

## MODEL SSN DO WYZNACZANIA SIŁY NISZCZĄCEJ SKORUPĘ ORZECHA WŁOSKIEGO

Tomasz Hebda, Sławomir Francik

*Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy w Krakowie*

**Streszczenie.** Materiał badawczy stanowiły cztery odmiany orzecha włoskiego (*Juglans regia* L.): Silesia, Targo, Albi i Tryumf. Do tworzenia modelu sztucznych sieci neuronowych (SSN) niezbędna była znajomość rzeczywistej wartości siły niszczącej skorupę orzecha (endokarp). Badania wykonano na maszynie wytrzymałościowej Insight 2 firmy MTS. Jako model służący do wyznaczania siły potrzebnej do rozkruszenia okrywy orzecha włoskiego zastosowano jednodokierunkowe wielowarstwowe sieci neuronowe. Opracowano kilka różnych sieci neuronowych, które poddano następnie weryfikacji w celu wybrania modelu najdokładniej opisującego zależność siły niszczącej skorupę orzecha włoskiego od jego cech morfologicznych.

**Słowa kluczowe:** orzech włoski, SSN, model

### Wstęp

Wszystkie surowce pochodzenia roślinnego wykorzystywane w przemyśle rolno-spożywczym podlegają procesom rozdrabniania, zaś rozdrabnianie surowców zawierających komórki kamienne jak w przypadku skorupy orzecha włoskiego wymagają dodatkowej energii.

Optymalizacja tego procesu jest bardzo trudna ponieważ zależy od wielu czynników. Z jednej strony są to właściwości fizyczne i biologiczne tych materiałów, z drugiej konstrukcja i rodzaj zastosowanego urządzenia [Laskowski i in. 1998; Licznar 2005; Marks i in. 2006; Napiórkowski, Mikołajczak 2006].

Dla efektywnego wykorzystania elementów roboczych maszyn do rozdrabniania tego typu surowców konieczna jest znajomość przebiegu procesów rozdrabniania zarówno w funkcji czasu jak i obrabianych powierzchni. Jedną z skutecznych metod poznania wyżej wymienionych zależności jest zastosowanie modelowania matematycznego. Aktualnie, dotychczasowy stan wiedzy nie daje jednoznacznej odpowiedzi w kwestii procesów rozdrabniania takich surowców.

W związku z powyższym konieczne jest poszukiwanie tanich i szybkich metod wspierających procesy analizy optymalnych sposobów oceny odporności skorupy orzecha na rozdrabnianie (naruszenie naturalnej ciągłości jej tkanki). Jednym z możliwych rozwiązań jest zastosowanie sztucznej inteligencji, a w szczególności Sztucznych Sieci Neuronowych (SSN) [Mueller i in. 2003; Hebda, Francik 2006; Wróbel i in. 2005].

Umożliwiają one modelowanie dowolnie złożonych i nieliniowych odwzorowań, będąc przy tym bardzo wygodnym narzędziem analitycznym. Posiadają ponadto zdolność do

samo programowania się w procesie uczenia [Cholewa, Moczulski 2004]. Zastosowanie do modelowania sieci neuronowe daje szybsze i dokładniejsze efekty niż wykorzystanie modeli empirycznych [Francik, Frączek 2001; Khazaei, Daneshmandi 2007; Licznar 2005].

## Cel pracy

Celem prezentowanej pracy była próba zastosowania SSN do wyznaczania siły niszczącej łupinę orzecha włoskiego na podstawie wyników pomiarów cech geometrycznych orzecha, masy i grubości łupiny.

W pracy uwzględniono również sposób ułożenia orzecha podczas testu ściskania. Pomiaru zostały wykonane dla trzech sposobów ułożenia orzecha (rys. 1):

I – pionowo po szwie, II – prostopadle do szwu, III – poziomo po szwie.



