

Marek Tukiendorf
Zakład Techniki Rolniczej i Leśnej
Politechnika Opolska

PRZYKŁAD ZASTOSOWANIA SIECI NEURONOWEJ W MODELOWANIU PROCESU MIESZANIA UKŁADÓW ZIARNISTYCH

Streszczenie

W pracy pokazano skuteczność i przydatność modelowania neuronowego w procesie mieszania dwuskładnikowego niejednorodnego układu ziarnistego mieszanego systemem funnel-flow.

Słowa kluczowe: niejednorodna mieszanina ziarnista, stan równowagowy, modelowanie neuronowe

Wykaz oznaczeń

- d – średnia średnica cząstek; mm
 $F\{\cdot\}$ – nieliniowy operator aktywacji neuronów;
 k – wektor sygnałów wejściowych;
 N_h – operator przetwarzania neuronowego kolejnej ukrytej warstwy H;
 N_{wyj} – operator przetwarzania neuronowego warstwy wyjściowej;
 W^h – macierz współczynników wag połączeń pomiędzy warstwami H i H-1;
 W^{wyj} – macierz współczynników wag połączeń między warstwą wyjściową i H - tą warstwą ukrytą;
 ρ – gęstość składników, kg/m³

Wprowadzenie

Procesy mieszania materiałów ziarnistych nie dają się opisać prostymi sposobami analitycznymi. W zależności od sposobów mieszania oraz rodzaju mieszanych układów, mieszanie może wykazywać cechy różnych modeli o postaciach charakterystycznych dla wybranych działów inżynierii procesowej, czy też probabilistyki.

Złożoność zachodzących zjawisk w mieszaniu inspiruje do poszukiwania innych, niż systemy ekspertowe, metod modelowania. Dlatego też podjęto próbę zastosowania metod opartych na programach tzw. sztucznej inteligencji, która zyskuje coraz większą rolę w technologiach przemysłu rolnego i spożywczego [Koszela, Boniecki, Weres 2001; Kusz Marciniak 1998; Tukiendorf 2003]. Przeprowadzono kilkietapowe eksperymenty. Mieszano układ dwuskładnikowy. Wybraną parę materiałów ziarnistych poddano mieszaniu systemem funnel-flow.


Cel badań

Celem badań było udowodnienie, że modelowanie neuronowe w procesie mieszania materiałów ziarnistych przy użyciu przesypowego mieszalnika statycznego jest dobrą metodą prognozowania. Sieć uczono na przykładzie pierwszych trzech kroków mieszania oczekując jej predykcji po 3 kolejnych.

Sposób prowadzenia badań

Mieszanie systemem funnel-flow

Dwuskładnikowy układ ziarnisty mieszano na drodze kolejnych przesypów ze zbiornika do zbiornika (rys. 1, tab.1) Zbiorniki charakteryzowały się specjalną konstrukcją umożliwiającą ich rozłożenie na 10 nakładanych kolejno na siebie pierścieni. System taki pozwalał na rozbiór zbiornika od góry do dołu, pierścien po pierścieniu.



Rys. 1. Schemat stanowiska badawczego: a) układ zbiorników do mieszania systemem funnel-flow; b) zbiornik analityczny z rozbieganymi segmentami

Fig. 1. Layout of a research stand: a) system of reservoirs for mixing in the funnel-flow system; b) analytic tank with removable segments

Tabela 1. Tabela użytych materiałów ziarnistych oraz ich podstawowe własności
 Table 1. Table of grainy materials and their basic properties

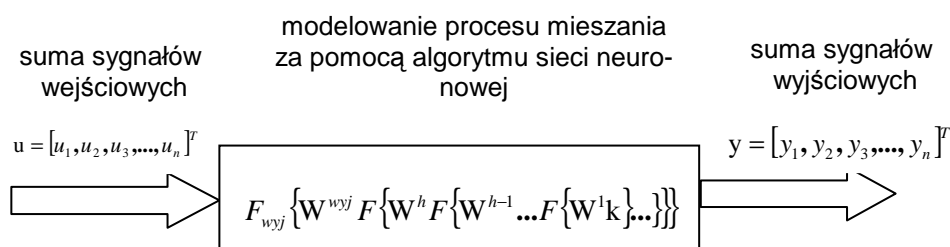
| Materiał | soja | gorczyca |
|--|------|----------|
| średnia średnica ziaren - d, mm | 4,5 | 2,0 |
| gęstość usypowa - ρ, kg/m ³ | 1250 | 1200 |

