



BADANIE WPLYWU ZAWARTOŚCI WODY I AKTYWNOŚCI WODY NA CECHY ELEKTRYCZNE MIODU Z WYKORZYSTANIEM SIECI NEURONOWYCH

Katarzyna Pentos*, Deta Łuczycka, Krzysztof Pruski

Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy we Wrocławiu

* Adres do korespondencji: ul. Chelmońskiego 37-41, 51-630 Wrocław, e-mail: katarzyna.pentos@up.wroc.pl

INFORMACJE O ARTYKULE

Historia artykułu:
Wpłynął: kwiecień 2013
Zrecenzowany: grudzień 2013
Zaakceptowany: styczeń 2014

Słowa kluczowe:
miód
właściwości elektryczne
sztuczne sieci neuronowe
aktywność wody
zawartość wody

STRESZCZENIE

Celem badań było ustalenie stopnia wpływu zawartości wody oraz aktywności wody na wybrane cechy elektryczne miodu. W badaniach wykorzystano dane doświadczalne uzyskane dla pięćdziesięciu próbek miodów zebranych na terenie całej Polski. Były to miody nektarowe, nektarowo-spadziowe oraz spadziowe. Dla próbek oznaczono parametry chemiczne oraz elektryczne: przewodność dwudziestoprocentowego roztworu wodnego miodu oraz przewodność i impedancję patoki. Następnie wykorzystując sztuczne sieci neuronowe, skonstruowano wielowymiarowe modele matematyczne, opisujące zależność cech elektrycznych od parametrów chemicznych. Na podstawie tych modeli, wykorzystując znajomość struktury sieci oraz wartości wag synaptycznych, określono stopień wpływu poszczególnych parametrów wejściowych na parametry wyjściowe modelu. Przeprowadzone badania wykazały, że aktywność i zawartość wody w znacznie większym stopniu wpływają na impedancję niż na przewodność patoki oraz roztworu.

Wstęp i cel badań

Zawartość oraz aktywność wody ma ogromne znaczenie w kontekście jakości oraz przechowywania żywności. Parametry te są ze sobą powiązane, a ich wartość ma decydujący wpływ na trwałość żywności pochodzenia biologicznego. Do tego typu żywności można zaliczyć miody, w przypadku których zawartość monosacharydów oraz wody określają właściwości fizyczne produktu. Zawartość wody ma bezpośredni wpływ na zjawisko fermentacji miodu, które niekorzystnie wpływa na jakość produktu (Lazaridou i in., 2004). Co prawda aktywność i zawartość wody są ze sobą skorelowane, jednak aktywność wody mówi więcej o produkcie. Podczas przechowywania miodu zachodzi jego krystalizacja, która wpływa na sposób wiązania wody w miodzie i powoduje wzrost aktywności wody (Iurlina i Fritz, 2005; Wojtacki, 1989).

Oznaczanie aktywności wody w miodzie jest procesem wymagającym specjalistycznego sprzętu, przez co badania te są przeprowadzane w wyspecjalizowanych laboratoriach. Cechy elektryczne materiałów biologicznych rzadko są wykorzystywane do oceny jakości żywności, jednak w literaturze pojawiają się opracowania dotyczące tej tematyki (Skierucha i in., 2012; Łuczycka i in., 2011). Cechy elektryczne, jak przewodność oraz impedancja, mogą zostać wykorzystane do szeroko rozumianej oceny jakości miodów. Dlatego celowym jest ustalenie, w jaki sposób zawartość oraz aktywność wody wpływają na wybrane cechy elektryczne miodów.

Wyznaczenie zależności pomiędzy cechami chemicznymi i elektrycznymi miodów na podstawie danych pomiarowych jest trudne do przeprowadzenia metodami analitycznymi. W literaturze związanej z inżynierią rolniczą przedstawiono wiele przykładów modelowania takich zależności za pomocą sztucznych sieci neuronowych (Langman, 1999; Hebda i Francik, 2006; Górski i in., 2008; Łapczyńska-Kordon i in., 2008). W zadaniach takich można wykorzystać proste sieci o jednokierunkowym przepływie sygnałów (Pentoś i in., 2008; Łuczycka i Pentoś, 2010).

