

*Tomasz Hebda, Sławomir Francik
Katedra Inżynierii Mechanicznej i Agrofizyki
Akademia Rolnicza w Krakowie*

WYKORZYSTANIE SSN DO WYZNACZANIA TWARDOŚCI ZIARNA PSZENICY

Streszczenie

W pracy opracowano modele wykorzystujące sztuczne sieci neuronowe do wyznaczenia twardości ziarna pszenicy (odmiany Mewa, Korweta, Sakwa, Symfonia, Zyta i Elena). Po przebadaniu 100 sieci wybrano jako model sieć typu perceptron trójwarstwowy. Jako dane wejściowe istotne okazały się: grubości i szerokości ziarna oraz zawartości białka. Wybrana sieć neuronowa zachowała zdolność generalizacji – średni błąd względny dla danych testujących (nie wykorzystywanych w procesie uczenia) były nieznacznie większy niż dla danych walidacyjnych.

Słowa kluczowe: sztuczne sieci neuronowe, ziarno, twardość, zawartość białka

Wstęp

Twardość uważana jest za jedną z ważniejszych cech fizycznych roślinnych materiałów ziarnistych. W Kanadzie, Australii, USA już na etapie klasyfikacji pszenicy uwzględnia się cechę twardości, czego wyrazem są nazwy handlowe np.: Hard Red Spring, Australian Prime Hard [Obuchowski i in. 1981]. W przypadku ziarna jest ona również najlepszym pośrednim wskaźnikiem wartości wypiekowej pszenicy. Jej związek z takimi cechami młynarskimi, jak łatwość prowadzenia przemiału, oraz piekarskimi, jak cechy reologiczne ciasta, umożliwia wczesne, wstępne określenie przydatności danej partii ziarna [Soszyńska, Cacek-Pietrzak 1992].

Jednym z ważniejszych czynników, który wpływa na twardość ziarna pszenicy jest białko występujące w bielmie. Uzyskane przez Obuchowskiego [1985] wyniki wskazują, że zawartość białka w bielmie pozostaje w istotnym związku z większością wyróżników twardości. Autor stwierdza, że substancja białkowa jest czynnikiem istotnie wpływającym na kształtowanie cech mechanicznych ziarna. Potwierdziły to

badania Symesa i Greenwaya [za Soszyńska 1992], jak również Lyonsa i Sheltona [1999].

Przeprowadzony przegląd literatury wykazał, że do chwili obecnej nie wypracowano żadnych standardów, norm czy sposobów pomiaru twardości ziarnistych materiałów roślinnych. Opracowano natomiast szereg metod, takich jak: WHI – (Wheat Hardnes Index) wskaźnik twardości pszenicy według Greenawaya, PSI – (Particle Size Index) - wskaźnika wielkości cząstki, PRI – (Pearling Resistance Index) - wskaźnik odporności na obłuskiwanie HI – (Hardnes Index) – indeks twardości, które są często zawodne i nie do końca spełniają swoje zadania [Hebda 2003]. Dodatkowe trudności wynikają także z braku jednoznacznie zdefiniowanych pojęć związanych z twardością materiałów biologicznych [Ślipek i in. 1999].

W związku z powyższym konieczne jest poszukiwanie tanich i szybkich metod wspierających procesy poznawcze. Jednym z możliwych rozwiązań jest stosowanie sztucznej inteligencji, a w szczególności komputerowych symulatorów sztucznych sieci neuronowych (SSN) [Mueller i in. 2003; Złobecki i Francik 2001, Łapczyńska-Kordon i Francik 2002]. Modele wykorzystujące sieci neuronowe są najczęściej dokładniejsze niż inne rodzaje stosowanych modeli empirycznych [Francik i Frączek 2001; Francik i in. 2005].

Cel pracy

Celem prezentowanej pracy było zastosowanie Sztucznych Sieci Neuronowych do wyznaczania twardości bielma ziarna pszenicy na podstawie wyników pomiarów wymiarów geometrycznych, masy i zawartości białka.

