

Marek Tukiendorf  
Wydział Mechaniczny  
Politechnika Opolska

## ZASTOSOWANIE SIECI FBM W NEURONOWYM MODELOWANIU MIESZANIA DWUSKŁADNIKOWYCH UKŁADÓW ZIARNISTYCH

### Streszczenie

Pokazano wyniki symulacji neuronowej procesów mieszania niejednorodnych układów ziarnistych. Mieszano dwuskładnikowy układ ziarnisty przy pomocy statycznego mieszalnika płytkowego. Estymacji rozkładów koncentracji składnika kluczowego dokonywano w oparciu o predykcję sztucznej sieci neuronowej *Flexible Bayesian Modeling* o 20 ukrytych warstwach neuronów. Porównano statystycznie wyniki modelu empirycznego i predyktowanego. Określono współczynnik korelacji.

**Słowa kluczowe:** ziarniste układy niejednorodne, statyczny mieszalnik płytkowy, modelowanie neuronowe, sieć *Flexible Bayesian Modeling*

### Wykaz oznaczeń

- $a_x, a_y$  – adresy siatki na powierzchni kaset;  
 $b(1, 0)$  – informacja o występowaniu lub braku trasera;  
 $d$  – średnia średnica cząstek; *mm*  
 $N$  – numer kroku mieszania;  
 $u_n$  – wektor sygnałów wejściowych;  
 $x_n$  – wartości koncentracji obserwowanego składnika;  
 $\rho$  – gęstość składników,  $kg/m^3$

### Wprowadzenie

Poszukiwanie nowych, tanich i szybkich sposobów mieszania niejednorodnych układów ziarnistych jest bardzo poważnym wyzwaniem dla przemysłu rolno-spożywczego. Zważywszy na fakt, iż mieszanin materiałów ziarnistych towarzyszy często silna segregacja przeciwdziałająca homogenizacji ważny jest właściwy

dobór urządzeń mieszających [Boss 1987]. Są jednak układy ziarniste, które nie pozwalają się dobrze mieszać, ze względu na zbyt istotne różnice pomiędzy ich własnościami fizycznymi i chemicznymi [Boss, Tukiendorf 1990]. Dlatego ważna jest wówczas jak najszybsza informacja o ich maksymalnych zdolnościach do homogenizacji.

W modelowaniu procesów mieszania takich układów dobrze się sprawdzają stosowane od niedawna metody sztucznej inteligencji oparte na użyciu sztucznych sieci neuronowych (ssn) [Tukiendorf 2003]. Jedną z sieci jest nieczęsto stosowanych w Polsce jest sieć typu *Flexible Bayesian Modeling* pracująca w środowisku *Linux*. Jakkolwiek dobór sieci może mieć charakter ze zupełnie arbitralny, to są pewne powody przemawiające za użyciem takiego właśnie pakietu. Po pierwsze zarówno pakiet jak i środowisko, w którym działa są bezpłatne. Dodatkową zaletą jest to, że sieć typu *FBM* jest łatwa w użyciu. Przygotowuje się własne procedury umożliwiające nadanie modelowaniu bardziej indywidualnego charakteru niż pakiety standardowe. A co najważniejsze „bayesowskie” uczenie sieci ogranicza możliwość jej przeuczenia zwiększając wyraźnie trafność predykcji [Lampinen, Vehtari 2001].

### **Cel badań**

Celem badań było udowodnienie, że modelowanie procesów mieszania niejednorodnych układów ziarnistych przy pomocy pakietu *FBM* jest dobrą metodą predykcji rozkładów koncentracji mieszanych składników. Modelowano proces mieszania dwuskładnikowego układu ziarnistego mieszanego przy pomocy statycznego mieszalnika przesypowego z wypełnieniem płytkowym [Boss, 1983]. Mieszano układ dwuskładnikowy.


### **Sposób prowadzenia badań**

*Mieszanie przy użyciu mieszalnika statycznego z wypełnieniem płytkowym układów dwuskładnikowych*

Mieszalnik płytkowy składał się z dwóch kaset podzielonych na 9 cel. Kasety znajdowały się na górze i u dołu komina mieszającego. Przed rozpoczęciem mieszania traser (składnik kluczowy – rozpraszany) umieszczono w środkowej celi kasety zasilającej, natomiast w ośmiu zewnętrznych celach umieszczono wypełniacz (rys. 1). Następnie wypuszczano materiał z kasety zasilającej, który przesypany się po układzie szeregu płytek w kominie mieszającym ulegał mieszanemu. Kasety zamieniano miejscami (odbierająca – zasilająca: góra – dół). Proces powtarzano pięciokrotnie. Zastosowany system umożliwił szybkie osiągnięcie dobrych efektów zmieszania.

