

## MODEL NEURONOWY ZMIAN TEMPERATURY PODCZAS KONWEKCYJNEGO SUSZENIA ZRĘBKÓW WIERZBY ENERGETYCZNEJ

Bogusława Łapczyńska-Kordon, Sławomir Francik, Zbigniew ŚlipekJakub Katedra Inżynierii Mechanicznej i Agrofizyki, Uniwersytet Rolniczy w Krakowie

**Streszczenie.** W pracy podjęto próbę zastosowania sztucznych sieci neuronowych do modelowania rozkładu temperatury w zrębках suszonych konwekcyjnie. W modelu uwzględniono cztery zmienne wejściowe: temperaturę czynnika suszącego, początkową zawartość wody, wymiary zrębka, czas suszenia oraz jedna wyjściowa – temperaturę materiału. Do budowy modelu posłużyły wyniki badań procesu konwekcyjnego suszenia zrębków wierzby, w trzech temperaturach: 50, 60 i 70°C, w suszarce z wymuszonym obiegiem powietrza. Podczas suszenia, w równych odstępach czasowych, określano zawartość wody i temperaturę materiału. Sformułowany model w oparciu o sztuczne sieci neuronowe został wybrany na podstawie najmniejszej wartości błędu średnio kwadratowego dla zbioru walidacyjnego. Następnie model ten poddano testowaniu i weryfikacji za pomocą wyników pomiarów wykonanych w takich samych warunkach jak opisane powyżej. Stwierdzono, że model poprawnie opisuje kinetykę zmian temperatury materiału w zależności od wybranych czterech czynników wejściowych.

**Slowa kluczowe:** model neuronowy, zmiany temperatury, suszenie konwekcyjne

### Wstęp

Wierzba energetyczna po zbiorze jest materiałem o znacznej wilgotności, powyżej 50%, i przed zrębkowaniem wymaga, żeby ją obniżyć do około 25%. Do produkcji pelet i brykietów wymagana jest wilgotność wierzby poniżej 15%, dlatego powinna być suszona. Proces suszenia należy tak prowadzić, aby zminimalizować zużycie energii. Ilość zużywanej energii w tym procesie zależy od temperatury czynnika suszącego, który ma wpływ na szybkość nagrzewania materiału i wzrost jego temperatury oraz szybkość odprowadzania wody do otoczenia. Dobór optymalnych parametrów suszenia umożliwia model procesu, za pomocą którego można symulować różne stany w zależności od parametrów wejściowych i poszukiwać optymalnych rozwiązań. Dobór optymalnych parametrów suszenia, które pozwolą na skrócenie tego procesu, jak również obniżenie kosztów, które są dość znaczne, ze względu na to, że proces suszenia jest energochłonny [Świgon, Kurasia 1996; Vissers, Giegler 2000].

W pracy podjęto próbę opracowania modelu zmian temperatury zrębków wierzby podczas ich konwekcyjnego suszenia za pomocą sztucznych sieci neuronowych, uwzględniającego wpływ temperatury czynnika suszącego, początkową zawartość wody i czas suszenia.

## Metodyka badań

Model zmian zawartości wody, w postaci sztucznej sieci neuronowej, został sformułowany na podstawie wyników pomiarów procesu suszenia. Badaniom poddano wierzbę krzewiątą (wierzba konopiana) – *Salix viminalis*. Materiał suszono w postaci zrębków o długości około 2 cm. Próbki były pobierane bezpośrednio przed suszeniem, aby nie dopuścić do obsychania materiału. Badany materiał był przed suszeniem ważony na elektronicznej wadze WPE 300 (dokładność 0,01g). Materiał suszono w suszarce konwekcyjnej firmy ELKON KC 100 N z wymuszonym obiegu czynnika suszącego. Materiał był suszony w temperaturach 40, 50, 60 i 70°C. Do pomiarów suszenia w każdej temperaturze było przygotowanych 20 próbek. Pomiary masy próbek, do wyznaczenia zawartości wody, wykonywano co 5 min. Proces suszenia prowadzono do momentu ustalenia się równoważowej zawartości wody. W czasie suszenia była również rejestrowana temperatura materiału co 5 min.. Temperaturę mierzono termoparą NiCr-NiAl, umieszczoną wewnątrz zrębka, z dokładnością do 0,01°C.

