

ANALIZA JAKOŚCI MODELU MATEMATYCZNEGO I MODELI OPARTYCH NA SZTUCZNYCH SIECIACH NEURONOWYCH NA PRZYKŁADZIE WYBRANYCH CECH FIZYCZNYCH KOMPONENTÓW

Streszczenie

Opisano procedurę badania wytrzymałości kinetycznej paszy granulowanej. Na podstawie przeprowadzonego eksperymentu zbadano zależności pomiędzy stopniem rozdrobnienia komponentów paszy sypkiej i ciśnieniem pary podawanej do kondycjonera granulatora na wytrzymałość kinetyczną paszy granulowanej. Na podstawie uzyskanych wyników zbudowano model matematyczny i dziewięć modeli opartych na strukturze sztucznych sieci neuronowych. Na podstawie przeprowadzonej analizy nie stwierdzono istotnych różnic w wartościach średnich błędów względnych badanych modeli.

Słowa kluczowe: model matematyczny, sztuczne sieci neuronowe, pasza granulowana wytrzymałość kinetyczna

Oznaczenia

ε_a – błąd względny
 d_g – geometryczna średnia ważona wielkość cząstek – średnica cząstek mm
 K – liczba neuronów w warstwie ukrytej pierwszej
 m – liczba neuronów w warstwie wyjściowej
 m – masa próbki laboratoryjnej badanych granul - 500 g
 m_i – masa granul pozostałych na sicie po zbadaniu ich wytrzymałości g
 n – liczba neuronów w warstwie wejściowej
 P_{di} – wytrzymałość kinetyczna paszy granulowanej %
 P_k – ciśnienie pary podawanej do kondycjonera MPa
 y_o – wartość oczekiwana
 y_u – wartość uzyskana

Wstęp

Stosowanie w żywieniu zwierząt paszy granulowanej umożliwia uzyskanie większej wydajności produkcji zwierzęcej w porównaniu z paszą sypką. Wynika to z wielu zalet, jakimi charakteryzuje się pasza granulowana:

większa wartość odżywcza, mniejsza liczba bakterii i grzybów, nierozwarstwianie się, jest zjadana w całości i chętniej przez zwierzęta [Grochowicz 1996]. Wzrost przyrostu produkcji ściśle związany jest z jakością paszy granulowanej, najczęściej wymieniana w literaturze i najważniejsza jest wytrzymałość kinetyczna. Wysoka wartość wytrzymałości kinetycznej oznacza, że pasza jest bardziej trwała, granule nie ulegają uszkodzeniu podczas transportu [Grochowicz 1996]. Na wytrzymałość kinetyczną paszy granulowanej mają wpływ parametry techniczne i technologiczne procesu granulowania oraz użyte komponenty. Można na nią wpływać przez zmianę ciśnienia pary podawanej do kondycjonera granulatora lub użycie komponentów o różnym stopniu rozdrobnienia. W pracy badawczej dokonano wstępnej oceny wpływu ciśnienia pary podawanej do kondycjonera granulatora i stopnia rozdrobnienia komponentów na wytrzymałość kinetyczną paszy granulowanej. Na podstawie wyników uzyskanych w trakcie badań zbudowano model matematyczny i modele oparte na strukturach sztucznych sieci neuronowych.

Metodyka i przebieg badań

Materiałem badawczym była pasza sypka przeznaczona dla drobiu. W trakcie procesu granulowania dokonywano zmiany ciśnienia pary podawanej do kondycjonera granulatora co 0,05 MPa w zakresie od 0,2 MPa do 0,45 MPa. Badania prowadzono dla mieszanek o średnicy cząstek 0,6 mm, 0,7 mm i 1,6 mm. Po procesie granulowania dokonywano pomiaru wytrzymałości kinetycznej paszy granulowanej.

Do pomiaru wykorzystano tester mechaniczny ZU-05, zbudowany z komory stalowej o wymiarach 285 x 285 x 120 mm, w której umieszczona jest płyta stalowa o wymiarach 230 x 50 x 2 mm (PN-R-64834). Komora testera obracana jest wokół swojej osi z prędkością 50 obr/min. Badania polegały na przygotowaniu próbki ogólnej o masie co najmniej 3 kg z próbek pierwotnych. Z próbki ogólnej odsiewano rozkruszone części na sicie o średnicy otworów mniejszej o 1 mm od średnicy granul. Następnie pobierano trzy próbki laboratoryjne o masie 500g każda. Każdą próbkę umieszczano w komorze, którą wirowano przez 10 min. Po zatrzymaniu testera próbkę odsiewano na sicie o oczkach o średnicy otworów mniejszej o 1 mm od średnicy granul, a pozostałości na sicie były ważone. Uzyskane wyniki wytrzymałości kinetycznej paszy granulowanej obliczano wg wzoru