Rys.1. Sposób ułożenia orzecha w trakcie badań wytrzymałościowych  
Fig. 1. Positioning of the walnut during strength tests

Sformułowano następujący model semantyczny:

$$Fn = f(a, b, c, mp, l, z) \quad (1)$$

gdzie:

- $Fn$  – siła niszcząca łupinę orzecha [N],
- $a$  – długość orzecha [m],
- $b$  – szerokość orzecha [m],
- $c$  – grubość orzecha [m],
- $mp$  – masa orzecha [kg],
- $l$  – grubość łupiny orzecha [m],
- $z$  – sposób ułożenia orzecha w czasie zgniatania.

Model ten wykorzystano następnie do tworzenia modelu SSN.

## Metodyka badań

Dane potrzebne dla zrealizowania celu pracy pozyskano z wcześniejszych badań autorów opublikowanych w Inżynierii Rolniczej [Hebda, Francik 2008]. Poniżej przedstawiono jedynie krótką metodykę wykonania tych badań.

Materiał badawczy stanowiły cztery odmiany orzechów włoskich: Silesia, Targo, Albi i Tryumf. Pomiaru cech geometrycznych orzechów, jak również grubość łupiny zostały wykonane przy pomocy elektronicznej suwmiarki firmy LIMIT. Wymiary orzechów były

mierzone w trzech płaszczyznach (rys. 1). Masę pojedynczych orzechów wyznaczono za pomocą wagi WPE -300S.

Doraźną odporność na ściskanie łupiny owoców, badano do momentu jej pęknięcia z zachowaniem ciągłości naturalnej tkanek jądra. Testy wytrzymałościowe wykonano używając uniwersalnej maszyny wytrzymałościowej Insight 2 firmy MTS.

Z pomiarów uzyskano 84 wzorce (4 odmiany \* 3 sposoby ułożenia orzecha \* 7 powtórzeń) przeznaczone do uczenia, weryfikacji i testowania sieci neuronowych. Wzorce te podzielono losowo na zbiory uczący (60 wzorców), walidacyjny i testowy (po 12 wzorców), przy czym dla każdej odmiany i każdego sposobu ułożenia orzecha losowanie przeprowadzano niezależnie (podział wzorców: 5 uczących - 1 walidacyjny - 1 testowy).

Jako model służący do wyznaczania siły niszczącej łupinę orzecha zastosowano jednokierunkowe wielowarstwowe sieci neuronowe. Do tworzenia modeli neuronowych użyto programu Statistica Sieci Neuronowe.

Do celów modelowania neuronowego, zgodnie z modelem semantycznym, przyjęto następujące oznaczenia sześciu zmiennych niezależnych (wejściowych dla sieci) i jednej zmiennej zależnej (wyjściowej):

wejście:

X1\_ – masa [g];

X2\_ – długość [mm];

X3\_ – szerokość [mm];

X4\_ – grubość [mm];

X5\_ – średnia grubość okrywy [mm];

X6\_ – sposób ułożenia orzecha (zmienna skategoryzowana).

wyjście:

Y1\_ – siła niszcząca [N].

Testowano 100 różnych sieci neuronowych typu: trójwarstwowy perceptron (MLP3), sieci o radialnych funkcjach bazowych (RBF) oraz sieci liniowe (LIN). Ograniczono liczbę neuronów w warstwie ukrytej dla sieci MLP3 do 6 neuronów, a dla sieci RBF do 21 neuronów. Ostatecznie zachowano 10 najlepszych modeli: 5 sieci typu RBF, 4 sieci typu MLP3 i 1 sieć liniową.

W celu sprawdzenia czy uwzględnienie wszystkich zmiennych wejściowych (niezależnych) wpływa na poprawę dokładności działania modelu neuronowego, przeprowadzona została analiza „wrażliwości”. Analiza ta pozwala ocenić użyteczność poszczególnych zmiennych wejściowych. Wskazuje, które zmienne są ważne dla jakości działania modelu i ich brak powoduje wzrost błędów wyznaczania wartości zmiennej wyjściowej. Obliczony został iloraz błędu uzyskiwanego przy uruchamianiu sieci neuronowej dla zbioru danych bez jednej zmiennej i błędu uzyskiwanego z zastosowaniem wszystkich zmiennych. Jego wartość wskazuje jak bardzo sieć jest wrażliwa na brak danej zmiennej wejściowej.