### Model neuronowy kinetyki zmian temperatury zrębków

W oparciu o otrzymane wyniki pomiarów sformułowano model neuronowy. W modelu przyjęto trzy parametry wejściowe:

X1\_t\_susz - czas suszenia [min.],

X2\_T\_pow - temperatura powietrza [°C],

X3\_średniaH2Opocz - średnia początkowa zawartość wody, [kgH<sub>2</sub>O/kg.s.s.]

i jeden parametr wyjściowy

Y3\_Tprob - temperatura próbki [°C],

Podział danych do modelu na zbiory: uczący, walidacyjny i testujący przedstawiono w tabeli 1.

Tabela 1. Dane do modelu

Table 1. Data for the model

Temperatura	Liczba serii	Liczba pomiarów w serii	Calkowita liczba pomiarów	Seria 1	Seria 2	Seria 3	Seria 4
40	4	64	256	U	U	W	T
50	4	103	412	U	U	W	T
60	4	67	268	U	U	W	T
70	4	69	276	U	U	W	T
			1212				

Za pomocą programu Statistica Sieci Neuronowe przebadano 100 różnych architektur sieci jednokierunkowych. Były to sieci o radialnych funkcjach bazowych (RBF) oraz wielowarstwowe (3 i 4 warstwowe) sieci typu Perceptron (MLP).

Spośród analizowanych sieci (Automatyczny Projektant Sieci) zachowano 10 najlepszych (minimalna wartość błędu). Były to sieci MLP.

Przeprowadzono analizę wrażliwości dla wybranych sieci (rys. 1). Wartości ilorazu wzrostu błędu wskazują, że wszystkie zmienne wejściowe są istotne (wyjątkiem jest sieć

## Model neuronowy zmian temperatury...

sn05 – wartość ilorazu mniejsza od 1). Spośród zmiennych wejściowych najważniejszą zmienną jest temperatura powietrza suszującego. Ważną zmienną jest również czas suszenia, a najmniej istotna jest początkowa zawartość wody.

Jako kryterium wyboru najlepszej sieci neuronowej przyjęto minimalną wartość błędu średniokwadratowego (RMS) dla zbioru walidacyjnego:

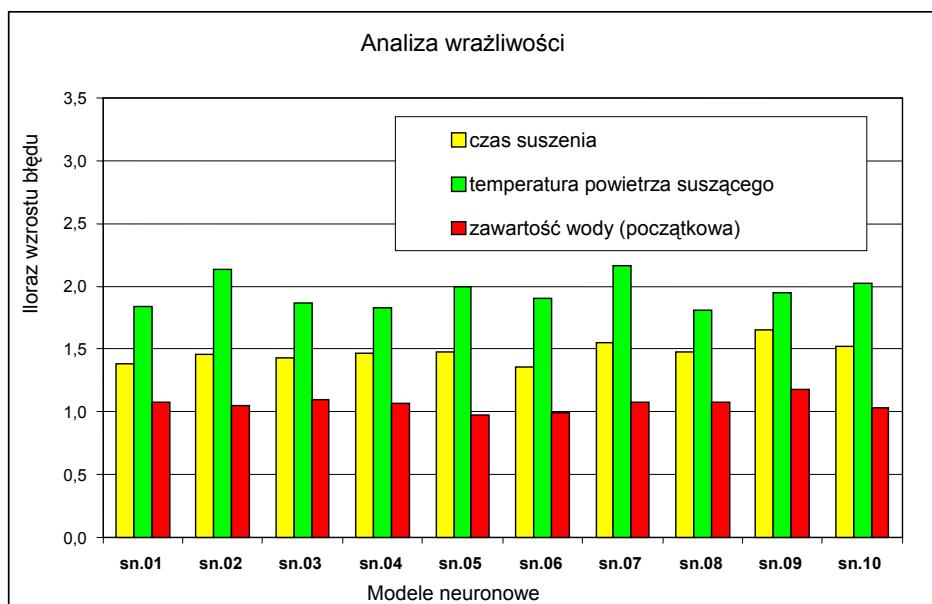
$$RMS = \sqrt{\frac{\sum (Y_{OBL} - Y_{RZECZ})^2}{n}}$$