$$P_{di} = \frac{m_i}{m} \cdot 100 \quad (1)$$

Pomiar wytrzymałości kinetycznej paszy granulowanej wykonywane były

w trzech seriach dla próbek uzyskanych przy tych samych parametrach technologicznych produkcji. Wyniki, w zależności od uzyskanej wytrzymałości kinetycznej granul, klasyfikowano następująco: ocenę niedostateczną otrzymywały granule, których wytrzymałość kinetyczna była mniejsza od 91%, dostateczną dla wartości w przedziale ≥ 91 i < 93 , dobrą ≥ 93 i < 95 . Granule, których wytrzymałość była większa niż 95% klasyfikowano do bardzo dobrej oceny (instrukcja obsługi testera do pasz granulowanych typ zu-05 2000). Na podstawie zebranych danych zbudowano model matematyczny, w oparciu o procedurę podaną przez Stanisza (2000), uzyskując następujący wzór

$$P_{di} = 94,56 + 27,55 \cdot P_k - 13,05 \cdot d_g \quad (2)$$

Zbiory danych z eksperymentu zastosowano również do budowy modeli opartych na sztucznych sieciach neuronowych, które podobnie jak model matematyczny odwzorowują określoną funkcję. Zbudowano dziewięć modeli sztucznych sieci neuronowych, które różniły się pomiędzy sobą liczbą neuronów w pierwszej warstwie ukrytej. Parametrami wejściowymi była średnica cząstek komponentów (d_g) oraz ciśnienie pary podawanej do kondycjonera granuladora (P_k). Parametrem wyjściowym była wytrzymałość kinetyczna paszy granulowanej (P_{di}). Model sztucznych sieci neuronowych realizowano w programie Neuronix 2.3. W celu rozpoczęcia procesu uczenia sieci określano parametry strukturalne sieci, tj. liczbę neuronów w warstwie ukrytej pierwszej. Początkową liczbę neuronów w warstwie ukrytej pierwszej wyznaczono z zależności:

$$K = \sqrt{N \cdot M} \quad (3)$$

Liczba neuronów w warstwie wejściowej i wyjściowej była generowana w sposób automatyczny. Jako punkt zakończenia procesu uczenia przyjęto zaproponowany przez system domyślny warunek:

$$RMS \text{ uczenia} < \text{'epsilon'}$$

gdzie 'epsilon' jest parametrem określającym próg liczbowy dla warunku zakończenia. Błąd RMS jest podstawową miarą stosowaną w systemie Neuronix [Dokumentacja 1999].

W celu uzyskania lepszej stabilności w trakcie uczenia i poprawienia osiągnięć sieci wszystkie neurony w warstwie ukrytej i wyjściowej połączono z dodatkowym neuronem 'bias' [Dokumentacja 1999].

Po nauczeniu sztucznych sieci neuronowych dokonano próby oceny działania wyuczonych modeli neuronowych oraz modelu matematycznego. Analizę oparto na porównaniu uzyskanych wartości wyjściowych w wyniku

działania modelu matematycznego i modeli neuronowych z wartościami oczekiwanymi uzyskanymi w trakcie przeprowadzonego eksperymentu [Grieger, Rynkiewicz 2001]. W tym celu obliczono błędy względne oraz wyznaczono uzyskane wartości minimalne, maksymalne, średnie i odchylenie standardowe.

Po procesie nauczania przeprowadzono kontrolę jakości pracy sieci neuronowych poprzez poddanie ich testom, które polegały na wprowadzaniu do nauczonej sieci wartości wejściowych pochodzących ze zbioru uczącego i testującego. Po wprowadzeniu zbiorów każdą sieć uruchamiano w celu wygenerowania przez model sztucznej sieci neuronowej wartości wyjściowych.

Analiza działania modelu matematycznego i modeli neuronowych

W celu porównania jakości działania modelu matematycznego i dziewięciu modeli neuronowych, dokonano porównania modeli uzyskanych wartości wyjściowych z wartościami wyjściowymi oczekiwanymi, które były zadane w procesie uczenia. W tym celu dokonano obliczenia błędu względnego.

Błąd względny obliczono wg następującego wzoru [Dahlquist 1983]:

$$\varepsilon_a = \frac{|y_u - y_o|}{y_o} \cdot 100\% \quad (4)$$

Istotność różnic wartości średnich sprawdzono testem Kruskala-Wallisa wg założeń wymienionych przez Stanisza [2000].


