

## WYKORZYSTANIE SIECI NEURONOWYCH W MODELOWANIU ZALEŻNOŚCI MIĘDZY WYBRANYMI CECHAMI FIZYKOCHEMICZNYMI I ELEKTRYCZNYMI MIODU

Deta Łuczycka, Katarzyna Pentoś

Uniwersytet Przyrodniczy we Wrocławiu

**Streszczenie.** Na cechy chemiczne i elektryczne miodu mają wpływ jego skład pyłkowy oraz zawartość wody. O ile zawartość wody można powiązać z analizowanymi parametrami zależnością funkcyjną, o tyle wpływ zawartości pyłków na badane cechy chemiczne i elektryczne miodu jest bardziej skomplikowanym zagadnieniem. W jednej próbce miodu można stwierdzić kilka do kilkunastu rodzajów pyłków różnych roślin, dlatego analiza jedynie wpływu pyłku przewodniego nie jest wystarczająca. Przedmiotem pracy jest wykorzystanie dwóch rodzajów sztucznych sieci neuronowych do tworzenia możliwie dokładnych modeli matematycznych uwzględniających zależność takich cech miodu, jak zawartość cukrów, aminokwasów, wolnych kwasów oraz przewodność elektryczna patoki od zawartości pyłków roślin i zawartości wody w próbce. Wykorzystując perceptron wielowarstwowy jako model matematyczny opisanych wyżej zależności, dokonano analizy wrażliwości. Na podstawie tej analizy możliwa była ocena wpływu parametrów wejściowych modelu na poszczególne wielkości wyjściowe. Sztuczne sieci neuronowe są wygodnym narzędziem do modelowania zależności pomiędzy cechami chemicznymi i elektrycznymi miodu a jego składem pyłkowym oraz zawartością wody. Większą dokładność modelu uzyskano wykorzystując perceptron wielowarstwowy o stosunkowo prostej strukturze. Sieci RBF generują model o znacznie niższej dokładności.

**Słowa kluczowe:** miód, sztuczne sieci neuronowe, analiza wrażliwości, cechy elektryczne

### WSTĘP

Sztuczne sieci neuronowe (SSN) są w ostatnich latach chętnie wykorzystywane w badaniach z zakresu agrofizyki [Langman 1999, Hebda i Francik 2006, Górski i in. 2008, Łapczyńska-Kordon i in. 2008]. Najczęściej stosuje się proste sieci o jednokierunkowym

przeplwywie sygnałów [Łapczyńska-Kordon i Francik 2008, Łuczycka i Pentoś 2010], ale również sieci typu RBF (o radialnych funkcjach bazowych) i sieci uczone metodami bez nauczyciela. Dzięki swoim właściwościom SSN umożliwiają m.in. modelowanie zależności, których złożoność, wielowymiarowość oraz nieliniowy charakter sprawiają, że trudno je opisywać metodami analitycznymi. Dzięki SSN możemy uzyskać przydatne w zastosowaniach praktycznych modele jedynie na podstawie danych pomiarowych, bez znajomości teoretycznych zależności opisujących badane zjawiska [Rutkowska i in. 1999, Osowski 2006, Rutkowski 2011]. Zagadnienia teoretyczne dotyczące SSN zostały szczegółowo opisane w wielu książkach oraz publikacjach [Tadeusiewicz 1993, Patterson 1996, Gardner i Dorling 1998, Agatonovic-Kustrin i Beresford 2000, Duch i in. 2000, Madden i in. 2001, Krawiec i Stefanowski 2003, Osowski 2006].

Cechy chemiczne i elektryczne miodu zależą w dużej mierze od rodzaju i odmiany miodu [Terrab i in. 2003, Jasim i in. 2007, Kędzia i Holderna-Kędzia 2008, Łuczycka 2009, Guo i in. 2010], te zaś mogą mieć znaczący wpływ zarówno na procesy przetwarzania miodu, jak i cechy fizyczne i chemiczne produktu finalnego, np. preparatów miodowych suszonych rozpyłowo [Samborska i Bieńkowska 2013]. Wielu badaczy analizowało powiązania między zawartościami różnych cukrów i proporcjami między nimi, charakterystycznymi dla danego rodzaju miodu, a właściwościami elektrycznymi. Autorzy uważają, że celowa jest również analiza powiązań pomiędzy zawartością pyłków roślin a cechami chemicznymi i elektrycznymi miodu. Przy dużej różnorodności badanych próbek wyniki analizy pyłkowej generują wektor danych wejściowych zawierający kilkanaście elementów. Poszukiwanie informacji o właściwościach takiego modelu metodami analitycznymi byłoby niezwykle trudne. Uzasadnia to podjęcie próby uzyskania takich wielowymiarowych modeli za pomocą sieci neuronowych.