$Y_{OBL}$  – wartość wielkości wyjściowej uzyskana z modelu neuronowego,

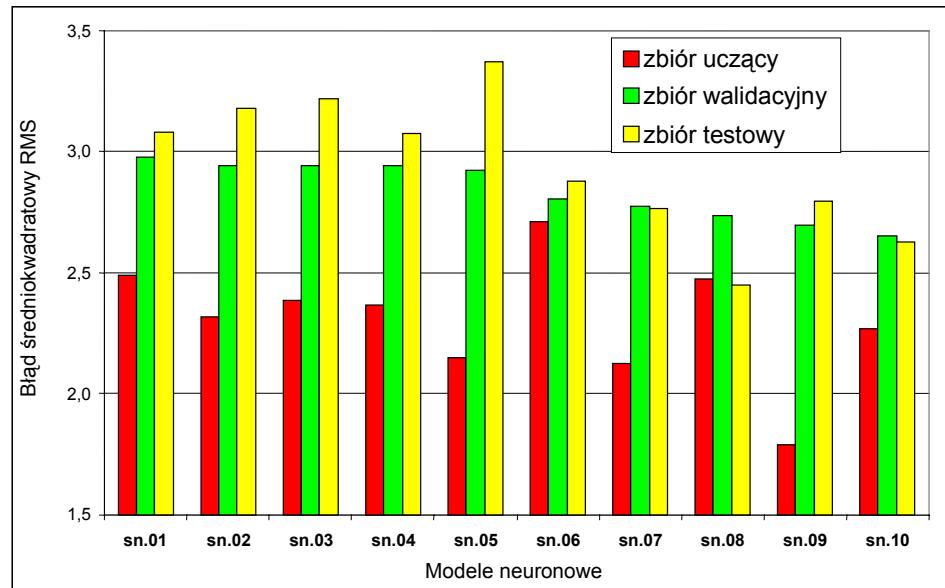
$Y_{RZECZ}$  – wartość wielkości wyjściowej uzyskana z pomiarów,

$n$  – liczba danych (wzorców).

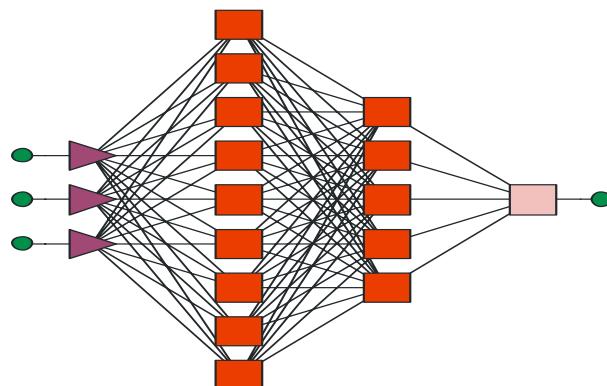
Okazało się, że najlepszą siecią jest oznaczona symbolem sn10 (rys. 2), dla której obliczona wartość RMS wyniosła 2,65 [°C]. Jest to czterowarstwowy Perceptron o 3 neuronach wejściowych, 9 neuronach w pierwszej warstwie ukrytej, 5 neuronach w drugiej warstwie ukrytej i jednym neuronie wyjściowym (MLP 3:3-9-5-1:1). Architekturę tej sieci przedstawiono na rysunku 3.



Rys. 1. Rozkład ilorazu wzrostu błędu dla różnych architektur sieci neuronowych  
Fig. 1. Distribution of error growth ratio for different architectures of neural networks



Rys. 2. Rozkład błędu średniokwadratowego dla przyjętych modeli neuronowych  
Fig. 2. Distribution of mean square error for accepted neural models



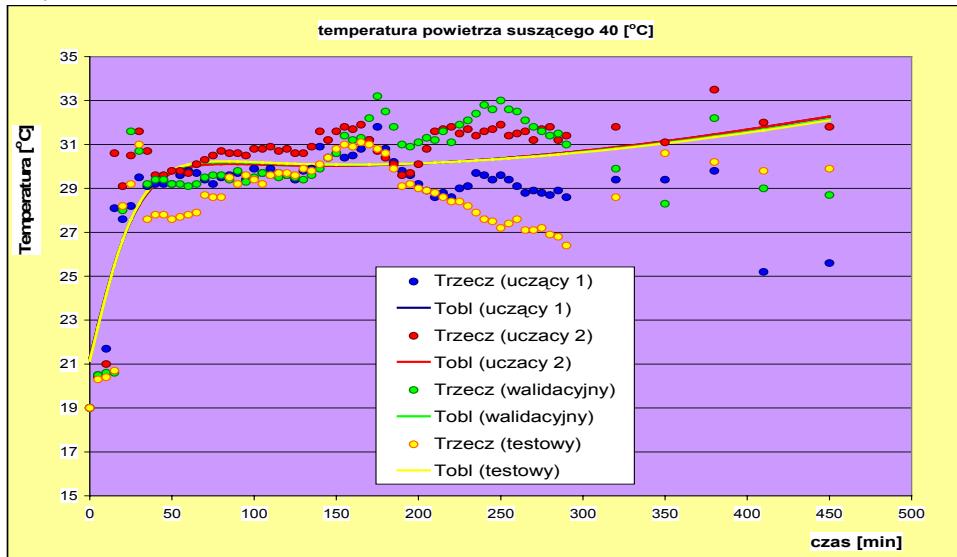
Rys. 3. Architektura przyjętego modelu neuronowego  
Fig. 3. The architecture of accepted neural model