Wyniki badań

Wartość wytrzymałości kinetycznej w funkcji średnicy cząstek rośnie wraz ze wzrostem stopnia rozdrobnienia komponentów mieszanek użytych do produkcji paszy granulowanej (rys.1). Następuję również jej zmiana w funkcji ciśnienia pary podawanej do kondycjonera granulatora (rys. 2).

Proces uczenia sztucznej sieci neuronowej przeprowadzono dla sieci jednowarstwowej z: dwoma, trzema, czterema, pięcioma, sześcioma, siedmioma, ośmioma, dziewięcioma i dziesięcioma neuronami w warstwie ukrytej.

Na podstawie rysunku 3 można stwierdzić, że najmniejszą wartość maksymalnego błędu względnego uzyskał model matematyczny (12,4%). Maksymalny błąd względny modeli sztucznych sieci neuronowych w każdym wypadku był większy od 18%.


Dokonując analizy wyników błędów względnych uzyskanych przez poszczególne modele zauważono, że błędy względne, których wartość jest większa od 6% stwierdzono przy wartości wyjściowej wytrzymałości kinetycznej mniejszej niż 80% (rys. 4).



Rys.1. Zależność pomiędzy wytrzymałością kinetyczną paszy granulowanej a średnicą cząstek granulowanych pasz

Fig. 1. Relationship between kinematic strength of feed pellets and diameter of pelleted feed particles

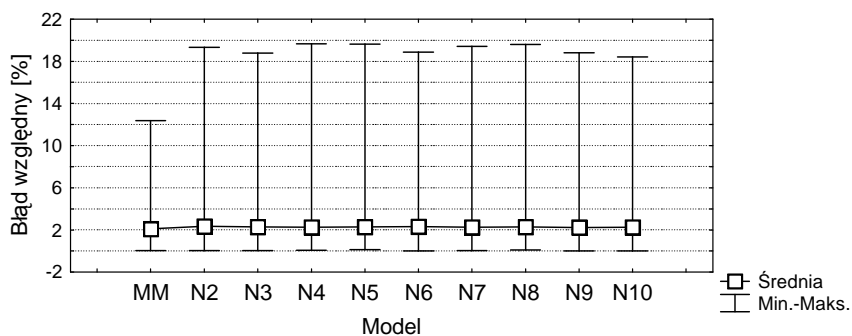
Na rysunku 4 dodatkowo umieszczono linię, którą zostały oddzielone wyniki błędów względnych większych niż 6%. Na podstawie rys. 4 można stwierdzić, że wyniki błędów względnych, których wartość była mniejsza niż 6%, zostały uzyskane przez wszystkie utworzone modele, dla wytrzymałości kinetycznej większej niż 80%. Z tego względu w dalszej analizie porównawczej oceny jakości działania, utworzonych wcześniej modeli, wyniki z błędem powyżej 6% zostały pominięte.



Rys. 2. Zależność pomiędzy wytrzymałością kinetyczną paszy granulowanej a ciśnieniem pary podawanej do kondycjonera granulatora pasz
 Fig. 2. Relationship between kinetic strength of feed pellets and the pressure of steam supplied to conditioning unit of granulator


W tabeli 1 przedstawiono wartość minimalną i maksymalną, średnią, medianę i odchylenie standardowe uzyskanych wyników błędów względnych w wyniku przeprowadzonej analizy jakości działania utworzonych modeli, z pominięciem błędów większych od 6%.

Na podstawie wyników zawartych w tabeli można stwierdzić, że modele mm, n3, n6, n9 i n10 uzyskały minimalny błąd względny, który wyniósł 0%. Najmniejszą wartość błędu maksymalnego uzyskał model matematyczny (mm). Jednak osiągnął on największą wartość względnego błędu średniego (1,7%). Odchylenie standardowe wyników działania większości badanych modeli wyniosło 1,2, oprócz dwóch modeli (n2 i n6), których odchylenie standardowe równało się 1,3.