Przy odpowiednio dużej liczbie danych pomiarowych wykorzystanych do uczenia sieci, może ona stać się modelem matematycznym skomplikowanych, wielowymiarowych i nieliniowych zależności (Rutkowska i in., 1999; Osowski, 2006; Rutkowski, 2011). Strukturę sieci dobiera się w sposób empiryczny tak, aby uzyskać model o możliwie dużej dokładności, określanej dla zbioru uczącego oraz testowego.

Celem pracy było wykorzystanie modeli neuronowych uzyskanych na drodze badań symulacyjnych do określenia stopnia wpływu zawartości oraz aktywności wody na wybrane cechy elektryczne miodów.

Metodyka badań

Badania parametrów chemicznych oraz cech elektrycznych wykonano dla pięćdziesięciu próbek miodów. Badano miody nektarowe (39), nektarowo-spadziowe (4) oraz spadziowe (7) pozyskane w 2011 roku z terenu całej Polski. Próbkę miodów pochodziły bezpośrednio od producentów. Pomiary dotyczyły następujących parametrów miodu: zawartość oraz aktywność wody, zawartość glukozy, fruktozy oraz proliny, pH, liczba diastazowa, przewodność patoki oraz dwudziestoprocentowego roztworu wodnego miodu, impedancja patoki.

Badanie aktywności wody zostało przeprowadzone w Zakładzie Techniki Rolno-Spożywczej Politechniki Białostockiej. Oznaczenie aktywności wody zostało wykonane dla miodu w stanie płynnym. Próbkę została ogrzana do temperatury 55°C, a następnie schłodzona do temperatury 25°C. Pomiaru dokonano za pomocą przyrządu AQUA LAB CX-2 z komorą termostatowaną w temperaturze 25°C. Pomiary były wykonywane w pięciu powtórzeniach (dla pięciu niezależnych próbek), następnie określano wartość średnią. Pomiary zawartości wody wykonano metodą refraktometryczną poprzez pomiar współczynnika załamania światła za pomocą refraktometru Abbego. Pomiary pozostałych parametrów chemicznych zostały wykonane w Laboratorium Badania Jakości Produktów Pszczelich Instytutu Ogrodnictwa w Puławach. Zawartość glukozy oraz fruktozy została oznaczona metodą HPLC, zawartość proliny – metodą kalorymetryczną (A), liczby diastazowej – metodą Phadebas (A). Pomiar cech elektrycznych został wykonany w Instytucie Inżynierii Rolniczej Uniwersytetu Przyrodniczego we Wrocławiu. Wszystkie cechy elektryczne były mierzone w temperaturze 25°C. Do wykonania pomiarów posłużono się anali-

zатorem impedancji ATLAS 0441. Analizator ten umożliwił pomiar wartości impedancji w formie zespolonej. W modelach uwzględniono oddzielnie składową rzeczywistą i urojoną impedancji. Pomiar przewodności elektrycznej wykonano dla 20% roztworu wodnego miodu, metodą bezpośrednią za pomocą konduktometru AZ 8361 Cond./TDS. Przed wykonaniem pomiarów próbki miodów podgrzano do temperatury 40°C, aby uzyskać postać płynną. Wszystkie pomiary cech elektrycznych zostały wykonane czterokrotnie.

