

Marek Rynkiewicz  
Instytut Inżynierii Rolniczej  
Zakład Użytkowania Maszyn i Urządzeń Rolniczych  
Akademia Rolnicza w Szczecinie

## ANALIZA JAKOŚCIOWA MODELI NEURONOWYCH NA PRZYKŁADZIE WYTRZYMAŁOŚCI KINETYCZNEJ GRANUL

### Streszczenie

W pracy dokonano analizy działania modeli neuronowych, które różniły się parametrami tj. liczbą neuronów i liczbą warstw ukrytych. Ocenę jakości działania przeprowadzono w oparciu o wartości uzyskanych błędów względnych i odchylenia standardowego. Do nauczania sieci neuronowych wykorzystano dane, dotyczące zależności pomiędzy średnią średnicą granulowanych cząstek komponentów i temperatury pary wodnej podawanej do kondycjonera granuladora a wytrzymałością kinetyczną granul.

Słowa kluczowe: wytrzymałość kinetyczna, sztuczna sieć neuronowa

### Wprowadzenie

Sztuczne sieci neuronowe należą do jednej z dziedzin sztucznej inteligencji. Symulują one działanie ludzkiego mózgu. Mogą być stosowane w zadaniach, które wymagają kojarzenia informacji. Sztuczne sieci neuronowe mogą rozwiązywać określone problemy po jej nauczaniu, bez konieczności głębokiej znajomości tworzonego modelu [Dokumentacja programu Neuronix 2.3., 1999]. Skuteczność działania modelu opartego na sztucznych sieciach neuronowych zależy od jego jakości. Jakość ta może zależeć od struktury sieci neuronowej (liczby neuronów wejściowych, wyjściowych, liczby warstw ukrytych wraz z liczbą neuronów w poszczególnych warstwach) oraz nauczania sieci. Modele neuronowe znajdują zastosowania w rolnictwie i z powodzeniem wykorzystywane są do opisywania zachodzących zjawisk [Złobecki i Francik 2000].

Znajomość wytrzymałości kinetycznej granul, która jest jednym z parametrów określających jakość paszy granulowanej [Beyer i in. 1999; Grochowicz 1996],

w zależności od parametrów technicznych i technologicznych procesu granulowania oraz właściwości granulowanych komponentów, ma na celu dobranie takich wielkości parametrów procesu granulowania, aby uzyskać wyrób przy najmniejszych nakładach pracy i energochłonności, a o wysokich walorach jakościowych produktu.

### **Cel badań**

Celem badań było określenie jakości działania modeli opartych na sztucznych sieciach neuronowych z różną liczbą neuronów i warstw ukrytych na przykładzie. Utworzone modele opisywały zależności pomiędzy jakością paszy granulowanej w zależności od parametrów technologicznych procesu produkcji.

### **Metodyka badań**

Do uczenia sieci neuronowych wykorzystano parametry procesu technologicznego produkcji paszy granulowanej. Parametrem wejściowym było ciśnienie pary wodnej podawanej do kondycjonera granulatora ( $P_k$ ) oraz stopień rozdrobnienia komponentów ( $d_g$ ). Parametrem wyjściowym była wytrzymałość kinetyczna paszy granulowanej ( $P_{di}$ ). Dane użyte w eksperymencie uzyskano w trakcie badań przeprowadzonych w Zakładzie Użytkowania Maszyn i Urządzeń Rolniczych, Instytutu Inżynierii Rolniczej Akademii Rolniczej w Szczecinie [Rynkiewicz, 2004].

Badania wykonano dla sieci neuronowych wygenerowanych w programie Neuro-nix. Wspólną cechą badanych struktur sieci była taka sama liczba neuronów wejściowych (2) i neuronów wyjściowych (1). Badania przeprowadzono dla sieci z jedną, dwoma i trzema warstwami ukrytymi. Pierwszy eksperyment przeprowadzono dla sieci z jedną warstwą ukrytą, w której neuronów było od 3 do 10. W drugim przypadku strukturę sieci wzbogacono o drugą warstwę ukrytą, w której znajdowało się pięć neuronów. W trzecim przypadku wprowadzono dodatkowo trzecią warstwę ukrytą również z pięcioma neuronami. Wszystkie neurony w warstwie ukrytej i wyjściowej połączono z dodatkowym neuronem 'bias' w celu uzyskania lepszej stabilności w trakcie uczenia i poprawienia osiągnięć sieci. Proces uczenia sieci trwał do momentu uzyskania najlepszej sieci, tzn. takiej, która uzyskała najmniejszą wartość błędu RMS. Błąd RMS oblicza się jako kwadrat różnicy wartości rzeczywistej i oczekiwanej podzieloną przez liczbę wyrazów w epoce [Dokumentacja programu Neuronix 2.3.1999]. Podział danych na uczące i testujące został przez program Nuronix dokonany losowo.

