

*Bogusława Łapczyńska-Kordon, Sławomir Francik,  
Jarosław Frączek, Zbigniew Ślipek  
Katedra Inżynierii Mechanicznej i Agrofizyki  
Akademia Rolnicza w Krakowie*

## **MODELOWANIE SKURCZU SUSZARNICZEGO WYBRANYCH WARZYW KORZENIOWYCH ZA POMOCĄ SIECI NEURONOWYCH**

### **Streszczenie**

W pracy przedstawiano próbę zastosowania modelu sformułowanego z pomocą sztucznych sieci neuronowych do opisu zmian skurczu suszarniczego próbek buraka ćwikłowego, podczas konwekcyjnego suszenia, w zależności od zawartości wody, temperatury materiału i wielkości powierzchni. Na podstawie analizy różnych architektur sieci, wybrano do opisu trójwarstwową sieć z trzema wejściami (trzy neurony w pierwszej warstwie ukrytej, jeden neuron w drugiej warstwie ukrytej i jeden neuron na wyjściu – jedna zmienna wyjściowa) ze względu na najmniejsze mierniki błędów. Stwierdzono, że model ma cechy uniwersalności, gdyż pozwala na jednoczesną analizę zmian skurczu w zależności od trzech wielkości: zawartości wody, temperatury i powierzchni przekroju poprzecznego próbki.

**Słowa kluczowe:** skurcz, model SSN, burak ćwikłowy

### **Wykaz oznaczeń**

$V(\tau)$  – objętość chwilowa, [m<sup>3</sup>],  
 $V_0$  – objętość początkowa, [m<sup>3</sup>].

### **Wstęp**

Warzywa podczas suszenia, pod wpływem zmian temperatury i zawartości wody, zmieniają swoje wymiary, powierzchnię oraz objętość w wyniku skurczu suszonej próbki, zwanego skurczem suszarniczym. Skurcz liniowy lub objętościowy traktowany jest jako jedna z fizycznych właściwości i uwzględniany w matematycznych modelach kinetyki suszenia. Proces suszenia warzyw dzieli się na okres z dominującą

powierzchniowa wymianą masy i na okres dyfuzyjnego transportu masy z wnętrza materiału do powierzchni. Najbardziej kurczy się materiał w okresie powierzchniowej wymiany masy i dlatego w matematycznych modelach tego okresu uwzględniony jest objętościowy skurcz suszarniczy [Pabis 1999]. Ze względu na anizotropowość materiałów roślinnych, sformułowano model pierwszego okresu suszenia, wprowadzając do matematycznego opisu skurcze liniowe próbek wzdłuż poszczególnych wymiarów [Pabis, Jaros 2002]. Z przeprowadzonych badań wynika, że skurcz zależy od zawartości wody, temperatury, składu chemicznego itp., a parametry te zmieniają się w czasie suszenia [Karathanos i in. 1993; Nowak i in. 1994; Wang, Brennan 1995]. Dotychczas zmiany skurczu suszarniczego opisywano jedynie modelami empirycznymi w formie funkcji algebraicznych w zależności od zawartości wody [Lozano i in. 1983; Suzuki i in. 1976; Markowski 1994; Łapczyńska-Kordon 2003]. Brak jest modeli określających zmiany skurczu od kilku parametrów niezależnych równocześnie. Taką możliwość daje wykorzystanie sztucznych sieci neuronowych, które w ostatnich latach coraz częściej są stosowane w modelowaniu zagadnień suszarniczych. Istnieją modele sformułowane w oparciu o SSN określające zmiany parametrów i właściwości warzyw i owoców podczas suszenia [Łapczyńska-Kordon, Francik 2001].

Dlatego w pracy podjęto próbę opracowania modelu w oparciu o sztuczne sieci neuronowe (SSN), do opisu zmian objętościowego skurczu suszarniczego buraka ćwikłowego w zależności od zmian zawartości wody, temperatury powierzchni materiału suszonego i powierzchni jego przekroju poprzecznego.

### Metodyka badań

Do opracowania modelu posłużyły wyniki badań skurczu suszarniczego, podczas konwekcyjnego suszenia buraka ćwikłowego w temperaturach 50°C i 70°C. Podczas suszenia próbek w kształcie sześcianów o wymiarach 10x10x10 [mm] mierzono co 10 min. objętość oraz powierzchnię przekroju poprzecznego próbek. Objętość określano za pomocą metody opartej na prawie Archimedesesa, w cylindrze miarowym wypełnionym olejem rzepakowym. Do pomiaru powierzchni wykorzystano komputerową analizę obrazu. Podczas suszenia rejestrowano kamerą obraz i przesyłano do komputera, a następnie za pomocą programu MultiScan v.0896, służącego do komputerowej analizy obrazu, określano powierzchnie próbki. Na podstawie pomierzonej objętości obliczano współczynnik skurczu suszarniczego z następującej zależności [Jaros 1999]:

$$s = 1 - \frac{V(\tau)}{V_0} \quad (1)$$

Jednocześnie, podczas suszenia rejestrowane były ubytki masy, które posłużyły do określenia zmian zawartości wody oraz temperatur powierzchni materiału w czasie suszenia. Temperaturę mierzono za pomocą termopary NiCr-Ni. Otrzymane wyniki badań posłużyły do budowy modelu SSN.