Tabela 1. Tabela użytych materiałów ziarnistych oraz ich podstawowe własności  
Table 1. ???

materiał	soja	rzepak
średnia średnica ziaren - $d$ , mm	4,5	2,0
gęstość - $\rho$ , kg/m <sup>3</sup>	1250	1200



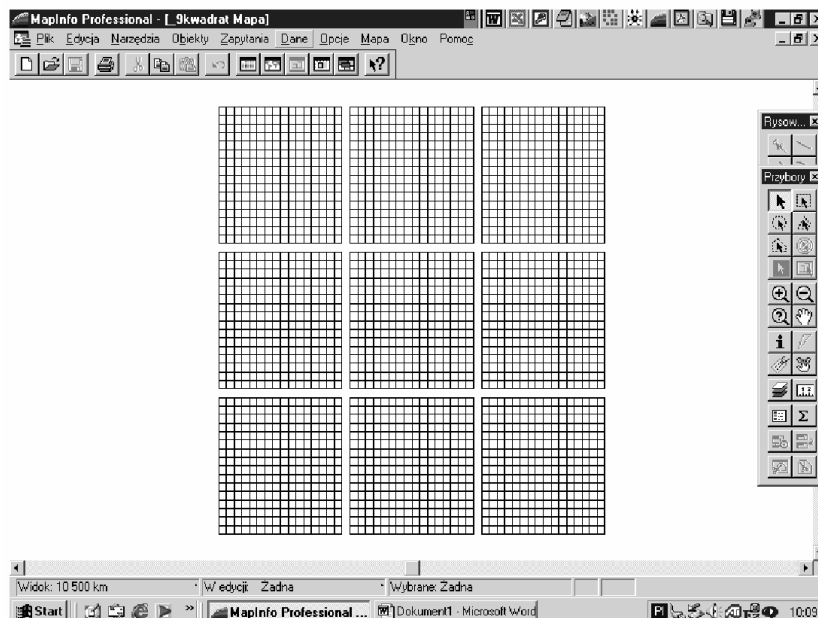
Rys. 1. Mieszalnik statyczny - płytkowy; a) widok ogólny; b) kasetka zasilająca – 9 cel; c) kasetka zasypana materiałem ziarnistym – traser w środkowej celi; (segregacja pierwotna)

Fig. 1. ???

#### Topologia sieci, definicje sygnałów wejścia i wyjścia, predykcja

Przyjęto algorytm jednokierunkowej wieloperceptronowej (MLP) sztucznej sieci neuronowej [Tadeusiewicz 1993, 1998], Zastosowano sieć typu *Flexible Bayesian Modeling* pracującą w środowisku *Linux* o  $H = 20$  ukrytych warstwach.

W procesie przygotowywania danych na każdą z cel nakładano 256-punktową (16x16) siatkę o przekroju kwadratowym (rys. 2).



Rys.2. Siatka dla dziewięciu przekrojów cel mieszalnika statycznego  
 Fig. 2. ???

Przy jej pomocy identyfikowano ziarna traseru uzyskując w ten sposób dane do opisu wektorów sygnałów wejściowych  $u_n$ . Określały one rozkład oraz wartości koncentracji  $x_n$  obserwowanego składnika (zabarwiona na biało soja) po  $N = 1$  i 2 kroku mieszania, na powierzchni wszystkich przekrojów 9 cel. Oceniano poziom odcieni szarości w poszczególnych elementach siatki nadając kolejnym adresom  $(a_x, a_y)$  informacje  $b(1, 0)$ - kolor czarny lub jasny (soja lub rzepak) (Rys. 2).

Wektory sygnałów wejściowych zdefiniowano następująco:


$$u_n = [x_n; (a_x, a_y); b(0, 1); N] \quad (2)$$

Do nauczania sieci przedstawiano wyniki uzyskane na drodze kolejnych kroków mieszania (zbiór uczący: po 1 i 2 kroku). Następnie prowadzono obserwacje rozkładu składników po kolejnych trzech krokach (3, 4, 5). Po piątym kroku mieszanie przerwano uznając, że mieszanina osiągnęła stan równowagowy [Tukiendorf, 2003]. Sieć w wyniku predykcji - na podstawie doświadczeń zbioru treningowego - udzielała odpowiedzi na temat możliwego rozkładu poszczególnych ziaren traseru

w dziewięciu celach kaset, po kolejnych krokach mieszania (3, 4, 5) Wyniki modelowania neuronowego porównano z wynikami rozkładów koncentracji zaobserwowanymi empirycznie.

