

Dr inż. Katarzyna SZWEDZIAK
Katedra Techniki Rolniczej i Leśnej, Politechnika Opolska

MODELOWANIE NEURONOWE W PROCESIE TRANSPORTU WILGOCI W ZIARNIE PSZENICY®

W artykule opisano wykorzystanie sieci neuronowych do opisu transportu wilgoci w ziarnie pszenicy, podczas suszenia metodą niekonwencjonalną. Jako alternatywną metodę do suszenia konwencjonalnego zastosowano suszenie z wykorzystaniem sorbentu naturalnego, jakim było ziarno tego samego gatunku co ziarno suszone.

Słowa kluczowe: sorbent naturalny, sorbent sztuczny, suszenie, sieci neuronowe.

WSTĘP

Transport wilgoci w ziarnie zbóż jest procesem bardzo skomplikowanym i trudnym do interpretacji, ponieważ mamy do czynienia z materiałem porowato-kapilarnym oraz biologicznie czynnym. Do suszenia zbóż wykorzystywane są głównie technologie oparte na metodzie tradycyjnej. Stosuje się suszarki i urządzenia dosuszające wykorzystujące podgrzane powietrze. Do suszenia zbóż można także wykorzystać różnego rodzaju sorbenty w szczególności mineralne, jak również naturalne. Dotychczas wykorzystywane są one na niewielką skalę. Wymogi ostatnich lat preferujące zmniejszenie zużycia energii prowadzą do rozwoju tej metody jako jednej z niekonwencjonalnych metod suszenia zbóż [2, 3].

W ciągu ostatnich lat bardzo dynamicznie rozwijają się badania nad sztuczną inteligencją, a tym samym nad systemami doradczymi, jak również nad zastosowaniem sztucznych sieci neuronowych. Duża ilość prac badawczo-naukowych z wykorzystaniem komputerowego wspomaganie decyzji i innowacyjnych technik modelowania, realizowana jest w ramach inżynierii rolniczej.

Celem artykułu jest przybliżenie zagadnień związanych z modelowaniem neuronowym przy opisie transportu wilgoci w ziarnie pszenicy, podczas suszenia metodą niekonwencjonalną.

CEL BADAŃ

Celem prowadzonych badań zaprezentowanych w artykule było zastosowanie sztucznych sieci neuronowych do empirycznego opisu transportu wilgoci w ziarnie pszenicy podczas suszenia z wykorzystaniem sorbentów naturalnych.

METODYKA BADAŃ

Przeprowadzono 3 serie badań wymiany wody między ziarnami pszenicy o różnej zawartości wody dla 3 różnych udziałów masowych ziarna wilgotnego i sorbentu (tab. 1).

Badanie przebiegu wymiany wody między obiema frakcjami ziarna przeprowadzono w pojemnikach o pojemności 3 kg, do których wsypywano odpowiednio wymieszany materiał tak, aby wypełniał całą objętość pojemnika. Następnie pojemniki zamknięto. Aby uzyskać właściwe wymieszanie obu

frakcji zastosowano metodę przesypu, w której wykorzystano mieszalnik statyczny przesypowy. Ziarna mieszano ze sobą do uzyskania stanu randomowego.

Tabela 1. Skład mieszaniny dla poszczególnych prób pszenicy

Lp.	Materiał wilgotny [%]	Sorbent [%]	Masa ziaren wilgotnych [kg]	Masa sorbentu [kg]
1	50	50	1	1
2	60	40	1,2	0,8
3	75	25	1,5	0,5

W każdej próbie mieszano ze sobą materiał o różnej zawartości wody (tab. 2).


Tabela 2. Zawartość wody w sorbacie i sorbencie dla poszczególnych wariantów

Numer próby	Udział ziaren wilgotnych i suchych [%]	Zawartość wody w sorbacie [kg/kg]	Zawartość wody w sorbencie [kg/kg]
1	50/50	0,25	0,06
2	60/40	0,24	0,06
3	75/25	0,29	0,12

Wymianę wody między ziarnami badano na podstawie zmiany zawartości wody w materiale wilgotnym i w sorbencie podczas trwania procesu. W tym celu pobierano próbki o masie około 50 gram i po rozdzielaniu ziaren określano w nich zawartość wody metodą suszarkową zgodnie z PN-79/R-65950, ważąc próbki sorbatu i sorbentu bezpośrednio po ich pobraniu i rozdzielaniu oraz po wysuszeniu ich w suszarce do stałej masy. Próbkę ważono z dokładnością do $\pm 0,0001$ g. Zawartość wody oznaczano w kg H₂O/kg s.m. Próbkę pobierano co 15 minut przez pierwsze 2 godziny trwania procesu.

ANALIZA WYNIKÓW

Na podstawie uzyskanych wyników sporządzono wykresy transportu wilgoci między ziarnami wilgotnymi i suchymi wykorzystując model oparty na funkcji wielomianowej. Na rysunku 1 przedstawiono przykładowy wykres transportu wilgoci między ziarnami wilgotnymi a sorbentem dla wariantu, gdzie zmieszano 50% ziaren wilgotnych i 50% ziaren suchych.




