

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

ANALIZA TWARDOŚCI SELERA W CZASIE SUSZENIA

Streszczenie

W pracy przedstawiono próbę zastosowania modelu sformułowanego na bazie sztucznych sieci neuronowych do opisu zmian twardości selera w czasie konwekcyjnego suszenia w warunkach wymuszonego przepływu powietrza. Model opracowano na podstawie badań. Próbki selera w kształcie cylindrów o wymiarach 10x10 mm poddano suszeniu konwekcyjnemu w temperaturach: 60 i 70°C. Podczas suszenia w równych odstępach czasowych określano twardość materiału metodą Vickersa za pomocą mikrotwardościomierza PMT-3. Do opisu zmian twardości w zależności od zawartości wody, temperatury suszenia i rodzaju obróbki przed suszeniem zastosowano model opracowany za pomocą sztucznych sieci neuronowych SSN. Do budowy modelu zastosowano wielowarstwową jednokierunkową sztuczną sieć neuronową, wykorzystując do uczenia zmodyfikowany algorytm wstecznej propagacji błędów. Analizowano sieci o różnej architekturze w celu zoptymalizowania działania modelu sieciowego. Stwierdzono, że sieć o 3 neuronach w warstwie 1, 3 neuronach w warstwie 2 i 1 neuronie w warstwie wyjściowej jest optymalna. Błąd względny globalny pomiędzy wartościami otrzymanymi z doświadczeń i z obliczeń wyniósł 28,7%.

Słowa kluczowe: twardość, model, sztuczne sieci neuronowe SSN, seler

Wstęp


Warzywa pod wpływem obróbki termicznej, takiej jak blanszowanie, suszenie, zmieniają swoje właściwości fizyko-mechaniczne. Wynika to ze zmian zawartości wody i innych składników odżywczych w materiale, które pod wpływem gradientu temperatury i różnicy stężeń oraz ciśnienia cząsteczkowego tych składników transportowane są do jego powierzchni. Ponadto w materiale zachodzą przemiany chemiczne i strukturalne. W związku z tym zmienia się jakość badanego warzywa i jego właściwości fizyczne. Najczęściej przedmiotem badań były zmiany gęstości i porowatości w funkcji zawartości wody [Wang, Brennan 1995; Lozano

i in. 1983]. Suszenie pociąga za sobą też zmiany właściwości mechanicznych [Sitkiewicz i in. 1997]. Jedną z wielkości należącą do tych cech jest twardość. Prześledzenie przebiegu jej zmian może pomóc w ocenie zmian zachodzących wewnątrz materiału w czasie trwania procesu.

Dlatego w pracy podjęto próbę opracowania modelu opisującego zmiany twardości selera w zależności od zawartości wody oraz wpływu wstępnego nagrzewania w mikrofalach z wykorzystaniem sztucznych sieci neuronowych SSN.

Metodyka badań

Próbki selera w kształcie cylindrów o wymiarach 10x10 mm poddano suszeniu konwekcyjnemu, w warunkach wymuszonego przepływu powietrza, w dwóch temperaturach: 60 i 70°C. Suszono próbki nie blanszowane i blanszowane w gorącej wodzie (95°C). Podczas suszenia, co 10 min. wyciągano próbki z suszarki i określano twardość materiału metodą Vickersa za pomocą mikrotwardościomierza PMT-3W, gdzie penetrator miał kształt stożka o kącie 136°, a siła oddziaływania wynosiła 0,5 N (rys. 1). W trakcie pomiaru odczytywano maksymalną wartość zagłębienia penetratora w próbce. Przesunięcie wgłębnika było wyświetlane na ekranie czujnika zegarowego „Digimatic” z serii 543 firmy Mitutoyo, z dokładnością 0,001 mm. Czas zagłębiania się penetratora w materiał określono, kiedy wartość na czujniku nie zmieniała się przez około 10 sekund.



Rys. 1. Pomiar twardości przy zastosowaniu penetratora w kształcie stożka: a – wymiary penetratora; b – schemat pomiaru

Fig. 1. Hardness measurement using a penetrator in a cone form: a – penetrator dimensions; b – measurement diagram

Ponadto w czasie suszenia była wyznaczana zawartość wody w badanych próbkach na podstawie pomiarów mas przed i po określonym czasie suszenia oraz zawartości suchej substancji.

Twardość obliczono z następującej zależności:


$$HV = \frac{P}{F} = P \cdot \frac{\sin \frac{\alpha}{2}}{\pi \cdot h^2 \cdot \operatorname{tg}^2 \frac{\alpha}{2}} \quad [\text{N/m}^2] \quad (1)$$

gdzie:

- d – średnica arytmetyczna obu przekątnych odcisku [mm],
- α – kąt wierzchołkowy penetratora [°],
- h – wartość zagłębienia się penetratora [mm],
- F – pole powierzchni bocznej [mm],
- P – siła obciążająca wglębnik [N].

Wyniki badań


Analizując wyniki pomiarów zaobserwowano, że podczas suszenia w dwóch różnych temperaturach przebieg zmian twardości próbek materiału nie blanszowanych jest porównywalny (rys. 2) – twardość materiału maleje do zawartości wody ok. 2 kg/kg, następnie stabilizuje się do zawartości wody ok. 1 kg/kg, a dalej rośnie, aż do uzyskania przez materiał równowagowej zawartości wody.