### Analiza wyników

Wszystkie uzyskane wyniki przedstawiono w formie histogramów obrazujących w odcieniach skali szarości - wartości koncentracji zaobserwowanych i przewidywanych na powierzchni 9 cel, we wszystkich badanych przekrojach. Wybrany przykład rozkładu po ostatnim (piątym kroku) mieszania podano na rysunku 4 a, b. Przy czym obraz na rysunku 4a dotyczy rozkładu empirycznego, podczas gdy obraz na rysunku 4b jest predykcją sieci.



Rys. 3. Rozkłady traseru po piątym kroku zmieszania a) rozkład empiryczny, b) rozkład predyktowany

Fig. 3. ???

## Statystyczna analiza podobieństwa

Dokonano statystycznego porównania wartości rozkładów koncentracji składników dla wszystkich predykowanych przypadków. W oparciu o test dla współczynnika  $\tau$  Kendalla oceniono istotność różnic pomiędzy empirycznymi i prognozowanymi wartościami koncentracji po trzecim, czwartym i piątym kroku mieszania. Jest to test do badania korelacji między dwiema cechami X i Y w oparciu o analizę dwóch zbiorów rang, odpowiednio wyników obserwacji zmiennej losowej X i Y. Miarą korelacji i zarazem statystyką testową jest tzw. współczynnik  $\tau$  Kendalla [Kendall 1975, Magiera 2002]. Porównano 27 rekordów (9 cel x 3 kroki) uzyskując zadawalającą wartość współczynnika korelacji  $\tau = 0,6341$  (przy  $\tau = 1,0$  dla przypadku pełnej zgodności wszystkich rang  $\tau = -1,0$  dla zupełnej niezgodności).

## Wnioski

Uzyskane wyniki pozwalają na przyjęcie hipotezy o dobrym statystycznym podobieństwie modeli: empirycznego i neuronowego. W prowadzonych już wcześniej badaniach - nad modelowaniem procesów mieszania układów niejednorodnych - przy zastosowaniu mieszalników statycznych, dla innych par składników, uzyskiwano dobre ale nieco niższe wartości współczynnika  $\tau$  Kendalla [Tukiendorf 2003]. W przypadku omówionego sposobu modelowania uzyskano miarodajne predykcje o zachowaniu się trasaera na podstawie doświadczeń 40% eksperymentu. Wyższa wartość współczynnika  $\tau$  w porównaniu z badaniami prowadzonymi wcześniej [Tukiendorf 2003] może być konsekwencją lepszej percepcji sieci będącej skutkiem poprawniejszego nauczania.

## Bibliografia

- Boss J. 1987. Mieszanie materiałów ziarnistych, PWN Warszawa-Wrocław.
- Boss J. Mieszalnik statyczny z wypełnieniem płytkowym, Patent PRL 119191.
- Boss J., Tukiendorf M. 1990. Wpływ niektórych parametrów ziarnistych na stan dynamiczny układu podczas mieszania metodą wysypu ze zbiornika, Zeszyty Naukowe Politechniki Łódzkiej, Inżynieria Chemiczna, z 16, 29-36.
- Kendall M.G., M. G. 1975. Rank correlation methods (4th ed.), Griffin London.
- Lampinen J., Vehtari A. 2001. Bayesian approach for neural networks-review and case studies, *Neural Networks* 14, 257-274.

Magiera R. 2002. Modele, metody statystyki matematycznej, Oficyna wydawnicza GiS, Wrocław.

Tadeusiewicz R. 1998. Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami, Wydawnictwo PLJ.

Tadeusiewicz R. 1993. Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa.

Tukiendorf M. 2003. Modelowanie neuronowe procesów mieszania niejednorodnych układów ziarnistych, Rozprawa habilitacyjna, Prace i monografie, Akademia Rolnicza w Lublinie.

## **THE USE OF A NEURAL NETWORK IN MODELING OF A TWO-COMPONENT GRANULAR SYSTEMS' MIXING**

### **Summary**

The results of a neural network's simulation of the mixing processes of non-homogenous granular systems were shown. A two-component granular system was mixed using a static plate mixer. Estimations of the key component's concentration distribution were performed based on the artificial neural network's prediction for the assumed numbers of neurons' hidden layers. The empirical and the predicted results were statistically compared. A correlation coefficient was estimated between them.

**Key words:** non-homogenous granular systems, a static plate mixer, neural modeling, FBM