

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

MODEL TWARDOŚCI ZIARNIAKÓW PSZENICY WYKORZYSTUJĄCY SZTUCZNE SIECI NEURONOWE

Streszczenie

W pracy opracowano modele wykorzystujące sztuczne sieci neuronowe do wyznaczania twardości ziarna pszenicy (odmiany Mewa, Korweta, Sakwa, Symfonia, Zyta i Elena) na podstawie wymiarów geometrycznych, masy ziarniaka, grubości jego okrywy owocowo-nasiennej oraz odmiany. Po przebadaniu 150 sieci wybrano jako model sieć typu perceptron trójwarstwowy o siedmiu neuronach w warstwie ukrytej. Jako dane wejściowe istotne okazały się wszystkie przyjęte do badań zmienne.

Słowa kluczowe: sztuczne sieci neuronowe, ziarno, twardość, grubość okrywy owocowo-nasiennej

Wstęp

Jedną z ważniejszych właściwości fizycznych roślinnych materiałów ziarnistych jest twardość. W wielu krajach o wysokiej kulturze rolnictwa (np. Kanada czy USA) cecha ta jest uwzględniana już na etapie klasyfikacji pszenicy, czego wyrazem są nazwy handlowe np.: Hard Red Spring, Australian Prime Hard.

Twardość ziarna pszenicy jest również najlepszym wskaźnikiem przydatności technologicznej, służącym m. in. do oceny wartości wypiekowej [Soszyńska i Cacek-Pietrzak 1992].

W przemyśle zbożowo-młynarskim do oceny twardości opracowano wiele metod technologicznych jak np.: 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. Sposoby te są często zawodne i nie do końca spełniają swoje zadania [Hebda 2003]. Dodatkowo trzeba zaznaczyć, że pomiar twardości w wyżej wymienionych metodach odbywa się nie na pojedyn-

czych ziarnach ale w masie. Otrzymany wynik jest więc wypadkową twardości ziarniaków [Hebda i Francik 2006].

W celu zwiększenia dokładności oznaczania własności roślinnych materiałów ziarnistych opracowywane są różne modele. Jednym z wygodnych sposobów modelowania są Sztuczne Sieci Neuronowe, które umożliwiają odwzorowanie zależności o praktycznie dowolnym stopniu komplikacji [Ślipek i in. 2003; Francik i in. 2005].

Cel pracy

Celem prezentowanej pracy była próba zastosowania Sztucznych Sieci Neuronowych do wyznaczania twardości ziarna pszenicy na podstawie wyników pomiarów wymiarów geometrycznych, masy i grubości okrywy owocowo-nasiennej. Sformułowano model teoretyczny (1), który wykorzystano następnie do tworzenia modelu SSN.

$$HV_{PZ} = f(a, b, c, m_{PZ}, g_o) \quad (1)$$

gdzie:

- HV_{PZ} – twardość pojedynczego ziarniaka pszenicy [MPa],
- a – długość ziarniaka [m],
- b – szerokość ziarniaka [m],
- c – grubość ziarna [m],
- m_{PZ} – masa pojedynczego ziarniaka [kg],
- g_o – grubość okrywy owocowo-nasiennej [m].