Metodyka

Do badań wykorzystano ziarno pszenicy odmian Mewa, Korweta, Sakwa, Symfonia, Zyta i Elena. Wilgotność ziarna wynosiła około 12% (powietrznie suche). Pomiary geometrii ziarna wykonano za pomocą elektronicznej suwmiarki firmy Limit - mierząc ich wymiary z dokładnością do 0,01 mm, mierzono je w trzech płaszczyznach rejestrując wartości długości, grubości i szerokości. Pomiar masy pojedynczych ziarniaków przeprowadzono przy wykorzystaniu wagi WPS 510/c/1, ważąc je z dokładnością do 0,001 grama. Zawartość białka w ziarnie pszenicy wykonano według metody Kjeldahla.

Do tworzenia modelu SSN (proces uczenia sieci) konieczna była znajomość rzeczywistej twardości ziarna. Pomiar twardości bielma pszenicy i obliczenie jej wartości wykonano według metody opracowanej przez Frączka i Hebdę [2003], przy

wykorzystaniu diamentowego węgelnika o kącie wierzchołkowym 120° i sile nacisku 200 gram. Badania wykonano na maszynie wytrzymałościowej firmy MTS.

Ostatecznie uzyskano 300 wzorców przeznaczonych do uczenia, weryfikacji i testowania sieci neuronowych. Dane te podzielono losowo na zbiory: uczący (150 wzorców), walidacyjny i testowy (po 75 wzorców).

Do wyznaczania twardości bielma pojedynczego ziarniaka zastosowano jednokierunkowe wielowarstwowe sieci neuronowe. Do tworzenia modeli neuronowych użyto programu Statistica Sieci Neuronowe. Testowano 100 różnych architektur SSN – różne typy sieci (Liniowe, wielowarstwowe Perceptrony i sieci RBF) o różnej liczbie warstw i neuronów. Opracowano 10 różnych modeli neuronowych, które poddano następnie weryfikacji w celu wybrania modelu najdokładniej opisującego twardość.

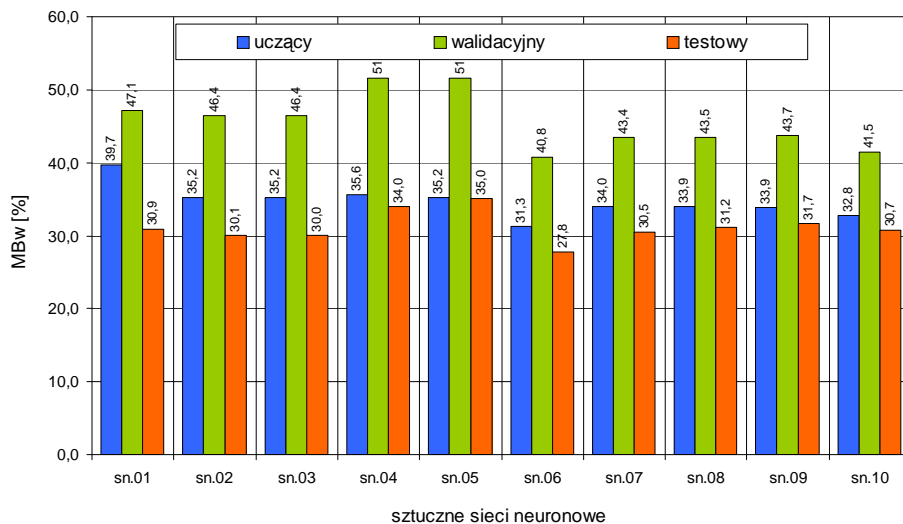
W celu określenia SSN pozwalających uzyskiwać najdokładniejsze prognozy obliczono miernik błędu względnego (MBw) [Ślipek i in. 2003]. Ostatecznego wyboru sieci neuronowej dokonano na podstawie sumy wartości miernika MBw dla danych walidacyjnych i uczących.