Na rysunku 4 przedstawiono przykładowe przebiegi zmian temperatury materiału w czasie suszenia, dla czterech temperatur czynnika suszącego (powietrza). Na wykresach zamieszczono analizowane zmiany temperatur dla wyszczególnionych zbiorów wyników pomiarowych – uczącego, walidacyjnego i testującego. Analizując rozkład temperatury obliczonej za pomocą modelu stwierdzono, że model jest poprawny pod względem logicz-

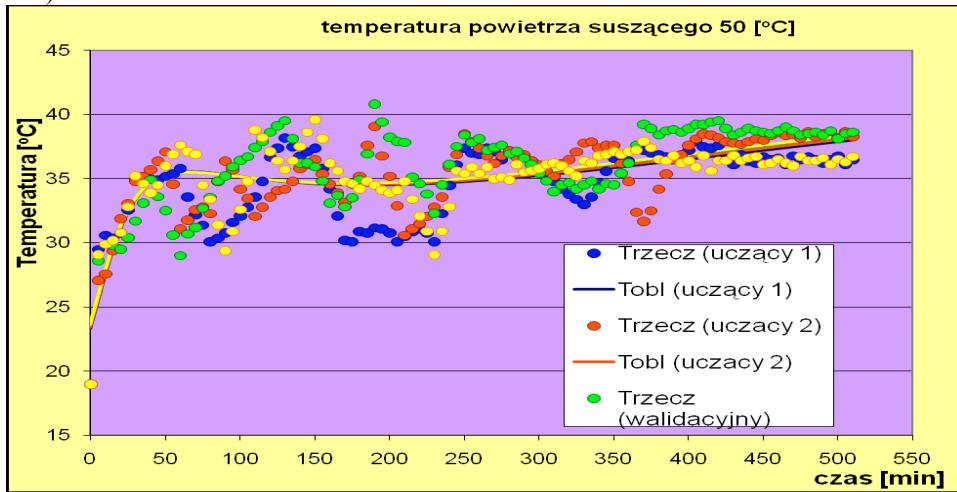
## Model neuronowy zmian temperatury...

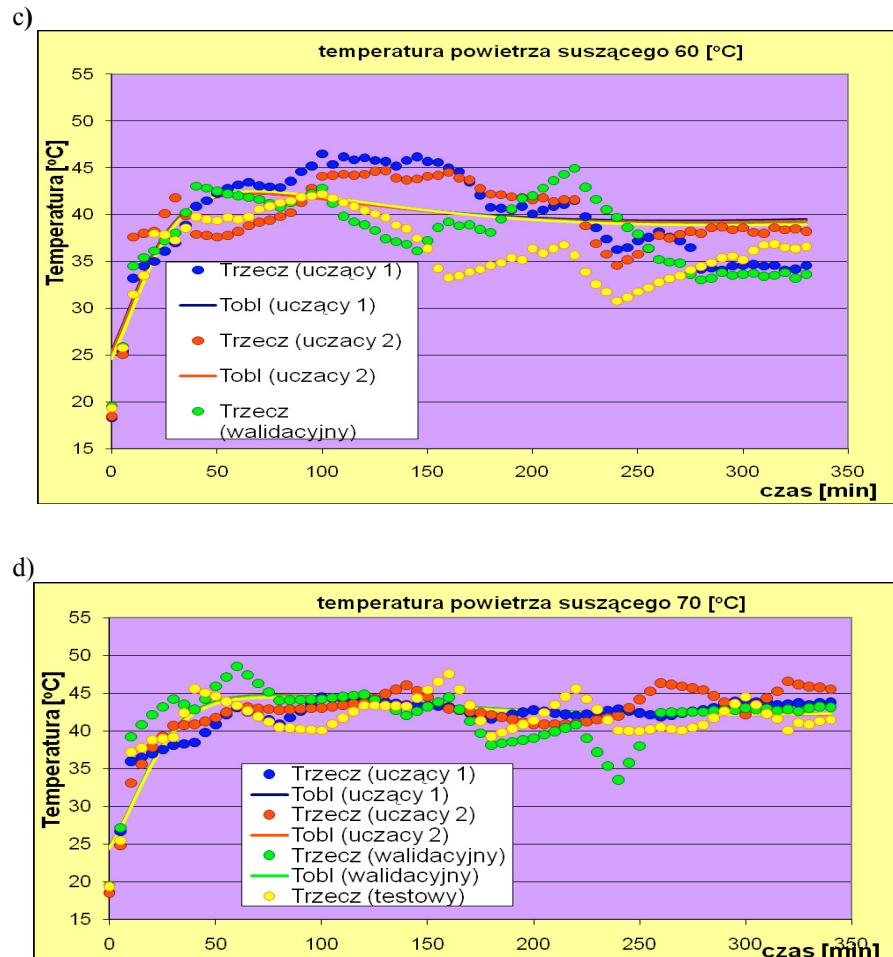
nym, ponieważ zmiana ta jest zgodna z przebiegiem zmian temperatury podczas nagrzewania ciał stałych. Również model został poprawnie zweryfikowany empirycznie – największa wartość błędu średniokwadratowego wyniosła około 3,5%. Na przedstawionych wykresach widoczna jest również wrażliwość na zmiany parametrów takie jak temperatura czynnika suszącego i czasu suszenia.