Następnie wybrano sieć neuronową najdokładniej opisującą zależność siły niszczącej łupinę orzecha od przyjętych w modelu semantycznym zmiennych niezależnych. Jako kryterium wyboru modelu neuronowego przyjęto wartość błędu średniokwadratowego ( $E_{RMS}$ ) dla zbioru walidacyjnego. Wartość tego błędu została obliczona według wzoru:

$$E_{RMS} = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (Y_{SSN,i} - Y_{R,i})^2}$$

gdzie:

- $Y_{R,i}$  – wartość rzeczywista zmiennej wyjściowej,
- $Y_{SSN,i}$  – wartość obliczona przez SSN zmiennej wyjściowej,
- $n$  – liczba przypadków (wzorców).

## Wyniki

W tabeli 1 zamieszczono 10 najlepszych (najdokładniejszych) modeli neuronowych opracowanych przy wykorzystaniu Automatycznego Projektanta programu Statistica Sieci Neuronowe. Są to: 1 sieć liniowa, 4 sieci MLP3 i 5 sieci RBF. Wszystkie te sieci neuronowe mają 6 zmiennych wejściowych i 1 zmienną wyjściową, oraz 8 neuronów wejściowych (3 neurony dla skategoryzowanej zmiennej X6). Liczba neuronów w warstwie ukrytej zmieniała się dla MLP3 od 1 do 6 neuronów, a dla RBF od 4 do 9 neuronów.


Tabela 1. Architektura opracowanych modeli neuronowych  
Table 1. Architecture of elaborated neural models

Model	Typ sieci neuronowej	Liczba neuronów wejściowych	Liczba neuronów ukrytych	Liczba neuronów wyjściowych
sn01	Liniowa 6:8-1:1	8	0	1
sn02	MLP 6:8-1-1:1	8	1	1
sn03	MLP 6:8-2-1:1	8	2	1
sn04	MLP 6:8-3-1:1	8	3	1
sn05	MLP 6:8-6-1:1	8	6	1
sn06	RBF 6:8-4-1:1	8	4	1
sn07	RBF 6:8-8-1:1	8	8	1
sn08	RBF 6:8-9-1:1	8	9	1
sn09	RBF 6:8-9-1:1	8	9	1
sn10	RBF 6:8-9-1:1	8	9	1

*Źródło: obliczenia własne autorów*

Na rysunku 2 pokazano wartości błędu średniokwadratowego  $E_{MRS}$  dla zbioru walidacyjnego. Najdokładniej wartości zmiennej wyjściowej (siły niszczącej okrywę orzecha) obliczała sieć neuronowa sn05, dla której wartość  $E_{MRS} = 79$  N.

W tabeli 2 zamieszczono wyniki analizy wrażliwości. Wartości ilorazu błędu wskazują, że wszystkie zmienne niezależne uwzględnione w modelu semantycznym są istotne dla działania modeli neuronowych (wartości ilorazu błędu  $\geq 1$ ). Najważniejszą zmienną jest X6 (sposób ułożenia orzecha).



Rys. 2. Wartości błędu średniokwadratowego  $E_{RMS}$  dla zbioru walidacyjnego  
 Fig. 2. Values of the mean square error  $E_{RMS}$  for the validation set