Przed rozpoczęciem mieszania zasypano zbiornik podający (o wymiarach jak w pracach Boss i in. [2002]; Tukiendorf [2002]) dwoma składnikami ziarnistymi w proporcji 1:8 (objętościowo – soja/gorczyca). Nasiona soi umieszczono w piątej (środkowej) sekcji mieszalnika. Umieszczenie składnika na pozycjach bardziej odległych od środka zbiornika, nie sprzyja dobrym efektom mieszania [Boss, Tukiendorf 1990, 1998]. Resztę objętości, tj. poniżej i powyżej piątej sekcji, zasypano gorczycą. Następnie wysypywano ładunek do zbiornika odbierającego umieszczonego poniżej zbiornika podającego. W trakcie tego wysypu następowało mieszanie. Po przesypaniu zbiorniki zamieniano miejscami w taki sposób, że dotychczasowy zbiornik zasilający stawał się odbierającym i na odwrót. Mieszanie prowadzono aż do osiągnięcia stanu równowagowego.

Topologia sieci, definicje sygnałów wejścia i wyjścia, predykcja

Przyjęto algorytm jednokierunkowej wieloperceptronowej (MLP) sztucznej sieci neuronowej (rys. 2) [Tadeusiewicz 1993, 1998], dla której ogólne odwzorowanie wejście-wyjście zostało zdefiniowane przy pomocy przedstawionego we wzorze (1) operatora aktywacji $F\{\cdot\}$ o ogólnej postaci:


$$y = N\{\mathbf{k}\} = F_{wyj} \{ \mathbf{W}^{wyj} F \{ \mathbf{W}^h F \{ \mathbf{W}^{h-1} \dots F \{ \mathbf{W}^1 \mathbf{k} \} \dots \} \} \} = N_{wyj} N_H N_{H-1} N_1 \{ \mathbf{k} \} \quad (1)$$



Rys. 2. Schemat blokowy doświadczenia
 Fig. 2. Block diagram of the experiment

Zastosowano sieć typu Flexible Bayesian Modeling pracującą w środowisku Linux o $H = 20$ ukrytych warstwach. Wektory sygnałów wejściowych u_n określały rozkład oraz wartości koncentracji x_n obserwowanego składnika (zabarwiona na czarno soja) po $N = 1, 2$ i 3 kroku mieszania, na powierzchni wszystkich badanych 9 przekrojów mieszalnika. Opisano nimi pozycje poszczególnych pikseli obrazu przekroju o adresach (a_x, a_y) informacjami $b(1, 0)$ - kolor czarny lub jasny (soja lub gorczyca) (rys. 3). Wektory te zdefiniowano następująco:

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



Rys. 3. Cyfrowy zapis rozkładu koncentracji nasion soi i gorczycy na wybranym przekroju mieszalnika

Fig. 3. Digital recording of distribution of soya and charlock seeds in a selected agitator section


Do nauczania sieci przedstawiano wyniki uzyskane na drodze kolejnych kroków mieszania (zbiór uczący: po 1, 2 i 3 kroku). Następnie prowadzono obserwacje rozkładu składników po kolejnych krokach mieszania (4, 5, 6 krok). Po szóstym kroku mieszanie przerwano uznając, że mieszanina osiągnęła stan równowagowy [Tukiendorf, 2003]. Predyktowanymi odpowiedziami sieci były informacje zawarte w wektorach sygnałów wyjściowych (po kroku $N = 4, 5$ i 6). Różniły się one od wektorów wejściowych informacją o sposobie rozmieszczenia czarnych i jasnych pikseli w badanym przekroju (a'_x, a'_y) oraz informacją o ich koncentracji powierzchniowej w przekroju x'_n :

$$y_n = [x_n'; (a_x', a_y'); b' (0,1); N] \quad (3)$$

Uzyskane na drodze predykcji neuronowej wyniki zostały porównane z zaobserwowanymi empirycznie wynikami rozkładów koncentracji mieszanych składników (dla kroków: 4, 5, 6).