Celem pracy było porównanie dokładności modeli neuronowych dla różnych struktur perceptronu wielowarstwowego a następnie, po wybraniu optymalnej struktury sieci, porównanie uzyskanych wyników z dokładnością modelu uzyskanego z wykorzystaniem sieci typu RBF. Dodatkowo, wykorzystując uzyskane modele zależności poszczególnych parametrów wyjściowych od składowych wektora wejść, analizowano ich wpływ na cechy chemiczne i elektryczne miodu.

## MATERIAŁ I METODY

Dla realizacji założonych celów badawczych przeprowadzono pomiary właściwości chemicznych miodu oraz przewodności elektrycznej patoki w temperaturze 25°C (pomiary przewodności prowadzono w szafie klimatyzacyjnej, w której miód przebywał w stabilizowanej temperaturze ok. 24 godzin). W przeznaczonych do analizy próbkach miodu określano następujące parametry:

- zawartość pyłków na podstawie analizy pyłkowej (PN-88/A-77626, pkt. 5.3.18),
- zawartość glukozy oraz fruktozy (PB-02:E05 z 17.02.2012 r. Metoda HPLC),
- zawartość wolnych kwasów (PB-07, E 03 z dnia 14.01.2011 r. – metoda potencjometryczna),
- zawartość proliny (PN-88/A-77626, pkt 5.3.9 – metoda kolorymetryczna),
- zawartość wody w próbce (refraktometryczna – refraktometr do miodu PAL-22S).

Przewodność elektryczną patoki  $\sigma$  mierzono za pomocą konduktometru Cond 3210 z dołączonym 4-elektrodowym czujnikiem konduktometrycznym TetraCon 325 o dokładności 1,5%. Czujnik ten przeznaczony jest do wykonywania pomiarów w substancjach typu pasty i emulsje. Posiada wbudowany czujnik temperatury o dokładności  $\pm 0,2$  K.

Badaniom poddano pięćdziesiąt próbek miodów, wśród których znajdowały się różne rodzaje miodów nektarowych, miody nektarowo-spadziowe oraz spadziowe. Pomiary dla każdej próbki zostały przeprowadzone czterokrotnie. Na podstawie uzyskanych badań laboratoryjnych określono składowe wektora wejściowego i wyjściowego modelu.

Składowe wektora wejściowego:

- zawartość pyłków dla 13 roślin [%],
- zawartość wody w próbce [%].

Składowe wektora wyjściowego:

- przewodność elektryczna patoki [ $S \cdot m^{-1}$ ],
- stosunek zawartości glukozy do zawartości fruktozy,
- zawartość wolnych kwasów [ $meq \cdot kg^{-1}$ ],
- zawartość proliny [ $mg \cdot (100 g)^{-1}$ ].

W przypadkach, gdy zawartość pyłku nie przekraczała 5%, była ona eliminowana z wektora danych wejściowych. Uzyskane dane doświadczalne charakteryzowały się dużą rozbieżnością wartości, która mogłaby spowodować trudności w procesie uczenia sieci neuronowych. Dlatego dane wykorzystane do uczenia sieci neuronowej zostały znormalizowane do zakresu 0,1–1. Następnie zbiór danych został podzielony na zbiór uczący zawierający 80% (160) punktów pomiarowych oraz zbiór testujący zawierający 20% (40) punktów pomiarowych. Wykorzystując środowisko *Matlab*, wygenerowano cztery niezależne modele neuronowe. Składowymi wektora parametrów wejściowych w przypadku każdego modelu była zawartość pyłków dla 13 roślin oraz zawartość wody w próbce, a parametrem wyjściowym kolejnych modeli były przewodność elektryczna, stosunek zawartości glukozy do zawartości fruktozy, zawartość wolnych kwasów i zawartość proliny. W przypadku modeli opartych na perceptronie wielowarstwowym (MLP), zdefiniowano sieć z jedną warstwą ukrytą. Jako funkcję przejścia neuronów w warstwie ukrytej przyjęto funkcję sigmoidalną. Początkowe wartości elementów macierzy wag synaptycznych dobierano w sposób losowy. Uczenie sieci przeprowadzono wykorzystując algorytm Levenberga-Marquardta. Przetestowano kilkadziesiąt konfiguracji sieci neuronowej, zmieniając liczbę neuronów w warstwie ukrytej od 5 do 50. Następnie ten sam zbiór danych został wykorzystany do uczenia sieci o radialnych funkcjach bazowych (RBF).