W celu określenia działania jakości sieci neuronowych obliczano średnią arytmetyczną błędów względnych ( $\epsilon_a$ ) wg wzoru [Dahlquist 1983]:

$$\varepsilon_a = \frac{|y_u - y_o|}{y_o} \cdot 100\% \quad (1)$$

gdzie:

$y_o$  – wartość oczekiwana,

$y_u$  – wartość uzyskana.

Dodatkowo obliczono odchylenie standardowe uzyskanych błędów względnych. Im wartość odchylenia standardowego mniejsza, tym bardziej jednorodne dane.

Analizę statystyczną przeprowadzono przy pomocy programu Statistica i Excel. W celu określenia istotności różnic wartości średnich pomiędzy badanymi parametrami wykorzystano test nieparametryczny Anova Kruskala-Wallisa.


### **Wyniki badań**

Na rys. 1. przedstawiono uzyskane wartości błędów względnych badanych modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi, w zależności od liczby neuronów w pierwszej warstwie ukrytej.

Wyniki badań wykazały, że największą wartość błędu względnego uzyskał model z trzema neuronami w pierwszej warstwie ukrytej. Wartość tego błędu wyniosła 1,28%. Wraz ze zwiększaniem liczby neuronów w pierwszej warstwie, zauważano spadek wartości błędu względnego do wartości 0,31%, dla sieci z sześcioma neuronami w pierwszej warstwie ukrytej. Wraz z dalszym zwiększeniem liczby neuronów następował wzrost wartości błędu względnego. Najmniejszą wartość błędu względnego uzyskał model z dwoma warstwami ukrytymi, przy czym w pierwszej warstwie ukrytej znajdowało się 8 neuronów, a warstwie drugiej pięć.

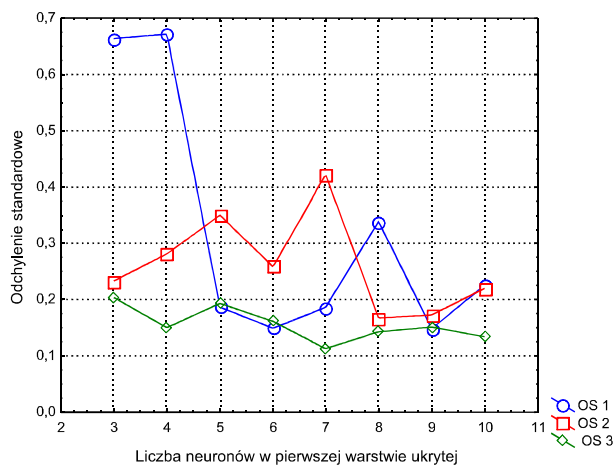
Na rys. 2. przedstawiono uzyskane wartości odchylenia standardowego błędów względnych modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi, w zależności od liczby neuronów w pierwszej warstwie ukrytej.

Maksymalną wartość odchylenia standardowego uzyskała sieć z czterema neuronami w pierwszej warstwie ukrytej (0,67), natomiast najmniejszą wartość uzyskała sieć z trzema warstwami ukrytymi, gdzie w pierwszej warstwie znajdowało się siedem neuronów (0,11). Zwiększanie liczby neuronów w warstwie pierwszej dla sieci jedno, dwu i trzywarstwowej nie zawsze wpływało na zmniejszenie wartości odchylenia standardowego.