Wyniki badań

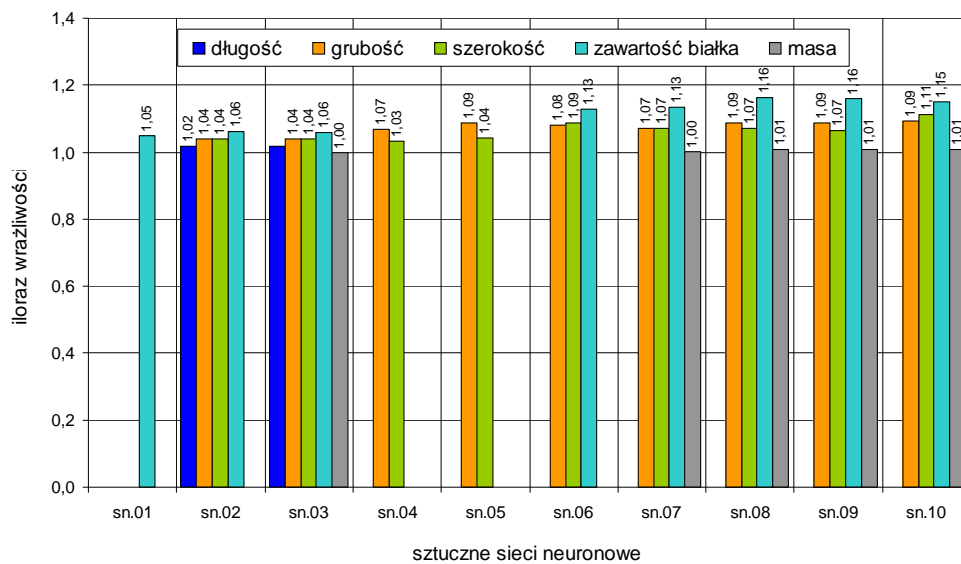
Na rysunku 1 zestawione zostały wartości miernika MBw dla danych uczących, walidacyjnych i testowych. Najmniejsze wartości miernika błędu MBw uzyskała sieć sn06 typu wielowarstwowy perceptron: 31,3% dla danych uczących, 40,8% dla danych walidacyjnych i 27,8% dla danych testujących. Drugą, pod względem dokładności, była sieć RBF sn10: MBw = 32,8% (dane testujące), MBw = 41,5% (dane walidacyjne) oraz MBw = 30,7% (dane testujące). Najlepszą siecią liniową była sn03, która uzyskała następujące wartości miernika MBw: 35,2% dla danych uczących, 46,4% dla danych walidacyjnych i 30,0% dla danych testowych. Niemal takie same wartości uzyskała sieć liniowa sn02.

Ostatecznie jako model wybrano sieć neuronową sn06 (wielowarstwowy perceptron).

Przeprowadzona analiza wrażliwości (rysunek 2) wykazała, że nie wszystkie przyjęte zmienne wejściowe mają wpływ na zmienną wyjściową, np. dla sieci neuronowych sn07, sn08, sn09 i sn10, nieistotna okazała się długość ziarna, a dla sieci sn04 i sn05 istotna okazała się tylko grubość i szerokość.