Uzyskane dane doświadczalne charakteryzowały się dużą rozbieżnością wartości (np. przewodność dwudziestoprocentowego roztworu wodnego miodu od 165 do 1222, aktywność wody od 0,52 do 0,65). Takie rozbieżności mogą powodować trudności w procesie uczenia sieci neuronowych, a także stwarzają niebezpieczeństwo błędnej oceny stopnia wpływu poszczególnych zmiennych wejściowych na parametry wyjściowe. Dlatego dane wykorzystane do uczenia sieci neuronowej zostały znormalizowane do zakresu 0,1–1 zgodnie z zależnością:

$$ZN = \frac{ZN_{\max} - ZN_{\min}}{Z_{\max} - Z_{\min}} \cdot (Z - Z_{\min}) + ZN_{\min} \quad (1)$$

gdzie:

- ZN – wartość unormowana zmiennej z ,
- ZN_{\min} – wartość minimalna przedziału normowania,
- ZN_{\max} – wartość maksymalna przedziału normowania,
- Z – wartość doświadczalna zmiennej z ,
- Z_{\min} – doświadczalna wartość minimalna zmiennej z ,
- Z_{\max} – doświadczalna wartość maksymalna zmiennej z .

Na podstawie otrzymanych wyników sformułowany został model neuronowy. Jako parametry wejściowe modelu zaproponowano:

- zawartość wody, (%)
- aktywność wody, (-)
- stosunek zawartości glukozy ($\text{g} \cdot 100\text{g}^{-1}$) do zawartości fruktozy ($\text{g} \cdot 100\text{g}^{-1}$),
- zawartość proliny, ($\text{mg} \cdot 100\text{g}^{-1}$)
- pH, (-)
- liczba diastazowa, (-).

Jako dane wyjściowe modelu zdefiniowano następujące cechy elektryczne:

- przewodność patoki, ($\text{S} \cdot \text{m}^{-1}$)
- przewodność dwudziestoprocentowego roztworu wodnego miodu, ($\text{S} \cdot \text{m}^{-1}$)
- impedancja, (Ω) .

O doborze parametrów wejściowych i wyjściowych wstępnego modelu zdecydowało doświadczenie autorów. Model ten został następnie zweryfikowany.

Do określenia wpływu zawartości i aktywności wody na cechy elektryczne wykorzystano dwa niezależne modele neuronowe. W pierwszym modelu parametrami wejściowymi były: zawartość wody, stosunek zawartości glukozy do zawartości fruktozy, zawartość proliny, pH i liczba diastazowa, w drugim modelu zawartość wody została zastąpiona aktywnością wody. Ponieważ celem skonstruowania modeli było określenie wpływu zawartości i aktywności wody na poszczególne cechy elektryczne, wykorzystano sieci neuronowe z pięcioma neuronami w warstwie wejściowej i czterema w warstwie wyjściowej.

wej. Doświadczenie innych autorów (Ślipek i in., 2003) wskazuje, że dane wykorzystane w procesie uczenia powinny zostać podzielone na zbiór uczący i testowy w odpowiednich proporcjach, np. 70% próbek uczących, 30% próbek testowych. W przeprowadzonym procesie uczenia wykorzystano 150-elementowy zbiór uczący i 50-elementowy zbiór testowy. Badania wykonano w środowisku *Matlab*, wykorzystując sieci neuronowe o jednokierunkowym przepływie sygnału (perceptron wielowarstwowy) z jedną warstwą ukrytą. Początkowe wartości elementów macierzy wag synaptycznych dobierano w sposób losowy. Uczenie sieci przeprowadzono, wykorzystując kilka różnych algorytmów uczących (różne modyfikacje algorytmu wstecznej propagacji błędów). Przetestowano kilkadziesiąt konfiguracji sieci neuronowej, zmieniając liczbę neuronów w warstwie ukrytej od 3 do 50. Najlepszą architekturę sieci wybierano na podstawie wartości błędu dla zbioru uczącego (z jednoczesną kontrolą błędu dla zbioru testowego, aby uniknąć efektu przeuczenia sieci). Wykorzystano wartości średniego błędu względnego obliczanego ze wzoru:

$$\varepsilon = \frac{\sum_{i=1}^n |(x_i^{\text{exp}} - x_i^{\text{calc}})|}{n} \cdot 100\% \quad (2)$$

gdzie:

x_i^{exp} – wartość oczekiwana sygnału wyjściowego dla i -tego elementu zbioru uczącego lub testowego,

x_i^{calc} – wartość sygnału wyjściowego dla i -tego elementu zbioru uczącego lub testowego uzyskana z modelu,

n – liczba elementów zbioru testującego.