### Wyniki badań i ich analiza

Analizując zmiany współczynnika skurczu suszarniczego w czasie suszenia, a więc wraz z ubytkiem wody i wzrostem temperatury próbki, stwierdzono, że wartość współczynnika skurczu suszarniczego rośnie szybko do krytycznej zawartości wody tj. ok. 2,6 kg/kg, niezależnie od temperatury suszenia. Wynika to najprawdopodobniej z tego, że w tym okresie intensywnie odparowywana jest woda z powierzchni próbek i front odparowania przesuwa się powoli do wnętrza próbki, powodując kurczenie się kolejnych warstw tkanki materiału. Podczas dalszego suszenia współczynnik skurczu nieznacznie wzrasta i stabilizuje się na poziomie około 0,75. Zmiany te odpowiadają okresowi transportu masy z wnętrza materiału, ustaleniu się temperatury próbki oraz momentowi usztywnienia ścian komórkowych na skutek przemian chemicznych niektórych jej składników.

### Model SSN

Do modelowania skurczu suszarniczego wykorzystano jednokierunkowe wielowarstwowe sztuczne sieci neuronowe. Jako zmienne wejściowe, przyjęto:

- x1 – temperaturę powierzchni próbki, [°C],
- x2 – względną zmianę zawartości wody, [kg/kg],
- x3 – względną zmianę powierzchni próbki, [kg/kg].

Jako zmienną wyjściową y przyjęto wielkość skurczu. Wartości temperatury przeskalowano według wzoru:

$$x_{1\text{skal}} = \frac{x_{1\text{rz}} - x_{1\text{D}}}{x_{1\text{G}} - x_{1\text{D}}} = \frac{x_{1\text{rz}} - 20}{80 - 20} \quad (2)$$

Wartości  $x_{1\text{D}}$  i  $x_{1\text{G}}$ , czyli najwyższą i najniższą temperaturę przyjęto na podstawie badań. Dane uzyskane z pomiarów zakwalifikowano losowo do trzech zbiorów:

- uczącego (35 przykładów),
- walidacyjnego (16 wzorców),
- testującego (16 wzorców).

Podczas tworzenia modelu wykorzystano sześć możliwych do zastosowania architektur sieci neuronowych:

a) dwuwarstwowe:

- 3:3–2–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 2 neurony w warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),
- 3:3–3–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 3 neurony w warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),
- 3:3–4–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 4 neurony w warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),

b) trójwarstwowe:

- 3:3–2–1–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 2 neurony w pierwszej warstwie ukrytej – 1 neuron w drugiej warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),
- 3:3–3–1–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 3 neurony w pierwszej warstwie ukrytej – 1 neuron w drugiej warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),
- 3:3–2–2–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 2 neurony w pierwszej warstwie ukrytej – 2 neurony w drugiej warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),


Dla wszystkich wymienionych architektur proces uczenia powtarzano pięciokrotnie uzyskując 30 modeli SSN. Do uczenia zastosowano algorytm wstecznej propagacji błędu, a uczenie prowadzono przez 100000 epok. Wyboru modelu – najlepszej sztucznej sieci neuronowej – dokonano na podstawie wartości miernika mBw dla zbioru testującego. Miernik ten został obliczony jako:

$$\begin{aligned} \text{mBw} &= |\text{srBw}| + \text{sdBw}; \\ \text{gdzie: } \text{Bw} &= \frac{Y_{\text{SSN}} - Y_{\text{POM}}}{Y_{\text{SSN}}}; \end{aligned} \quad (3)$$

Cztery sieci uzyskały wartość mBw poniżej 18% (dla danych testowych):


- sieć Nr 5 (3:3–2–1:1) mBw = 17,43%,
- sieć Nr 16 (3:3–2–1–1:1) mBw = 17,68%,
- sieć Nr 22 (3:3–2–2–1:1) mBw = 17,04%,
- sieć Nr 26 (3:3–3–1–1:1) mBw = 17,53%.

Na rysunku 1 przedstawiono 10 najlepszych modeli sieciowych, ponieważ pozostałych 20 modeli charakteryzowało się większymi wartościami błędów. Ze względu na małe różnice w wartościach mBw dla danych testujących, przy wyborze modelu SSN uwzględniono również wartości mBw dla zbioru uczącego i walidacyjnego. Ostatecznie jako najlepszy model wybrano sieć neuronową Nr 26 (3:3–3–1–1:1), dla której mBw (walidacyjne) = 14,07% i mBw (testujące) = 18,44% (rys. 1).