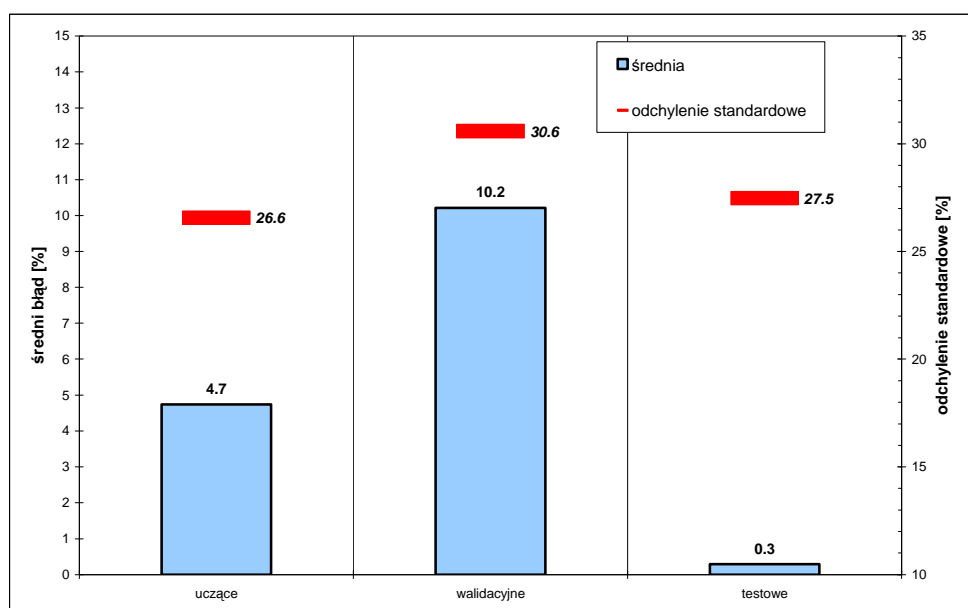


Rys. 1. Wartości miernika MBw dla sieci neuronowych
 Fig. 1. Values of the MBw standard for neural networks



Rys. 2. Wyniki analizy wrażliwości dla zmiennych wejściowych
 Fig. 2. Results of sensitivity analysis for input variables

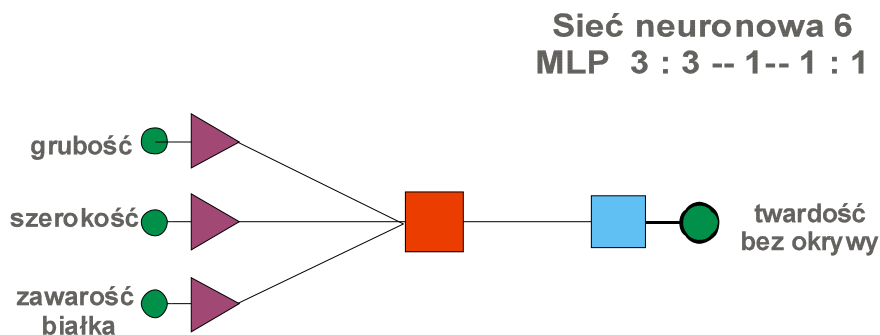
Na rysunku 3 przedstawiono wartości średniego błędu względnego i odchylenia standardowego tego błędu dla wybranego modelu neuronowego. Średni błąd zmienia się od 4,7% dla danych uczących do 10,2% dla danych walidacyjnych. W przypadku danych testowanych wartość błędu była niewielka i wyniosła zaledwie 0,3%. Natomiast wartość odchylenia standardowego była największa dla danych walidacyjnych i wyniosła 30,6%. Dla pozostałych była podobna i kształtowała się na poziomie 26,6 i 27,5%.



Rys. 3. Wartości średniego błędu względnego i odchylenia standardowego dla wybranego modelu neuronowego.

Fig. 3. Values of average relative error and standard deviation for selected neural model

Na rysunku 4 przedstawiono architekturę wybranego modelu neuronowego. Wybrany model to jednokierunkowa trójwarstwowa sieć neuronowa typu perceptron o trzech wejściach. Przeprowadzona analiza wrażliwości pozwoliła stwierdzić, że w celu wyznaczenia twardości ziarna wystarczy znajomość trzech zmiennych wejściowych: grubości i szerokości ziarna oraz zawartości białka. Wybrany model neuronowy ma trzy neurony wejściowe, jeden neuron w warstwie ukrytej i jeden neuron wyjściowy. Neurony w warstwie wejściowej miały liniową funkcję aktywacji, w warstwie ukrytej hiperboliczną funkcję aktywacji, a w warstwie wyjściowej logistyczną funkcję aktywacji.