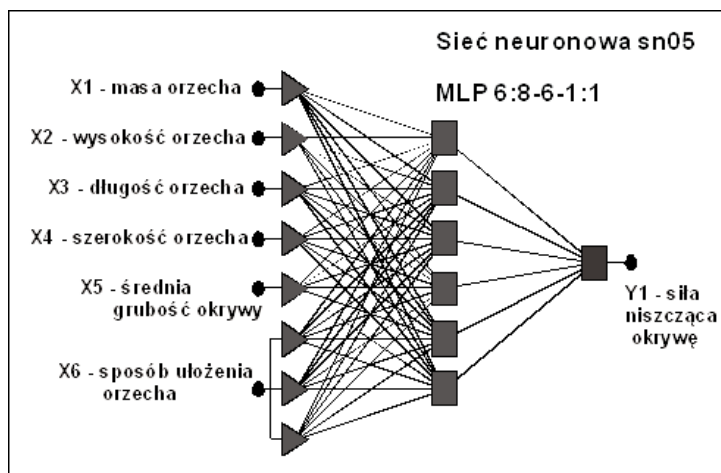
Tabela 2. Analiza wrażliwości (iloraz błędu) dla opracowanych modeli neuronowych  
 Table 2. Analysis of sensitivity (error quotient) for elaborated neural models

Model	$X1$	$X2$	$X3$	$X4$	$X5$	$X6$
sn01	1,01	1,10	1,02	1,19	1,34	1,60
sn02	1,00	1,03	1,01	1,01	1,34	1,61
sn03	1,01	1,13	1,72	1,32	1,78	2,05
sn04	1,01	1,33	1,60	1,10	1,77	1,94
sn05	1,02	1,02	1,01	1,08	1,25	1,50
sn06	1,00	1,02	1,01	1,00	1,04	1,42
sn07	1,00	1,01	1,00	1,00	1,30	1,58
sn08	1,01	1,01	1,00	1,00	1,40	1,67
sn09	1,00	1,01	1,01	1,00	1,10	1,41
sn10	1,01	1,03	1,02	1,03	1,51	2,09

Źródło: obliczenia własne autorów

Na rysunku 3 przedstawiono architekturę wybranego modelu neuronowego.

Jest to jednokierunkowa trójwarstwowa sieć neuronowa typu perceptron o sześciu wejściach. Wybrany model neuron wyjściowy. Neurony w warstwie wejściowej miały liniową funkcję aktywacji, w warstwie neuronowej ma osiem neuronów wejściowych, sześć neuronów w warstwie ukrytej i jeden ukrytej hiperboliczną funkcję aktywacji, a w warstwie wyjściowej logistyczną funkcję aktywacji.




Rys. 3. Sieć neuronowa sn05  
Fig. 3. Neural network sn05

Błąd średniokwadratowy dla zbioru uczącego ( $E_{RMS} = 136$  N) i testowego ( $E_{RMS} = 114$  N) był większy niż dla zbioru walidacyjnego. Dlatego też przeprowadzony został proces dalszego uczenia wybranego modelu neuronowego sn05. Wykres zmian błędów dla danych uczących i walidacyjnych podczas uczenia został pokazany na rysunku 4.

Zmodyfikowana w procesie ponownego uczenia sieć neuronowa uzyskała zmniejszenie wartości błędu dla zbioru uczącego ( $E_{RMS} = 73$  N), natomiast zwiększył się błąd dla zbioru walidacyjnego ( $E_{RMS} = 114$  N). Błąd dla zbioru testowego nie uległ zasadniczej zmianie ( $E_{RMS} = 113$  N). Dla sztucznej sieci neuronowej sn05 po douczeniu zwiększyły się wartości ilorazu błędu dla wszystkich zmiennych wejściowych (tab. 3). Największy wpływ na dokładność działania modelu miały kolejno zmienne: X3 (szerokość orzecha), X6 (sposób ułożenia orzecha), X5 (średnia grubość okrywy).

Na rysunkach 5, 6 i 7 pokazano jak sztuczna sieć neuronowa sn05 wyznacza wartości siły niszczącej okrywę orzecha, dla wzorców walidacyjnych i testowych. Dla I sposobu ułożenia orzecha, można zauważyć, że zmierzone dla poszczególnych odmian wartości siły różnią się znacznie bardziej niż wyznaczone za pomocą modelu neuronowego. Sztuczna sieć neuronowa w pewien sposób uśrednia wartości siły. Podobne zjawisko, można również zaobserwować dla III sposobu ułożenia. Natomiast przy II sposobie ułożenia zjawisko to występuje jedynie dla Tago i Tryumf.