Rys 1. Wartości mierników błędów  
 Fig. 1. Values of error standards

Wyniki obliczeń otrzymanych za pomocą modelu zachowują tendencje zmian podobną do wartości empirycznych, tzn. w miarę obniżania zawartości wody, wzrostu temperatury powierzchni próbek oraz zmniejszania się powierzchni przekroju poprzecznego współczynnik skurczu rośnie. Ponieważ po pewnym czasie suszenia zawartość wody i temperatura powierzchni próbek uzyskują wartości odpowiadające stanowi równowagi, a powierzchnia przekroju poprzecznego próbki nie zmienia się, dlatego też wartość współczynnika skurczu zbliża się asymptotycznie do wartości końcowej. Można zatem przyjąć, że model weryfikuje się logicznie, a wielkość błędów pomiędzy wartościami pomierzonymi i obliczonymi pozwala uznać, że model weryfikuje się też empirycznie (maks. błąd. ok. 20%). Przykładowe przebiegi zmian skurczu suszarniczego określonego empirycznie i obliczonego za pomocą modelu od zawartości wody przedstawiono na rysunkach 2 i 3.



Rys. 2. Zmiany współczynnika skurczu suszarniczego próbek w zależności od zawartości wody, suszonych w temperaturze 50°C

Fig. 2. Changes of drying shrinkage factor for samples as a function of water content, dried at a temperature of 50°C



Rys. 3. Zmiany współczynnika skurczu suszarniczego próbek w zależności od zawartości wody, suszonych w temperaturze 70°C

Fig. 3. Changes of drying shrinkage factor for samples as a function of water content, dried at a temperature of 70°C

### Podsumowanie

Do opisu zmian współczynnika skurczu suszarniczego buraka ćwikłowego podczas suszenia w warunkach konwekcji wymuszonej zastosowano model sformułowany za pomocą SSN o następującej architekturze: 3:3–3–1–1:1 (3 zmienne wejściowe: 3 wejścia do sieci – 3 neurony w pierwszej warstwie ukrytej – 1 neuron w drugiej warstwie ukrytej – 1 neuron wyjściowy: 1 zmienna wyjściowa),

Na podstawie otrzymanych wartości mierników błędów (maks. błąd ok. 20%) stwierdzono, że zastosowany model SSN poprawnie opisuje przebieg zmian skurczu suszarniczego w zależności od zawartości wody w materiale, temperatury i wielkości powierzchni przekroju poprzecznego próbek. Model ten ma pewne cechy uniwersalności, ponieważ pozwala na określanie skurczu suszarniczego równocześnie dla różnych temperatur czynnika suszącego.

### **Bibliografia**

- Jaros M. 1999. Kinetyka suszenia warzyw. Rozprawy Naukowe AR w Lublinie (224).
- Karathanos V. T., Anglea S., Karel M. 1993. Collapse structure during drying of celery. *Drying Technology*, 11: 1005-1023.
- Lozano J. E., Rostein R., Urbicain M. J. 1983. Shrinkage, porosity and bulk density of foodstuffs at changing moisture contents. *Journal of Food Science*, 48: 1497-1502.
- Łapczyńska-Kordon B. 2003. Komputerowa analiza obrazu w oznaczaniu skurczu suszarniczego. *Inżynieria Rolnicza*, Nr 11 (53).
- Łapczyńska-Kordon Bogusława, Francik Sławomir. 2001. Sztuczne sieci neuronowe w modelowaniu zmian wymiarów geometrycznych warzyw podczas konwekcyjnego suszenia”. *Prace Komisji Nauk Rolniczych PAU*, nr 2: 83-91.
- Markowski M. 1994. Effect of moisture content on shrinkage and bulk density of vegetables. *Pol. J. Food Nutr. Sci.*, 3/(44)/4.
- Nowak D., Witrowa-Rajchert D., Lewicki P. 1998. Skurcz objętościowy i zmiana gęstości marchwi i ziemniaka podczas suszenia konwekcyjnego. *Zesz. Probl. Post. Nauk Rol.*, 454: 461-468.
- Pabis S., Jaros M. 2002. The first period of the convection drying of vegetables and the effect of shape-dependent shrinkage. *Biosystems Engineering*, 81(2), 201-211.
- Pabis S. 1999. The initial phase of the convective drying of vegetables and mushrooms and the effect of shrinkage. *J. Agric. Engng. Res.*, 72, 187-195.
- Suzuki K., Kubota K., Hasegawa T., Hosaka H. 1976. Shrinkage in dehydration of root vegetables. *Journal of Food Science*, 41: 1189-1193.
- Wang N. and Brennan J.G. 1995. A mathematical model of simultaneous heat and moisture transfer during the drying of the potato. *J. Food Eng.*, 24, 47-60.



## **MODELING DRYING SHRINKAGE FOR SELECTED ROOT VEGETABLES USING NEURAL NETWORKS**

### **Summary**

The paper presents an attempt to use a model created with the use of artificial neural networks for description of changes of drying shrinkage of red beet samples, during convection drying, as a function of water content, temperature of material and surface size. Based on the analysis of different network architectures, for description a tri-layer network with three inputs (three neurons in the first hidden layer, one neuron in the second hidden layer and one neuron at the output – one output variable) was selected due to the lowest error standards. The model turned out to show universal character, since it enabled simultaneous analysis of changes of shrinkage as a function of three parameters: water content, temperature and cross-section area of the sample.

**Key words:** shrinkage, SSN model, red beet