Rys. 4. Architektura modelu neuronowego
Fig. 4. Neural model architecture

Wnioski

1. Opracowany model neuronowy (sn6) jest siecią jednokierunkową trzywarstwową typu perceptron o 1 neuronie w warstwie ukrytej.
2. Dla opracowanego modelu, jako zmienne wejściowe istotne okazały się: grubości i szerokości ziarna oraz zawartości białka.
3. Sieć neuronowe sn6 zachowała zdolność generalizacji.

Bibliografia

- Frączek J., Hebda T. 2003. Wpływ kąta wierzchołkowego końcówki penetratora na mierzoną twardość nasion fasoli. *Acta Agrophysica*, 82, 41-50.
- Hebda T. 2003. Ocena twardości i sprężystości ziarnistych materiałów roślinnych. Rozprawa doktorska, Kraków.
- Lyon D. J., Shelton D. R. 1999. Fallow management and nitrogen fertilizer influence winter wheat kernel hardness. *Crop Sci.*, 39, 448-452.
- Mueller W., Nowakowski K., Boniecki P. 2003. Sztuczne sieci neuronowe do predyspozycji pola temperatur w kamiennym magazynie energii cieplej. *Inżynieria Rolnicza*, nr 12 (54), 267-274.
- Obuchowski W., Gąsiorowski H., Kołodziejczyk P. 1981. Twardość ziarna pszenicy jako kryterium jego jakości. *Postępy Nauk Rolniczych*, 5/81, 97-107.

Obuchowski W. 1985. Twardość ziarna pszenicy: znaczenie technologiczne i czynniki wpływające na tę własność, Rocznik Akademii Rolniczej w Poznaniu str. 1-56.

Soszyńska M., Cacek-Pietrzak G. 1992. Mikrotwardość ziarna żyta, Przegląd Zbożowo - Młynarski nr 2 - 3 str. 7-8

Ślipek Z., Francik S., Frączek J. 2003. Metodyczne aspekty tworzenia modeli SSN w zagadnieniach agrofizycznych. Acta Agrophysica 2003, 2 (1), 231-241.

Francik S., Frączek J. 2001. Model development of the external friction of granular vegetable materials on the basis of artificial neural networks. Int. Agrophysics, 15,231-236.

Złobecki A., Francik S. 2001. Defining the damaging process of cereal grains on the basis of artificial neural network. Int. Agrophysics, 15, 219-223.

Łapczyńska-Kordon B., Francik S. 2002. Wykorzystanie sztucznych sieci neuronowych do wyznaczenia współczynnika dyfuzji masy. Inż. Rolnicza 9 (42), 163-168.

Ślipek Z., Francik S., Frączek J. 2003. Metodyczne aspekty tworzenia modeli SSN w zagadnieniach agrofizycznych. Acta Agrophysica, 95, 231-241.

Francik S., Frączek J., Ślipek Z. 2005. The use of artificial neural networks for cereal grain contact surface modelling. II International Scientific Conference: Information Technologies and Control Engineering in Management of Production Systems. Prague 20-22 September 2005, tome I, 52-59.

UTILIZATION OF ANN TO DETERMINE WHEAT GRAIN HARDNESS

Summary

The paper presents developed models using artificial neural networks (ANN) to determine wheat grain hardness (Mewa, Korweta, Sakwa, Symfonia, Zyta and Elena varieties). A three-layer perceptron-type network was selected as a model after having tested 100 networks. Grain thickness and width and protein content turned out to be important as input data. Selected neural network maintained its ability to generalize – average relative error for testing data (not being used in learning process) was slightly higher than for validation data.

Key words: artificial neural networks, grain, hardness, protein content