Rys.3. Wyniki błędów względnych uzyskanych przez utworzone modele. MM – model matematyczny, N2 – N10 – model neuronowy, gdzie liczba określa liczbę neuronów w warstwie ukrytej

Fig. 3. Relative errors arisen at application of studied models. MM – mathematical models, N2 – N10 – neural network based models, where 2 ...10 denoted a number of neurons in a latent layer



Rys.4. Zależność pomiędzy wytrzymałością kinetyczną paszy granulowanej a wynikami błędów względnych uzyskanych przez utworzone modele. Poszczególnym kształtom punktów przyporządkowano oceny wytrzymałości kinetycznej

Fig. 4. Relationship between kinetic strength of feed pellets and relative error values arisen at application of developed models. Particular shape of marks were assigned to kinetic strength valuations

Tabela 1. Wartość minimalną i maksymalną, średnia, mediana i odchylenie standardowe uzyskanych błędów względnych w wyniku przeprowadzonej analizy jakości działania modeli, z pominięciem błędów większych od 6%.
 Table 1. Minimum, maximum and mean values, median and standard deviation of relative errors obtained as a result of models' functioning, excepting the errors higher than 6%

L.p.	Model	Wartość błędu względnego badanych modeli				
		Min	Max	Średnia	Mediana	Odch. Std.
1	MM	0,0	4,6	1,7	1,5	1,2
2	N2	0,1	5,4	1,5	1,1	1,3
3	N3	0,0	5,4	1,5	1,3	1,2
4	N4	0,1	5,3	1,4	1,0	1,2
5	N5	0,1	5,3	1,4	1,0	1,2
6	N6	0,0	5,4	1,4	1,2	1,3
7	N7	0,1	5,2	1,4	1,1	1,2
8	N8	0,1	5,3	1,4	1,0	1,2
9	N9	0,0	5,4	1,4	1,2	1,2
10	N10	0,0	5,3	1,5	1,3	1,2

MM – model matematyczny, N2 – N10 model sztucznych sieci neuronowych, gdzie liczba określa liczbę neuronów w warstwie ukrytej

MM – mathematical model, N2...N10 – the ann models where 2...10 determine number of neurons in a latent layer

W wyniku przeprowadzonej analizy statystycznej nie stwierdzono istotnych różnic wartości średnich wyników błędów względnych pomiędzy modelami sztucznych sieci neuronowych, jak również pomiędzy modelem matematycznym a modelami sztucznych sieci neuronowych. Istotność różnic wartości średnich sprawdzono testem Kruskala-Wallisa wg założeń wymienionych przez Stanisza [1998].

Na podstawie analizy tej można wnioskować, że użycie badanego modelu matematycznego jak i modeli neuronowych, będzie przynosiło jednakowy efekt w badaniu zależności pomiędzy średnicą cząstek komponentów, ciśnieniem pary podawanej do kondycjonera a wynikami wytrzymałości kinetycznej.

Wnioski

1. Największe wartości wytrzymałości, a tym samym pozytywne wyniki oceny wytrzymałości kinetycznej paszy granulowanej stwierdzono dla cząstek granulowanych komponentów średnicy 0,6 mm.
2. Wraz ze wzrostem ciśnienia pary podawanej do kondycjonera granulatora rośnie wytrzymałości kinetycznej paszy granulowanej.
3. Nie stwierdzono statystycznie istotnych różnic w wartościach średnich błędów względnych uzyskanych przez utworzone modele sieci neuronowych, co potwierdza, że istnieje możliwość stosowania ich jako szybkiego narzędzia do oceny badanej materii.

Bibliografia

Dahlquist. 1983. Metody numeryczne. PWN, Warszawa

Dokumentacja programu Neuronix 2.3. 1999. Aitech, Katowice

Grieger A., Rynkiewicz M. 2001. Skuteczność uczenia sieci neuronowej na potrzeby oceny stanu technicznego maszyny rolniczej, Inżynieria Rolnicza 11: 85-90

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

PN-R-64834 – Badanie wytrzymałości kinetycznej granul

Stanisz A. 1998. Przystępny kurs statystyki. Statsoft Polska Sp. z o.o., Kraków

Stanisz A. 2000.: Przystępny kurs statystyki, t.II, Statsoft Polska Sp. z o.o., Kraków.

ADEQUACY OF THE MATHEMATICAL MODEL AND THE MODELS BASED ON ARTIFICIAL NEURAL NETWORKS TO EVALUATING THE KINETIC STRENGTH OF FEED PELLETS

Summary

The procedure of testing kinetic strength of the feed pellets was described. On the basis of experiment results the relationship between finesses degree of ground feed components and the pressure of steam supplied to conditioning assembly of

granulator, as well as their effect on the kinetic strength of feed pellets, were determined. Obtained results enabled to develop the mathematical model and nine models based on artificial neural networks. The ANN based models were the subjects to teaching according to the Neuronix 2.3 software. The errors arising at network teaching were compared with errors attributed to predetermined algorithm. No substantial differences were found between the mean values of relative errors bound to both tested models.

Key words: mathematical model, artificial neural networks, kinetic strength, feed pellets

Recenzent – Zbigniew Siarkowski