Rys. 2. Zmiany twardości próbek nie blanszowanych w zależności od zawartości wody i temperatury powietrza suszącego

Fig. 2. Changes of hardness of non-blanching samples as a function of water content and drying air temperature

Różnice stwierdzono natomiast pomiędzy próbkami nie blanszowanymi i blanszowanymi w końcowym okresie suszenia. W pierwszym okresie suszenia, powierzchniowej wymiany masy, twardość materiału blanszowanego była podobna do twardości nie blanszowanego. Po osiągnięciu krytycznej zawartości wody (ok. 1,5 kg/kg) i wejściu w drugi okres suszenia – dyfuzyjnego transportu masy – twardość próbek blanszowanych była wyższa (rys. 3). Prawdopodobnie wynika to ze zmian składu chemicznego i właściwości fizycznych materiału podczas blanszowania, podczas którego zachodzi proces wyługiwania stałej substancji i dodatkowego uwadniania. Rozluźnia się struktura wewnętrzna materiału i szybciej odbywa się transport wody do powierzchni materiału, a faza stała usztywnia się pod wpływem zmian chemicznych.



Rys. 3. Zmiany twardości próbek blanszowanych i nie blanszowanych w zależności od zawartości wody i temperatury powietrza suszącego

Fig. 3. Changes of hardness of blanched and non-blanched samples as a function of water content and drying air temperature

Model z wykorzystaniem SSN

Na podstawie uzyskanych wyników przeprowadzono próbę sformułowania modelu z wykorzystaniem sztucznych sieci neuronowych. Jako zmienne wejściowe do sieci neuronowej przyjęto:

X1 – zawartość wody [kg/kg],

X2 – temperaturę suszenia [°C]

X3 – blanszowany i nie blanszowany materiał.

Twardość była zmienną wyjściową Y.

Do budowy modelu zastosowano wielowarstwową jednokierunkową sztuczną sieć neuronową, wykorzystując do uczenia zmodyfikowany algorytm wstecznej propagacji błędów. Analizowano sieci o różnej architekturze w celu zoptymalizowania działania modelu sieciowego. Stwierdzono, że sieć o 3 neuronach w warstwie 1, 3 neuronach w warstwie 2 i 1 neuronie w warstwie wyjściowej jest optymalna.

Poprawność modeli informacyjnego i SSN określano za pomocą miernika błędów opisanego równaniem:


$$mBw = |\bar{s}rBw| + |sdBw|$$

gdzie:

$\bar{s}rBw$ – średni błąd względny,


$sdBw$ – odchylenie standardowe błędów względnego.

Średnia wielkość błędów dla modelu SSN wyniosła 28,7%. Przykładowe przebiegi zmian twardości selera w funkcji zawartości wody otrzymane z pomiarów i obliczone z modelu przedstawiono na rysunkach 4–7.




Rys. 4. Twardość selera nie blanszowanego w zależności od zawartości wody (temperatura suszenia 60°C)

Fig. 4. Hardness of non-blanching celery as a function of water content (drying temperature 60°C)




Rys. 5. Twardość selera nie blanszowanego w zależności od zawartości wody (temperatura suszenia 70°C)

Fig. 5. Hardness of non-blanching celery as a function of water content (drying temperature 70°C)



Rys. 6. Twardość selera blanszowanego w zależności od zawartości wody (temperatura suszenia 60 °C)

Fig. 6. Hardness of blanched celery as a function of water content (drying temperature 60°C)



Rys. 7. Twardość selera blanszowanego w zależności od zawartości wody (temperatura suszenia 70 °C)

Fig. 7. Hardness of blanched celery as a function of water content (drying temperature 70°C)

Podsumowanie

Analizując otrzymane wyniki z modelu SSN, stwierdzono, że model ten poprawnie opisuje przebieg zmian twardości selera blanszowanego i nie blanszowanego w funkcji zawartości wody dla różnych temperatur suszenia. Wartość miernika błędów dla modelu SSN jest równa 28,7% , co pozwala uznać, że model weryfikuje się też empirycznie. Wielkość błędów zależy też od błędów popełnionych podczas badań, a w przypadku materiału biologicznego występuje duża losowość w jego parametrach. Model sformułowany w oparciu o SSN pozwala na uzależnienie twardości od większej liczby zmiennych niezależnych, równocześnie dla selera blanszowanego i nie blanszowanego, bez konieczności wykonywania dodatkowych obliczeń.

Bibliografia

Wang N., Brennan J. G. 1995. Changes in Structure, Density and Porosity of Potato during Dehydration. Journal of Food Engineering, 24: 61-76.

Lozano J. E., Rotstein E, Urbicain M. J. 1983. Shrinkage, porosity, and bulk density of foodstuffs at changing moisture content. *Journal Food Science*, 48: 1497-1502.

Sitkiewicz, I., Lenart, A., Lewicki P.P. 1997. Rheological properties of osmo-dehydrated plant tissue. In: *Engineering and Food at ICEF 7, Part I*, R. Jowitt (Ed.), Sheffield Academic Press Ltd., UK, 41-44.

ANALYSIS OF CELERY HARDNESS DURING DRYING PROCESS

Summary

The paper presents an attempt of using a model created based on artificial neural networks for description of changes in celery hardness during convection drying under forced air circulation conditions. The model was developed based on the tests. Celery samples in a form of cylinders in size of 10x10 mm were put to convection drying at temperatures: 60 and 70°C. During the drying process material hardness was determined at equal time intervals based on the Vickers method using microhardness tester PMT-3. For description of hardness changes as a function of water content, drying temperature and type of treatment before drying a model developed based on artificial neural networks SSN was used. For creating the model a multilayer unidirectional neural network was employed, using a modified algorithm of backward error propagation for learning process. Networks with different architecture were analyzed in order to optimize actions of the network model. The analysis showed that the optimal network was the one with 3 neurons in layer 1, 3 neurons in layer 2 and 1 neuron in output layer. The global relative error between the values obtained from the experiments and from calculations was 28,7%.

Key words: hardness, model, artificial neural networks SSN, celery