a)



b)





Rys. 4. Wykresy zmian temperatury zrębków określone doświadczalnie i obliczone z modelu, dla:  
a) 40°C, b) 50°C, c) 60°C, d) 70°C

Fig. 4. Kinetics of changes in chips temperature, determined empirically and computed using the model: for 40°C, b) for 50°C, c) for 60°C, d) for 70°C

## Wnioski

1. Kinetykę zmian temperatury materiału w czasie konwekcyjnego suszenia najlepiej opisuje model neuronowy w postaci czterowarstwowego perceptronu o 3 neuronach wejściowych, 9 neuronach w pierwszej warstwie ukrytej, 5 neuronach w drugiej warstwie ukrytej i jednym neuronie wyjściowym (MLP 3:3-9-5-1:1), oznaczony jako sieć sn10, dla której wartość RMS wyniosła 2,65°C. – proponuję zmianę szyku zdania jw.

2. Na podstawie analizy wrażliwości wybranych sieci neuronowych, za pomocą wzrostu błędu średniokwadratowego stwierdzono, że dla zmian temperatury suszonego materiału wszystkie analizowane zmienne wejściowe są istotne: najważniejszą jest temperatura czynnika suszającego, następnie czas suszenia, a najmniej istotną jest początkowa zawartość wody.

## Bibliografia

- Świgon J., Kurasiak T.** 1996. Wpływ obniżenia ciśnienia czynnika suszującego na czas konwekcyjnego suszenia drewna, Przemysł Drzewny. Nr 7. s. 20-22.  
**Vissers M.M., Gigler J.K.** 2000. Forced convective drying of willow chips. Biomass and bioenergy 19(4). s. 259-270.

## NEURAL MODEL OF TEMPERATURE CHANGES DURING CONVECTION DRYING OF ENERGY WILLOW CHIPS

**Abstract.** The paper demonstrates an attempt to employ artificial neural networks to model temperature distribution in chips being dried in the convection process. Four input variables were taken into account in the model: drying medium temperature, initial water content, chip dimensions and drying time, and one output variable - material temperature. Examination results for willow chips convection drying process, carried out at three temperature values: 50, 60 and 70°C in a drier with forced air flow were used to build the model. During drying the researchers were determining water content and material temperature at equal time intervals. The model formulated using artificial neural networks was selected according to the lowest mean square error value for validation set. Then, this model was subject to testing and verification using results of measurements performed in the same conditions as those described above. It has been observed that the model correctly describes kinetics of changes in material temperature depending on the selected four input factors.

**Key words:** neural model, temperature changes, convection drying

### Adres do korespondencji:

Bogusława Łapczyńska-Kordon; e-mail: kordon@ar.krakow.pl  
Katedra Inżynierii Mechanicznej i Agrofizyki  
Uniwersytet Rolniczy w Krakowie  
ul. Balicka 120  
30-149 Kraków