Porównując wartości siły, zmierzone i obliczone za pomocą sieci neuronowej sn05, można stwierdzić, że większe różnice występują dla przypadków należących do zbioru testowego, niż dla przypadków ze zbioru walidacyjnego. Wynika to z faktu, że zbiór testowy nie był wykorzystywany w procesie uczenia.

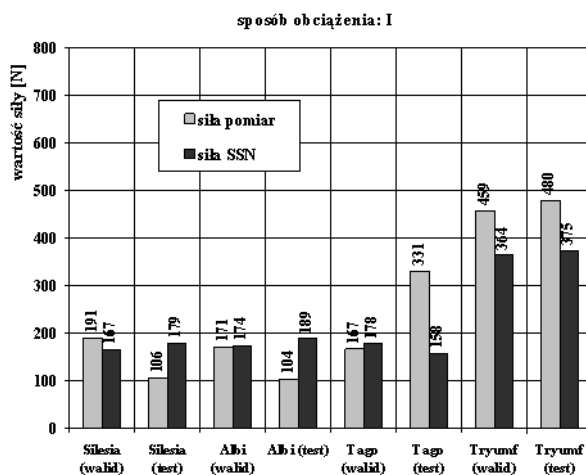


Rys. 4. Zmiana błędu podczas procesu uczenia sieci neuronowej sn05  
 Fig. 4. Change of error during the sn05 neural network learning process

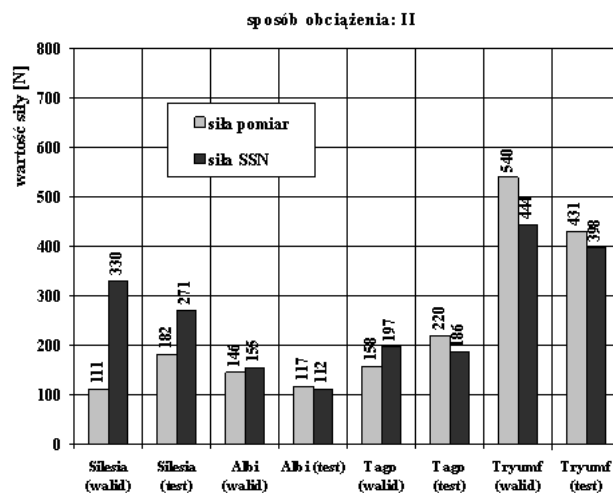
Tabela 3. Analiza wrażliwości (iloraz błędu) dla sn05 po douczeniu  
 Table 3. Analysis of sensitivity (error quotient) for sn05 after supplementary learning

SSN	X1	X2	X3	X4	X5	X6
sn05	1,35	1,42	2,75	1,53	1,87	2,51

Źródło: obliczenia własne autorów



Rys. 5. Porównanie siły niszczącej wyznaczonej za pomocą sieci neuronowej sn05 i uzyskanej z pomiaru dla I sposobu ułożenia orzecha (zbiór walidacyjny i testowy)  
 Fig. 5. Comparison of the destructive force determined by means of the neural network sn05 and obtained for the 1<sup>st</sup> walnut positioning method (validation and test set)



Rys. 7. Porównanie siły niszczącej wyznaczonej za pomocą sieci neuronowej sn05 i uzyskanej z pomiaru dla II sposobu ułożenia orzecha (zbiór walidacyjny i testowy)

Fig. 7. Comparison of the destructive force determined by means of the neural network sn05 and obtained for the 2<sup>nd</sup> walnut positioning method (validation and test set)

## Wnioski

1. Opracowany model neuronowy sn05 jest typową siecią jednokierunkową – trzywarstwowym perceptronem o 6 neuronach w warstwie ukrytej.
2. Wszystkie zmienne wejściowe (masa orzecha, jego wymiary, grubość łupiny oraz sposób ułożenia w czasie ściskania) okazały się istotne dla dokładności działania opracowanego modelu neuronowego.
3. Aby zwiększyć dokładność działania modelu SSN, konieczne jest powtórzenie badań z uwzględnieniem większej ilości danych, a także uwzględnienie dodatkowych zmiennych wejściowych jak np. wilgotność okrywy.