Na podstawie struktury i wartości wag poszczególnych neuronów nauczonej sieci, można skonstruować wyrażenie w postaci wielomianu, opisujące zależność parametrów wyjściowych modelu od parametrów wejściowych (Pentoś, 2009). Każde połączenie między neuronami jest charakteryzowane przez współczynnik wagowy w , a każdy neuron posiada zdefiniowaną funkcję przejścia f (w tym przypadku była to funkcja sigmoidalna w warstwie ukrytej i liniowa w warstwie wyjściowej). Ogólną postać wyrażenia definiującego sygnał wyjściowy i -tego neuronu w warstwie wyjściowej można zapisać następująco:

$$y_i = f_{wi} \left(\sum_{j=1}^n w_{ij}^{(2)} v_j \right), \quad (3)$$

gdzie:

$$v_j = f_{uj} \left(\sum_{k=1}^m x_k w_{kj}^{(1)} \right). \quad (4)$$

W powyższym wzorze x_k to k -ta składowa wektora wejściowego, y_i – i -ta składowa wektora wyjściowego, f_{wi} – funkcja przejścia i -tego neuronu w warstwie wyjściowej, f_{uj} – funkcja przejścia j -tego neuronu w warstwie ukrytej, $w_{kj}^{(1)}$ – waga połączenia między k -tym wejściem modelu a j -tym neuronem warstwy ukrytej, $w_{ji}^{(2)}$ – waga połączenia między j -tym neuronem warstwy ukrytej a i -tym neuronem warstwy wyjściowej, v_j – sygnał wyjściowy j -tego neuronu w warstwie ukrytej, n – liczba neuronów w warstwie ukrytej, m – liczba neuronów w warstwie wejściowej.

Na podstawie znajomości wartości wag synaptycznych sieci zbudowanej z neuronów z sigmoidalną funkcją aktywacji w warstwie ukrytej oraz liniową funkcją aktywacji w warstwie wyjściowej, dla każdego z wyjść uzyskuje się wyrażenie opisujące zależność wartości parametru wyjściowego modelu od parametrów wejściowych. Wyrażenie to jest sumą składników postaci

$$\frac{a}{1 + \exp(b_1x_1 + b_2x_2 + \dots + b_nx_n)} \quad (5)$$

w których wartość współczynnika a jest zależna od wartości wag neuronów warstwy wyjściowej sieci, a wartości współczynników b_1, b_2, \dots, b_n zależą od wartości wag neuronów warstwy ukrytej sieci. Wyrażenie definiujące sygnał wyjściowy i -tego neuronu w warstwie wyjściowej można aproksymować funkcją postaci:

$$y_i = \chi_{i1}x_1 + \chi_{i2}x_2 + \dots + \chi_{in}x_n \quad (6)$$

gdzie wartości współczynników χ można wyliczyć lub oszacować metodami numerycznymi. W tym wypadku została wykorzystana metoda regresji wielorakiej. Wygenerowano zbiór danych reprezentujących zależność y_i od parametrów wejściowych (hiperprzestrzeń tych parametrów musi być równomiernie wypełniona punktami w całym zakresie ich zmienności). Dla tych danych przeprowadzono regresję wieloraką (z jednoczesną kontrolą współczynników dobroci dopasowania – współczynnika korelacji R oraz współczynnika determinacji R^2).