W celu ustalenia stopnia wpływu poszczególnych parametrów wejściowych na parametry wyjściowe, wykonano dodatkowe badania w środowisku *Statistica*. Opracowano cztery niezależne modele neuronowe o parametrach wejściowych i wyjściowych opisanych wyżej. W celu znalezienia najlepszych architektur sieci, w każdym przypadku przebadano za pomocą *Automatycznego Projektanta Sieci 200* różnych sieci neuronowych o jednokierunkowym przepływie sygnału (MLP). Dla wybranych, najlepszych sieci przeprowadzono analizę wrażliwości.

## Metody statystyczne

Ocena jakości uzyskanych modeli była oparta o wartość średniego błędu względnego dla zbioru uczącego i testowego obliczanego ze wzoru:

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

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

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

$n$  – liczba elementów zbioru uczącego lub testującego.

Dodatkowo dla każdego z modeli obliczano odchylenie standardowe błędu względnego dla zbioru uczącego i testowego. Dobry model charakteryzuje się tym, że dla wszystkich elementów zbioru uczącego i testowego błąd odwzorowania przyjmuje podobne wartości. Model, dla którego niska wartość błędu średniego wynika z tego, że część punktów została odwzorowana bardzo dokładnie, a w przypadku pozostałych błąd był na bardzo wysokim poziomie, ma ograniczoną przydatność praktyczną.

## WYNIKI I DYSKUSJA

W celu opracowania modeli neuronowych przyjęto następującą strukturę wektora wejściowego: procentowa zawartość wody podawana na pierwszy węzeł wejściowy, do węzłów wejściowych 2–14 podawano kolejno procentową zawartość pyłków następujących roślin: 2 – *Brassica napus* (rzepak) oraz kapustowate, 3 – *Calluna* (wrzos), 4 – *Centaurea cyanus* (chaber bławatek), 5 – *Fagopyrum* (gryka), 6 – *Frangula* (kruszyna), 7 – *Phacelia* (facelia), 8 – *Prunus* (typ śliwy), 9 – *Robinia* (akacja), 10 – *Rubus* (typ maliny), 11 – *Salix* (wierzba), 12 – *Solidago* (typ nawłoci), 13 – *Tilia* (lipa), 14 – *Trifolium pratense* (koniczyna czerwona).

W tabeli 1 przedstawiono analizę błędów względnych uzyskanych dla zbiorów uczących i testowych w przypadku czterech badanych modeli opracowanych z wykorzystaniem sieci MLP. Wyboru najlepszych struktur sieci dokonano na podstawie wartości średniego błędu względnego dla zbioru testowego.

Dane przedstawione w tabeli 1 wskazują, że uzyskane modele charakteryzują się małym błędem względnym dla zbioru uczącego, a dla zbioru testowego błąd ten osiąga akceptowalną wartość nieprzekraczającą 7%. W inżynierii rolniczej modele neuronowe, dla których średni błąd względny osiąga wartość kilkunastu, a nawet około 20%, są oceniane jako przydatne w zastosowaniach praktycznych [Łączczyńska-Kordon i in. 2006]. Przy ocenie modelu brano także pod uwagę wartość odchylenia standardowego błędu, szczególnie dla zbioru testowego. Dobry model charakteryzuje się tym, że dla wszystkich

Tabela 1. Analiza błędów względnych uzyskanych dla zbiorów uczących i testowych

Table 1. The relative error analysis for training and test data sets

| Parametr wyjściowy modelu<br>Output parameter  | Struktura sieci<br>Neural network structure | Zbiór uczący<br>Training data set                  |   |  |  | Zbiór testowy<br>Test data set                     |   |  |  |
|--|---|--|---|--|--|--|---|--|--|
|  |   | średni błąd względny<br>average relative error [%] | minimalny błąd względny<br>minimum relative error [%] | maksymalny błąd względny<br>maximum relative error [%] | odchylenie standardowe błędu<br>standard deviation of the relative error [%] | średni błąd względny<br>average relative error [%] | minimalny błąd względny<br>minimum relative error [%] | maksymalny błąd względny<br>maximum relative error [%] | odchylenie standardowe błędu<br>standard deviation of the relative error [%] |
| Przewodność elektryczna patoki<br>Strained honey conductivity                        | 14-10-1                                     | 2,9  | 0,20  | 11,3   | 2,1  | 6,7  | 0,71  | 12,8   | 3,7  |
| Stosunek zawartości glukozy do zawartości fruktozy<br>Glucose/fructose content ratio | 14-9-1                                      | 2,1  | 0,18  | 10,3   | 1,7  | 4,2  | 0,59  | 13,0   | 4,0  |
| Zawartość wolnych kwasów<br>Free acids content                                       | 14-8-1                                      | 3,4  | 0,25  | 11,1   | 2,1  | 5,8  | 0,68  | 13,6   | 2,3  |
| Zawartość proliny<br>Proline content   | 14-9-1                                      | 2,8  | 0,42  | 9,3  | 1,8  | 6,1  | 0,36  | 10,4   | 1,6  |

