/2002.

Tukiendorf M. Modelowanie neuronowe procesów mieszania niejednorodnych układów ziarnistych. Rozprawy Naukowe Akademii Rolniczej w Lublinie.

Tukiendorf M. 2003. Optymalizacja procesu mieszania metodą zezbiornika do zbiornika ziarnistych układów niejednorodnych. Postęp Techniki Przetwórstwa Spożywczego, nr 1/2003, Wydawnictwo Instytut Maszyn Spożywczych, Warszawa.

ESTIMATING THE DISTRIBUTION OF A GRANUAL MOLECULE MIXED USING THE FUNNEL-FLOW SYSTEM

Summary

This research presents the outcomes of neuron modeling of the mixing process of a non-homogeneous grain configuration by the use of a funnel-flow system. On the basis of a computer image analysis an estimation of was executed the molecule distribution of each key component the observed. Speciffically a cross-section of the mixing device used in this process was analysed for statistical variance in key-component distribution. On the basis of the first five mixing steps the FBM network has been learned. Next, on the basis of the outcomes the network predicted the distribution of the key component concentration after the next five mixing steps. A statistical model comparison (empirical and predicted) was done using the spatial autocorrelation.

Key words: grain, mixing, quality evaluation of grain configuration, computer analysis of picture, neural networks, spatial correlation coefficient