Rys. 1. Średnia błąd względny modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi w zależności od liczby neuronów w pierwszej warstwie ukrytej

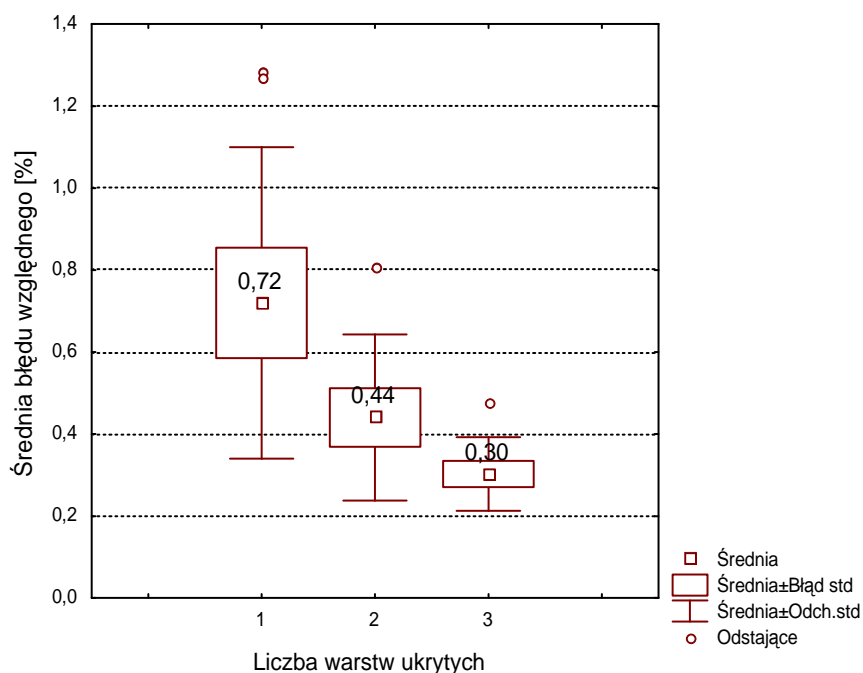
Fig. 1. Average of the relative mistake of neural models with one, two and three hidden layers depending on the neurons number in the first hidden layer



Rys. 2. Odchylenie standardowe błędów względnych modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi w zależności od liczby neuronów w pierwszej warstwie ukrytej

Fig. 2. Standard deviation of relative mistakes of neural models with one, two and three hidden layers depending on neurons number in the first hidden layer

Na rys. 3 pokazano średnie wartości błędów względnych, w zależności od liczby warstw ukrytych.

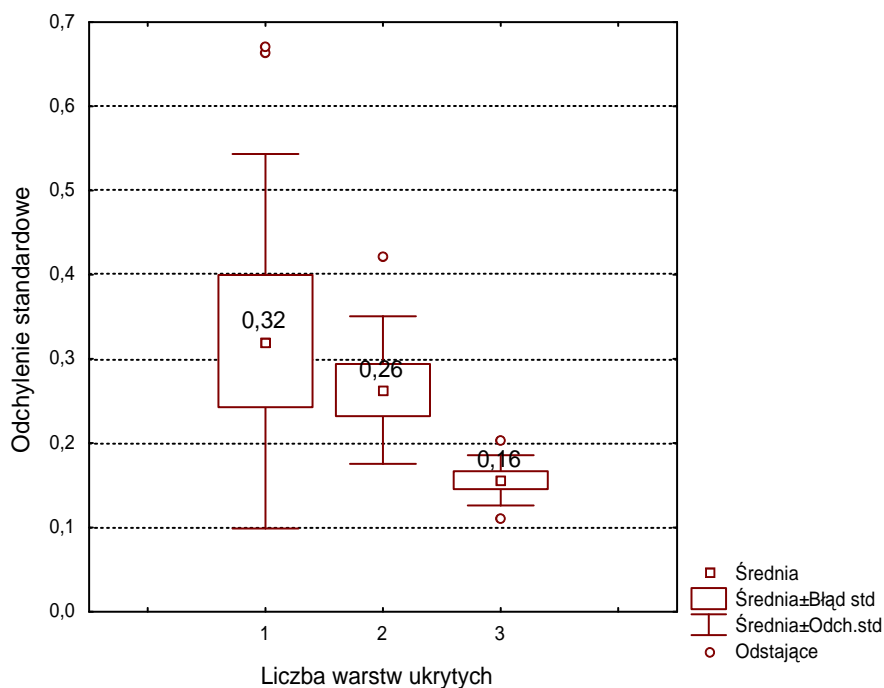


Rys. 3. Średnia wartość błędów względnych modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi

Fig. 3. Medium value of relative mistakes of neural models with one, two and three hidden layers

Maksymalną średnią wartość błędów względnych uzyskano dla modeli z jedną warstwą ukrytą (0,72%). Wraz ze zwiększaniem liczby warstw ukrytych, zaobserwowano spadek średnich wartości błędów względnych. Dla sieci z dwoma warstwami wartość tego błędu wyniosła 0,44% a dla sieci z trzema warstwami 0,30%. Jednak przeprowadzona analiza statystyczna, nie wykazała statycznie istotnych różnic wartości średnich przy  $p > 0,05$  (test nieparametryczny Anova Kruskala-Wallisa) błędów względnych, co potwierdza również rysunek 3.

Na rys. 4 przedstawiono uzyskane wyniki średniego odchylenie standardowego błędów względnych, w zależności od liczby warstw ukrytych.



Rys. 4. Średnia wartość odchylenia standardowego błędów względnych modeli neuronowych z jedną, dwoma i trzema warstwami ukrytymi

Fig. 4. Medium value of standard deviation of relative mistakes of neural models with one, two and three hidden layers

Najmniejszą średnią wartość odchylenia standardowego zaobserwowano dla sieci z trzema warstwami ukrytymi i wyniosła ona 0,16, natomiast średnią wartość maksymalną odchylenia standardowego uzyskano dla sieci z jedną warstwą ukrytą (0,32). Przeprowadzona analiza statystyczna, nie wykazała statycznie istotnych różnic wartości średnich przy  $p > 0,05$  (test nieparametryczny Anova Kruskala-Wallisa) odchylenia standardowego błędów względnych. Brak tej zależności potwierdza również rysunek 4.

### Podsumowanie

1. Najmniejszą wartość średnią błędu względnego uzyskano dla sieci z 8 neuronami w pierwszej warstwie ukrytej i z 5 neuronami w drugiej warstwie ukrytej (0,21%).

2. Najmniejszą wartość odchylenia standardowego uzyskano dla sieci z 7 neuronami w pierwszej warstwie ukrytej, z 5 neuronami w drugiej warstwie ukrytej i 5 w trzeciej warstwie ukrytej (0,11).
3. Wraz ze wzrostem liczby warstw ukrytych malał średni błąd względny oraz odchylenie standardowe, jednak analiza statystyczna nie wykazała statystycznie istotnych różnic wartości średnich.
4. Zbudowane modele charakteryzują się prostotą i mogą być z powodzeniem zastosowane w opisywaniu zachodzących zależności pomiędzy ciśnieniem pary podawanej do kondycjonera granuladora i stopnia rozdrobnienia komponentów na jakość granul, bez potrzeby budowy modeli matematycznych.

### **Bibliografia**

Beyer R. S., Greer D., Fairchild F. 1999. Broiler feed quality are significantly improved by precise ingredient moisture control in the mixer, *Feed International*, August, Vol. 20:8, page 32.

Dahlquist G. 1983. *Metody numeryczne*. PWN, Warszawa.

Dokumentacja programu Neuronix 2.3.1999. Aitech, Katowice.

Grochowicz J. 1996. *Technologia produkcji mieszanek paszowych*. PWRiL, Warszawa.

Rynkiewicz M. 2004. Wpływ cech fizycznych komponentów na jakość paszy granulowanej, *Praca doktorska, IBMER Warszawa*, s. 122.

Złobecki A., Francik S. 2000. Wykorzystanie sztucznych sieci neuronowych do modelowania procesu powstawania strat w kombajnie zbożowym, *Inż. Rol.* nr 8/2000, s. 87-93).

## **QUALITATY MODELS ANALYSIS NEURAL NETWORKS ON THE EXAMPLE OF THE PELLET QUALITY**

### **Summary**

In this work analyses of action of neural model were made. The neural models differed in parameters: number of neurons and the number of hidden layers. The assessment of the quality of action was carried in the support of relative mistakes gotten about value and of standard deviation. Data, concerning the relation was used to teaching neural networks between the average diameter particles of components and the temperature of given steam to conditioner and with kinetic durability of pellets.

**Key words:** degree of fineness, pellets, kinetic strength, neural networks model