Wyniki badań

W celu zweryfikowania poprawności przyjętego modelu, przeprowadzone zostały badania wstępne. Ich celem było ustalenie czy wszystkie zmienne wejściowe modelu wpływają w sposób istotny na zmiany parametrów wyjściowych. Wykorzystując środowisko *Statistica*, opracowano cztery niezależne modele neuronowe. Każdy z tych modeli zawierał sześć wymienionych wyżej parametrów wejściowych oraz jeden parametr wyjściowy (były to kolejno wszystkie wymienione wyżej parametry wyjściowe). W celu znalezienia najlepszych architektur sieci, w każdym przypadku przebadano za pomocą *Automatycznego Projektanta Sieci* 150 różnych sieci neuronowych o jednokierunkowym przepływie sygnału. Dla wybranych, najlepszych sieci przeprowadzono analizę wrażliwości. Wykazała ona, że wszystkie zmienne wejściowe są istotne dla wszystkich parametrów wyjściowych (wartość ilorazu błędu ≥ 1). W przypadku przewodności patoki, najważniejszą zmienną jest liczba diastazowa, najmniej istotną – stosunek zawartości glukozy do zawartości fruktozy. Dla przewodności dwudziestoprocentowego roztworu wodnego miodu najważniejszą zmienną jest liczba diastazowa, najmniej istotną – zawartość proliny. W przypadku części rzeczywistej impedancji są to odpowiednio zawartość proliny i pH, a dla części urojonej impedancji – liczba diastazowa i zawartość wody.

Następnie wykorzystano dwa niezależne modele neuronowe, na podstawie których określono wpływ zawartości i aktywności wody na cechy elektryczne miodu. W przypadku modelu wykorzystanego do określenia wpływu zawartości wody na wymienione wyżej

cechy elektryczne spośród wszystkich testowanych struktur sieci wybrano perceptron wielowarstwowy o strukturze 5-9-4 (9 neuronów w warstwie ukrytej). Średni błąd względny modelu określany dla danych uczących wyniósł 2% (dla zbioru testowego 5%).

Na podstawie wartości wag synaptycznych ustalono postać funkcyjną zależności każdego wyjścia modelu sieciowego od poszczególnych wejść. Następnie dokonano przybliżenia otrzymanej zależności funkcyjnej wielomianem, otrzymując następujący wynik:

$$y_1 = -27x_1 + 4,24x_2 + 0,79x_3 - 6,17x_4 + 32,77x_5 \quad (7)$$


$$y_2 = -9,28x_1 + 15,25x_2 + 0,49x_3 - 15,54x_4 + 11,16x_5 \quad (8)$$

$$y_3 = 58,45x_1 + 11,96x_2 - 21,93x_3 + 20x_4 - 108x_5 \quad (9)$$

$$y_4 = 41x_1 - 7,6x_2 - 14,77x_3 + 8,7x_4 - 89x_5 \quad (10)$$

gdzie kolejne wartości y_i odpowiadają przewodności patoki, przewodności roztworu, części rzeczywistej i urojonej impedancji, a kolejne wartości x_i odpowiadają zawartości wody, stosunkowi zawartości glukozy do zawartości fruktozy, zawartości proliny, pH, liczbie diastazowej.

Na rysunku 1 przedstawiono w sposób graficzny wartości bezwzględne współczynników otrzymanego wielomianu odpowiadających wpływowi zawartości wody na cechy elektryczne ustalone jako parametry wyjściowe modelu.



Rysunek 1. Wartości bezwzględne współczynników obrazujące wpływ zawartości wody na parametry wyjściowe modelu

Figure 1. Absolute values of coefficients which picture the impact of water content on input parameters of the model

Dla sieci neuronowej służącej do określenia wpływu aktywności wody na wybrane cechy elektryczne spośród testowanych sieci wybrano sieć z 10 neuronami w warstwie

ukrytej (architektura 5-10-4). Średni błąd względny modelu określany dla danych uczących wyniósł 2,5% (dla zbioru testowego 5,1%). Na podstawie uzyskanego modelu otrzymano następujące zależności wielomianowe:

$$y_1 = 10,5x_1 + 14,5x_2 - 6x_3 + 11,6x_4 - 12,6x_5 \quad (11)$$

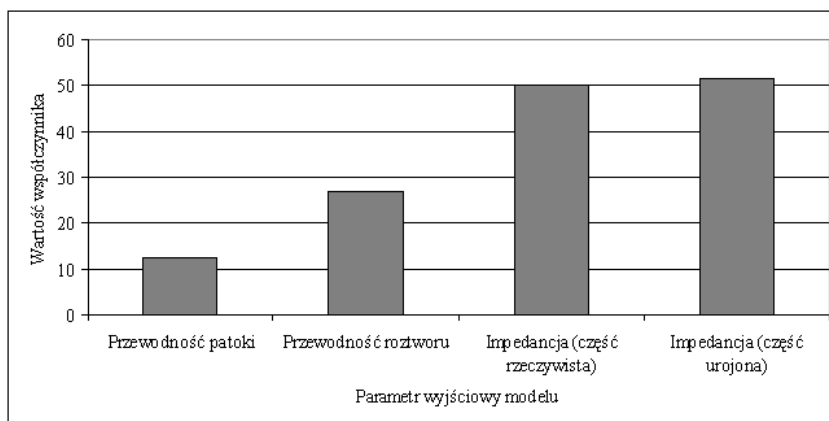
$$y_2 = -8,7x_1 - 9,6x_2 - 28,5x_3 + 24x_4 - 27x_5 \quad (12)$$

$$y_3 = 31,45x_1 - 17,3x_2 + 59x_3 + 15,3x_4 + 50x_5 \quad (13)$$

$$y_4 = 36,23x_1 - 44x_2 + 50x_3 - 12x_4 + 51,5x_5 \quad (14)$$

gdzie kolejne wartości y_i odpowiadają przewodności patoki, przewodności roztworu, części rzeczywistej i urojonej impedancji, a kolejne wartości x_i odpowiadają stosunkowi zawartości glukozy do zawartości fruktozy, zawartości proliny, pH, liczbie diastazowej, aktywności wody.

Na rysunku 2 przedstawiono wartości bezwzględne współczynników otrzymanego wielomianu odpowiadających wpływowi aktywności wody na cechy elektryczne ustalone jako parametry wyjściowe modelu.



Rysunek 2. Wartości bezwzględne współczynników obrazujące wpływ aktywności wody na parametry wyjściowe modelu

Figure 2. Absolute values of coefficients which picture the impact of water content on output parameters of the model

Otrzymane wyrażenia wielomianowe są aproksymacją zależności reprezentowanych przez model neuronowy uzyskaną z wykorzystaniem metod numerycznych. Dlatego nie mogą być traktowane jako model badanego zjawiska. Jednak stopień wpływu parametrów wejściowych na parametry wyjściowe nie został zniekształcony. Ponieważ badania zostały wykonane z wykorzystaniem dwóch niezależnych modeli neuronowych, różnice pomiędzy

wartościami współczynników przedstawionymi na rysunkach nie mogą podlegać interpretacji. Ocenie podlegają wyłącznie różnice w wartościach współczynników obliczonych dla konkretnego modelu.

Podsumowanie

Sieci neuronowe są wygodnym narzędziem analizy stopnia wpływu parametrów wejściowych modelu na jego parametry wyjściowe, szczególnie w przypadku gdy liczba parametrów jest duża, a zależności między nimi nieliniowe i ich charakter jest trudny do ustalenia metodami analitycznymi. Na podstawie przeprowadzonych badań sformułowano następujące wnioski:

1. Zawartość wody w największym stopniu wpływa na składową rzeczywistą oraz urojoną impedancji. Parametr ten wpływa również, choć w mniejszym stopniu, na przewodność patoki.
2. Aktywność wody w znacznie większym stopniu wpływa na impedancję (jej część rzeczywistą oraz urojoną) niż na przewodność patoki oraz roztworu miodu.