Rys. 1. Dynamika transportu wody między ziarnami pszenicy, dla wariantu w którym zmieszano ze sobą 50% ziaren wilgotnych i 50% ziaren suchych.

Wykorzystanie funkcji wielomianowej do opisu tego procesu nie dało zadowalających wyników, ponieważ uzyskano dla poszczególnych wariantów niski współczynnik R^2 na poziomie 0,67-0,80. Poszukiwano więc innych rozwiązań, które pozwoliłyby na empiryczny opis tego procesu. W tym celu wykorzystano sztuczne sieci neuronowe. Na podstawie uzyskanych wyników empirycznych przeanalizowano modelowanie neuronowe wykorzystując Automatycznego Projektanta. Spośród 10 modeli sieci wygenerowano 5 modeli spełniających najlepsze kryteria doboru. Wskaźnikiem pozwalającymi określić jakość sieci w momencie jej generowania i uczenia były: jakość uczenia, jakość walidacji oraz jakość testowania. Parametry te rozumiane były jako iloraz odchyłeń standardowych dla poszczególnych podzbiorów (uczącego, walidacyjnego i testowego) oraz błędy uczenia, walidacji i testowania, wyznaczone jako średni błąd kwadratowy dla danego podzbioru. Kolejnym ważnym parametrem był standardowy współczynnik korelacji R Pearsona dla wartości obserwowanych (oczekiwanych) i wartości przewidywanych przez sieć neuronową [1].


Przykładowe wskaźniki wybranego modelu oraz architekturę modelu MLP przedstawia rysunek 2.

Wygenerowany model charakteryzuje się następującymi parametrami: jakość uczenia 0,42; jakość walidacyjna 1,34; jakość testująca 0,87; błąd uczenia 0,15; błąd walidacyjny 0,03; błąd testujący 0,13.

Na podstawie modelu MLP sporządzono wykresy dynamiki oddawania wody oraz pochłaniania jej przez sorbent naturalny. Przykładowe wykresy dynamiki oddawania przez sorbet wody dla wariantu w którym zmieszano ze sobą 60% ziaren wilgotnych i 40% ziaren suchych przedstawia rys. 3.




Rys. 2. Architektura modelu sieci MLP (źródło własne).



Rys. 3. Dynamika oddawania wody przez ziarno wilgotne w czasie (źródło własne).

Na rysunku 4 przedstawiono analogicznie dynamikę pochłaniania wody przez sorbent w czasie. Oba przypadki uzyskały wysoki współczynnik $R^2 = 0,99$.



Rys. 4. Dynamika pochłaniania wody przez sorbent w czasie (źródło własne).

PODSUMOWANIE

Na podstawie wykonanego eksperymentu można wnioskować, że dla metody suszenia ziarna pszenicy z wykorzystaniem sorbentu naturalnego, jakim jest ziarno tego samego gatunku co ziarno suszone, znane rozwiązania empiryczne nie dają zadowalających rezultatów ze względu na złożoność procesu. Zastosowanie sztucznych sieci neuronowych pozwala na wygenerowanie modelu, który daje wysoki współczynnik R^2 . Uzyskane wyniki i sporządzone wykresy wykazały, że ziarno wilgotne oddaje wodę, która jest pochłaniana przez sorbent w początkowej fazie tego procesu, następnie pojawiają się fluktuacje, ponieważ sorbent nawilża się, następnie zaczyna się suszyć i znów nawilża. Jest to związane z tzw. wtórną sorpcją. Sieci neuronowe pozwalają na szybką interpretację wyników i poszukiwanie empirycznych rozwiązań zajmuje stosunkowo niewiele czasu w odniesieniu do tradycyjnych rozwiązań empirycznych. Z tego względu modelowanie neuronowe zasługuje na szczególną uwagę w interpretacji wyników i modelowaniu w zakresie suszenia płodów rolnych.

LITERATURA

- [1] Boniecki P.: Sieci neuronowe typu MLP oraz RBF jako komplementarne modele aproksymujące w procesie predykcji plonu pszenżyta, *Journal of Research and Application in Agricultural Engineering*, 2004, s. 49.
- [2] Pabis S.: *Suszenie płodów rolnych*, PWRiL, Warszawa, 1965.
- [3] Pabis S.: *Teoria konwekcyjnego suszenia produktów rolniczych*, PWRiL, Warszawa, 1982.

MOISTURE TRANSPORT PROCESS IN WHEAT SEEDS MODELED WITH ARTIFICIAL NEURONS

SUMMARY

Usage of neural networks as an instrument for describe moisture transport process in wheat seeds, during unconventional method of drying has been presented in article. As an alternative method for conventional drying natural absorbent desiccation method has been used. As an natural absorbent this same species of seeds as dried, has been used.

Key words: natural absorbent, artificial absorbent, desiccation, artificial neural networks.