## Bibliografia

- Cholewa W., Moczulski W.** 2004. Elementy sztucznej inteligencji w diagnostyce technicznej. Inżynieria Diagnostyki Maszyn. PTDT Radom.
- Francik S., Frączek J.** 2001. Model development of the external friction of granular vegetable materials on the basis of artificial neural networks. International-Agrophysics. 15. s. 231-236.
- Hebda T., Francik S.** 2006. Wykorzystanie SSN do wyznaczania twardości ziarna pszenicy. Inżynieria Rolnicza. Nr 12(87). s. 181-188.
- Hebda T., Francik S.** 2008. Analiza siły niszczącej okrywę orzecha włoskiego. Inżynieria Rolnicza. Nr 11(109). s. 83-89.



- Khazaei J., Daneshmandi S.** 2007. Modeling of thin-layer drying kinetics of sesame seeds: mathematical and neural networks modeling. *International Agrophysics*. 21. s. 335-348.
- Laskowski J., Łojewska H., Lysiak G.** 2001. Zastosowanie równania Walkera do oceny energochłonności rozdrabniania ziarna zbóż w rozdrabniaczu bijakowym. *Inżynieria Rolnicza*. Nr 2(22). s. 179-185.
- Laskowski J., Lysiak G., Melcion J.P.** 1998. Cereal grains resistance analysis in the aspect of energy utilization in the process of disintegration. *International Agrophysics*, 12 (3). s. 205-208.
- Licznar P.** 2005. Ocena możliwości stosowania sztucznych sieci neuronowych dla określania średniej rocznej wartości wskaźnika erozyjności deszczy. *Acta Agrophysica* 5(1). s. 65-74.
- Marks N., Sobol Z., Baran D.** 2006. Wpływ wilgotności na energochłonność procesu rozdrabniania ziarna zbóż. *Inżynieria Rolnicza*. Nr 3(78). s. 281-288.
- Mueller W., Nowakowski K., Boniecki P.** 2003. Sztuczne sieci neuronowe do predyspozycji pola temperatur w kamiennym magazynie energii cieplnej. *Inżynieria Rolnicza*. Nr 12(54). s. 267-274.
- Napiórkowski J., Mikołajczak P.** 2006. Modele neuronowe zużycia elementów roboczych w glebie. *Inżynieria Rolnicza*. Nr 12(87). s. 381-389.
- Wróbel M., Czarnik-Matusewicz H., Siuda R.** 2005. Artificial neural networks in compositional analysis of repeseed meal from nirs – assessment of applicability. *Acta Agrophysica* 6(1). s. 261-272.

## **SSN MODEL FOR DETERMINATION OF THE FORCE DESTROYING THE WALNUT COVER**

**Abstract.** Tests were performed with the use of the following varieties: Silesia, Targo, Albi and Tryumf. For the creation of the SSN model (network learning process), the knowledge of the actual value of the force destroying the walnut cover was necessary. Tests were performed on the testing machine Insight 2 of MTS company. Unidirectional multi-layer neural networks were used as a model aimed at determining the force necessary to crush the walnut cover. Several different neural networks were elaborated and then verified for the purpose of selecting a model that would describe most accurately the dependence of the destructive force on the morphological characteristics of the walnut.

**Key words:** walnut, SSN, model

**Adres do korespondencji:**

Tomasz Hebda; e-mail: Tomasz.Hebda@ur.krakow.pl  
Katedra Inżynierii Mechanicznej i Agrofizyki  
Uniwersytet Rolniczy w Krakowie  
ul. Balicka 120  
30-149 Kraków