Literatura

- Górski, M.; Kaleta, J.; Langman, J. (2008). Zastosowanie sztucznych sieci neuronowych do oceny stopnia dojrzałości jabłek. *Inżynieria Rolnicza*, 7(105), 53-57.
- Hebda, T.; Francik, S. (2006). Model twardości ziarniaków pszenicy wykorzystujący Sztuczne Sieci Neuronowe. *Inżynieria Rolnicza*, 13(88), 139-146.
- Iurlina, M.O.; Fritz, R. (2005). Characterization of microorganisms in Argentinean honeys from different sources. *International Journal of Food Microbiology*, 105, 297-304.
- Langman, J. (1999). Zastosowanie sztucznych sieci neuronowych w inżynierii rolniczej. *Inżynieria Rolnicza*, 1(7), 153-158.
- Lazaridou, A.; Biliaderis, C.G.; Bacandritsos, N.; Sabatini, A.G. (2004). Composition, thermal and rheological behaviour of selected Greek honeys. *Journal of Food Engineering*, 64, 9-21.
- Łapczyńska-Kordon, B.; Francik, S.; Ślipek, Z. (2008). Model neuronowy zmian temperatury podczas konwekcyjnego suszenia zrębków wierzby energetycznej. *Inżynieria Rolnicza*, 11(109), 149-155.
- Łuczycza, D.; Pentoś, K. (2010). Zastosowanie sztucznych sieci neuronowych do opisu przenikalności elektrycznej mąki. *Inżynieria Rolnicza*, 2(120), 43-48.
- Łuczycza, D.; Szewczyk, A.; Pruski, K. (2011). Elektryczne metody wykrywania zafałszowań miodu. *Inżynieria Rolnicza*, 5(130), 165-170.
- Osowski, S. (2006). *Sieci neuronowe do przetwarzania informacji*. Warszawa, Oficyna Wydawnicza Politechniki Warszawskiej, ISBN: 83-7207-615-4.
- Pentoś, K.; Piotrowski, K.; Koralewska, J.; Matynia, A. (2008). Multilayer Perceptron as the Tool for Modeling of Reaction Crystallization of Barium Sulphate in MSMR Crystallizer. *Proceedings of 2008 International Conference on Machine Learning and Cybernetics*, 6, 73413-3417.
- Pentoś, K. (2009). Modelowanie procesów krystalizacji za pomocą sieci neuronowych. Rozprawa doktorska. Politechnika Wroclawska.
- Rutkowska, D.; Piliński, M.; Rutkowski, L. (1999). *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Warszawa, Wydawnictwa Szkolne PWN, ISBN: 83-01-12304-4.

- Rutkowski, L. (2011). *Metody i techniki sztucznej inteligencji*. Warszawa, Wydawnictwo Naukowe PWN, ISBN: 83-01-14529-3.
- Skierucha, W.; Wilczek, A.; Szyplowska, A. (2012). Dielectric spectroscopy in agrophysics. *International Agrophysics*, 2(26), 187-197.
- Ślipek, Z.; Francik, S.; Frączek, J. (2003). Metodyczne aspekty tworzenia modeli SSN w zagadnieniach agrofizycznych. *Acta Agrophysica*, 95, 231-241.
- Wojtacki, M. (1989). Fermentacja miodu. *Pszczelarstwo*, 4, 17-18.

INVESTIGATION OF THE IMPACT OF WATER CONTENT AND ACTIVITY ON ELECTRIC PROPERTIES OF HONEY WITH THE USE OF NEURAL NETWORKS

Abstract. The aim of this research was to determine how water content and water activity influence on the selected electrical honey parameters. Experimental data obtained for fifty samples of honey collected on the territory of Poland were used for research. These were nectar honeys, nectar-honeydew as well as honeydew honeys. Chemical and electrical parameters were determined for each sample: conductivity of 20 percentage water and honey solution, conductivity and impedance of liquid honey. Then, with the use of artificial neural networks multi-dimensional mathematical models, describing relationships between electrical and chemical properties were constructed. Based on these models, with the use of the knowledge of networks structure and values of synaptic weights, degree of the impact of particular input parameters on output parameters of the model were determined. The tests which were carried out proved that water activity and content influence impedance more than conductivity of liquid honey and solution.

Key words: honey, electrical properties, artificial neural networks, water activity, water content