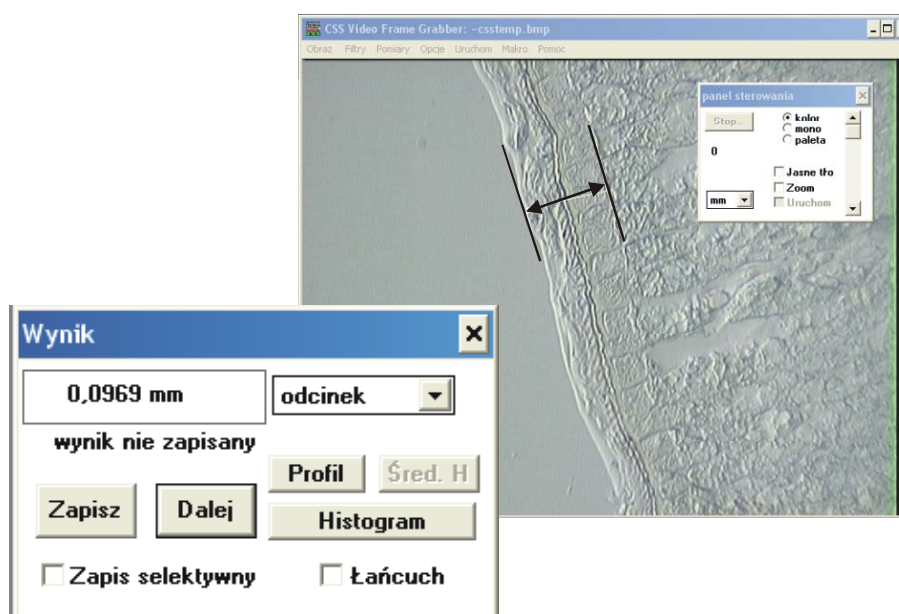
Metodyka

Do badań wykorzystano odmiany 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. Nasiona mierzono 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.

Przed przystąpieniem do pomiaru grubości okrywy owocowo-nasiennej nasion, przygotowano preparaty do analizy mikroskopowej. Polegała ona na zatapianiu materiału o żądanej zawartości wody w medium infiltracyjnym, które składało się z mieszaniny roztworu Technovit 7100 i ksylołu w proporcji 50 : 50. W dalszej kolejności ziarno umieszczano w kapsułkach żelatynowych i zalewano roztworem infiltracyjnym z dodatkiem utwardzacza. Tak przygotowane próbki można było przecinać przy użyciu mikrotomu saneczkowego ERGOSTAR HM 200.

Przygotowane preparaty z przekrojem poprzecznym ziarna mocowano nieruchomo na stoliku mikroskopu stereoskopowego HUND SM-33, na tubusie którego zamontowano aparat cyfrowy Canon. Po oświetleniu powierzchni próbki wiązką światła z oświetlacza światłowodowego dokonywano akwizycji obrazu.

W dalszej kolejności po wczytaniu, do programu Multi Scan, bitmapy z obrazem przekroju poprzecznego okrywy oraz makra ze zdefiniowaną skalą, wykonywano pomiar jej grubości. Wynik obliczenia wyświetlany był automatycznie w oknie dialogowym programu (rys. 1).



Rys. 1. Widok ekranu komputera z programem Multi Scan

Fig. 1. Screenshot of Multi Scan program

Dla zagwarantowania powtarzalności uzyskanych wyników pomiaru wykonane były zawsze w tej samej części nasienia. Do tworzenia modelu SSN (proces uczenia sieci) konieczna była znajomość rzeczywistej twardości ziarna. Pomiar twardości ziarna pszenicy i obliczenie jej wartości wykonano według metody opracowanej przez Frączka i Hebdę [2003], przy wykorzystaniu diamentowego wgłębnika o kącie wierzchołkowym 120° i sile nacisku 200 gram. Badania wykonano na maszynie wytrzymałościowej firmy MTS.

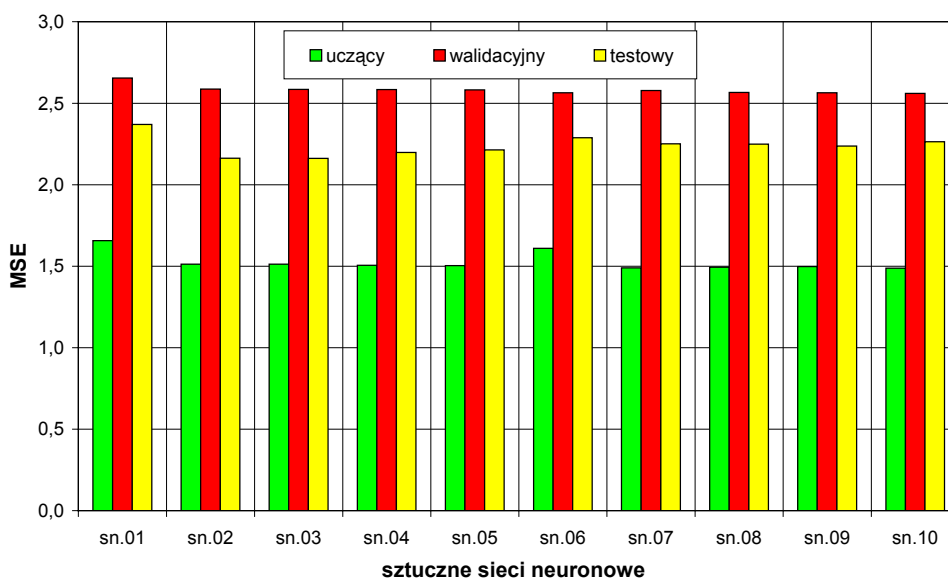
Jako model służący do wyznaczania twardości pojedynczego ziarniaka zastosowano jednokierunkowe wielowarstwowe sieci neuronowe. Opracowano kilka różnych

sieci neuronowych, które poddano następnie weryfikacji w celu wybrania modelu najdokładniej opisującego twardość.