Wyniki

Wyniki badań pokazano na kołowych histogramach obrazujących w odcieni skali szarości wartości koncentracji zaobserwowanych i predyktowanych na powierzchni poszczególnych przekrojów. Przykłady niektórych z nich podano na rysunkach 4 i 5. Po lewej stronie pokazano rozkłady empiryczne, po prawej predyktowane przez sieć:



Rys. 4. Rozkład i wartości koncentracji traseru: 2. przekrój; 4. krok mieszania (pierwszy predyktowany)

Fig. 4. Distribution and concentration values of traser: 2. section; 4. agitation step (first predicted)



Rys. 5. Rozkład i wartości koncentracji traseru: 3. przekrój; 6. krok mieszania (trzeci predyktowany)

Fig. 5. Distribution and concentration values of traser: 3. section; 6. agitation step (third predicted)

Statystyczna analiza podobieństwa

Dokonano statystycznego porównania wartości rozkładów koncentracji składników dla wszystkich predyktowanych przypadków. W oparciu o test dla współczynnika τ Kendalla oceniono istotność różnic pomiędzy empirycznymi i prognozowanymi wartościami koncentracji po czwartym, piątym i szóstym kroku mieszania. Jest to test do badania korelacji między dwiema cechami X i Y w oparciu o analizę dwóch zbiorów rang, odpowiadających wynikom obserwacji zmiennej losowej X i Y. Miarą korelacji i zarazem statystyką testową jest tzw. współczynnik τ Kendalla [Kendall 1975, Magiera 2002]. Porównano 243 rekordy (9 pierścieni x 9 segmentów x 3 kroki) uzyskując wartość współczynnika korelacji $\tau=0,8341$ (przy $\tau = 1,0$) dla przypadku pełnej zgodności wszystkich rang.

Wnioski

Uzyskane wyniki pozwalają na przyjęcie hipotezy o wysokim statystycznym podobieństwie modelu empirycznego i neuronowego. Prowadzono już obserwując inne rodzaje mieszanin, podobne badania nad modelowaniem procesów mieszania układów niejednorodnych. Uzyskano nieco niższe, ale także zadawalające wyniki [Tukiendorf 2003]. Uzyskane informacje stanowią dodatkowy wkład do zagadnień

modelowania niejednorodnych układów ziarnistych. Zdobyte doświadczenia mogą w najbliższej przyszłości być bardzo przydatne w kontekście przeciwdziałania segregacji, zjawisku ograniczającemu procesy homogenizacji.

Bibliografia

Boss J., Krótkiewicz M., Tukiendorf M. 2002. Porównanie metod oceny jakości stanu mieszaniny ziarnistej podczas mieszania w przesypie. *Inżynieria Rolnicza* 4, (37), 27-32

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.

Boss J., Tukiendorf M. 1998. Mieszanie wibracyjne. *Zeszyty Naukowe Politechniki Białostockiej, Nauki Techniczne Nr 120, Budowa i Eksploatacja Maszyn Zeszyt 5*, 37-48.

Kendall M. G. 1975. *Rank correlation methods* (4th ed.). Griffin London.

Kozłowski J., Kusz A., Weres J. 2001. Nowoczesne technologie informatyczne w projektowaniu systemów doradczych w zakresie ochrony roślin. Komitet Techniki Rolniczej PAN, Polskie Tow. Inżynierii Rolniczej, IBMER, Warszawa, *Inżynieria rolnicza* 7, 126-132.

Kusz A., Marciniak W. 1998. Zastosowanie technologii informacyjnych w rolnictwie. Streszczenia referatów, Kazimierz n. Wisłą, Inst. PT AR w Lublinie; Inst. Mech. Rol. AR w Poznaniu; Pol. Tow. Inż. Rol.; Kom. Tech. Rol. PAN, 29-30.

Koszela K., Boniecki P., Weres J. 2001. Wykorzystanie elementów sztucznej inteligencji w praktyce rolniczej. *Inżynieria Rolnicza*, Nr 11.

Magiera P. 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. 2002. Zagadnienie rozkładu koncentracji składników niejednorodnej mieszaniny ziarnistej podczas mieszania w przesypie. *Inżynieria i Aparatura Chemiczna*,4, 39-40.

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

AN EXAMPLE OF THE USE OF A NEURAL NETWORK TO MODEL A MIXING PROCESS OF GRANULAR SYSTEMS

Summary

In the study, an efficiency and usefulness of neural network was shown to model the mixing process of a two-components non-homogenous granular system during the funnel-flow mixing.

Key words: non-homogenous grainy mixture, balance status, neural modelling