Ostatecznie uzyskano 299 wzorców przeznaczonych do uczenia, weryfikacji i testowania sieci neuronowych. Dane te podzielono losowo na zbiory: uczący (151 wzorców), walidacyjny i testowy (po 74 wzorców). Do tworzenia modeli neuronowych użyto programu Statistica Sieci Neuronowe. Testowano 100 różnych sieci zachowując 10 najlepszych modeli. W celu określenia modeli pozwalających uzyskać najdokładniejsze prognozy obliczono błąd średniokwadratowy (MSE). Ostatecznego wyboru sieci neuronowej dokonano na podstawie wartości MSE dla danych walidacyjnych. W przypadku równych wartości uwzględniono MSE dla danych uczących. Obliczono globalny względny błąd aproksymacji [Trajer, Czekański 2005] dla zbioru testowego.

Wyniki badań

Na rysunku 2 zestawione zostały wartości błędu średniokwadratowego dla 10 najlepszych modeli neuronowych, które uzyskały najmniejsze wartości MSE dla zbioru walidacyjnego. Wśród tych modeli najdokładniejsze były sieci sn.06, sn.09 i sn.10 (dla danych walidacyjnych $MSE = 2,56$). Dla zbioru uczącego najmniejszą wartość $MSE = 1,49$ uzyskała sieć sn.10 – sieć tę wybrano jako model do wyznaczania twardości.



Rys. 2. Wartości błędu MSE dla wybranych sieci neuronowych

Fig. 2. MSE error values for selected neural networks


W tabeli 1 przedstawiono architekturę sztucznych sieci neuronowych. W przypadku dwóch sieci (sn.4 i sn.5) w warstwie wejściowej znalazły się po dwa neurony, w warstwie ukrytej i wyjściowej po jednym. Dodatkowo sn.5 posiada jeden neuron w drugiej warstwie ukrytej. Najbardziej rozbudowane sieci to sn.7, sn.8, sn.9 i sn.10, które mają po siedem neuronów w warstwie ukrytej.

Tabela 1. Architektura sieci
Table 1. Network architecture

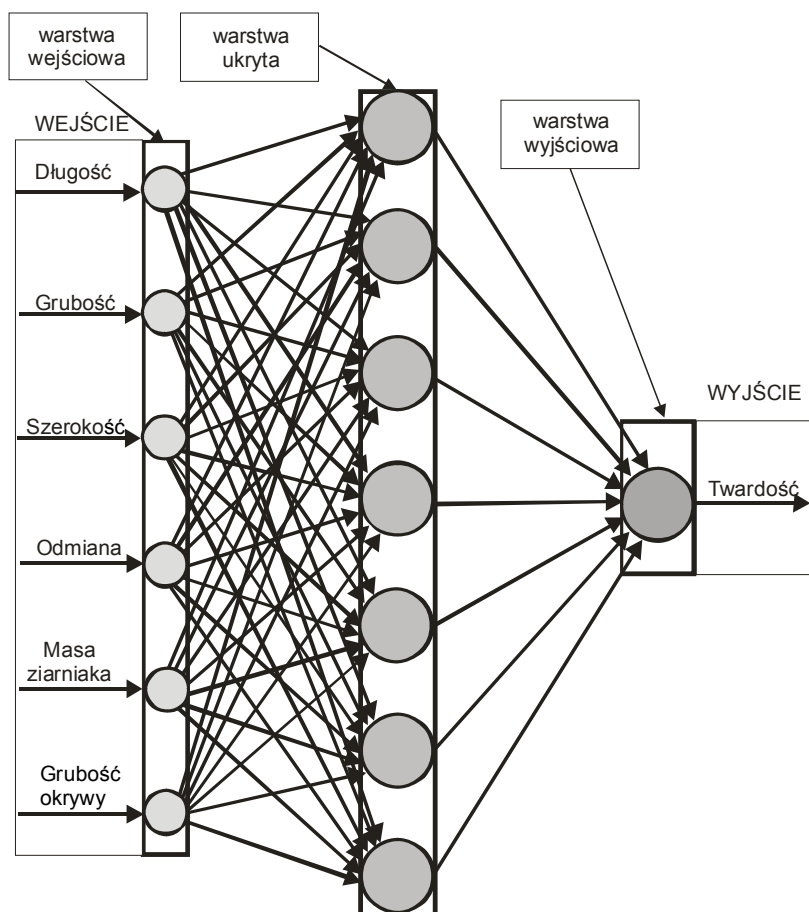
SSN	Typ sieci	Wejść	Ukryta(1)	Ukryta(2)
sn.01	Liniowa	1	0	0
sn.02	Liniowa	2	0	0
sn.03	Liniowa	3	0	0
sn.04	MLP	2	1	0
sn.05	MLP	2	1	1
sn.06	MLP	2	3	0
sn.07	RBF	3	7	0
sn.08	RBF	4	7	0
sn.09	RBF	5	7	0
sn.10	RBF	6	7	0

Przeprowadzona analiza wrażliwości wykazała, że dla wybranego modelu neuronowego (sieci sn.10) wszystkie przyjęte zmienne wejściowe (długość, szerokość i grubość ziarna, jego masa, grubość okrywy owocowo-nasiennej i odmiana) mają wpływ na zmienną wyjściową. Najistotniejsza okazała się odmiana pszenicy. W przypadku pozostałych modeli usunięcie niektórych zmiennych zwiększało dokładność działania sieci. Również dla tych modeli neuronowych najważniejszą zmienną była odmiana (za wyjątkiem sn.01).

Na rysunku 4 przedstawiono architekturę sieci sn.10. Wybrany model to jednokierunkowa sieć neuronowa o radialnych funkcjach bazowych (RBF), o sześciu wejściach, sześciu neuronach wejściowych, siedmiu neuronach w warstwie ukrytej i jednym neuronie wyjściowym. Dla używanego zbioru danych uczących sieć ta jest trochę przewymiarowana [Osowski 1996] i w dalszych badaniach rozmiar sieci będzie redukowany.



Rys. 3. Wartości ilorazu wrażliwości dla najlepszych sieci neuronowych
 Fig. 3. Sensitiveness quotient values for the best neural networks



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

Wnioski

1. Opracowany model neuronowy (sn.10) to sieć o radialnych funkcjach bazowych (RBF), posiadająca siedem neuronów w warstwie ukrytej. Sieć ta uzyskała wartość globalnego błędu względnego 26,7% (dla danych testowych).
2. Jako dane wejściowe istotne okazały się: wszystkie wymiary ziarna (długość, grubości i szerokości), grubość okrywy owocowo-nasiennej i odmiana.
3. Różnice wartości błędu średniokwadratowego dla wybranych 10 modeli neuronowych są nieznaczne, pomimo różnej architektury tych sieci.

Bibliografia

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.

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.

Hebda T., Francik S. 2006. Wykorzystanie SSN do wyznaczania twardości ziarna pszenicy. *Inżynieria Rolnicza – praca oddana do druku*.

Osowski S. 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT.

Soszyńska M., Cacek-Pietrzak G. 1992. Twardość ziarna pszenicy jako kryterium jego jakości. *Przegląd Zbożowo-Młynarki*, nr 2, 7-8.

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

Trajer J., Czekalski D. 2005. Prognozowanie sum napromieniowania słonecznego dla potrzeb energetyki słonecznej. *Inżynieria Rolnicza*, 8 (68), 393-399.

HARDNESS MODEL FOR WHEAT CARYOPSISES USING ARTIFICIAL NEURAL NETWORKS

Summary

The work presents models using Artificial Neural Networks for setting out hardness of wheat grain (variation Mewa, Korweta, Sakwa, Symfonia, Zyta and Elena) based on geometric dimensions, caryopsis weight, thickness of its fruit and seed coat and variation. After examining 150 networks as a model perceptron tri-layer type network with seven neurons in hidden layer was selected. As input data all the variables taken for tests turned out to be relevant.

Key words: Artificial Neural Networks, grain, hardness, thickness of fruit and seed coat