elementów zbioru testowego błąd odwzorowania przyjmuje podobne wartości. Model, dla którego niska wartość błędu średniego wynika z tego, że część punktów została odwzorowana bardzo dokładnie, a w przypadku pozostałych błąd był na bardzo wysokim poziomie, ma ograniczoną przydatność praktyczną. W przypadku modeli uzyskanych na podstawie przeprowadzonych badań symulacyjnych wartości średnie błędu względnego oraz odchylenie standardowe dla zbioru testowego wskazują na ich przydatność praktyczną. Wyniki uzyskane dla modeli wykorzystujących sieci typu RBF były gorsze w przypadku wszystkich czterech parametrów wyjściowych. Nie udało się uzyskać modelu, dla którego błąd  $\varepsilon$  osiągnąłby wartość mniejszą niż 20%.

W tabeli 2 przedstawiono wyniki analizy wrażliwości uzyskanych modeli. Analiza wrażliwości zwraca dla każdej zmiennej niezależnej informację, jak zmienia się wydajność sieci definiowana przez błąd predykcji, gdy usuniemy tę zmienną [Szaleniec 2008]. Informacja ta reprezentowana jest przez iloraz błędu. Im większa wartość tego ilorazu,


tym większy jest wpływ danej zmiennej niezależnej na zmienną zależną. W przypadku gdy iloraz przyjmuje wartość mniejszą od 1, dana zmienna niezależna nie jest istotna i powinna być usunięta z zestawu parametrów wejściowych modelu. Analogiczną metodę analizy wrażliwości zastosowali Hadzima-Nyarkoa w badaniach dotyczących modelowania stopnia uszkodzeń powstałych w wyniku trzęsień ziemi [Hadzima-Nyarkoa i in. 2011] oraz Pastor-Bárcenas w modelowaniu warstwy ozonowej w atmosferze [Pastor-Bárcenas 2005].

Tabela 2. Wartości ilorazów błędu dla poszczególnych parametrów wyjściowych modeli neuronowych

Table 2. Error quotient values for particular output parameters of neural models

| Parametr wyjściowy modelu<br>Output parameter  | Parametr wejściowy modelu – Input parameter |                       |                |                         |                  |                 |                 |               |                |              |              |                 |              |                           |      |
|--|---|-----------------------|----------------|-------------------------|------------------|-----------------|-----------------|---------------|----------------|--------------|--------------|-----------------|--------------|---------------------------|------|
|  | Zawartość pyłków – Pollen content [%]       |                       |                |                         |                  |                 |                 |               |                |              |              |                 |              |                           |      |
| Struktura sieci<br>Neural network structure  | Zawartość wody<br>Water content [%]         | <i>Brassica napus</i> | <i>Calluna</i> | <i>Centaurea cyanus</i> | <i>Fagopyrum</i> | <i>Frangula</i> | <i>Phacelia</i> | <i>Prunus</i> | <i>Robinia</i> | <i>Rubus</i> | <i>Salix</i> | <i>Solidago</i> | <i>Tilia</i> | <i>Trifolium pratense</i> |      |
| Przewodność elektryczna patoki<br>Strained honey conductivity                          | 14-7-1                                      | 1,30                  | 1,21           | 1,28                    | 1,50             | 1,03            | 1,11            | 1,04          | 1,03           | 1,00         | 1,23         | 1,01            | 1,01         | 1,11                      | 1,28 |
| Stosunek zawartości glukozy do zawartości fruktozy<br>Glucose/ /fructose content ratio | 14-8-1                                      | 3,35                  | 37,26          | 1,26                    | 1,20             | 11,00           | 1,23            | 12,21         | 5,23           | 3,46         | 2,96         | 9,36            | 5,07         | 1,72                      | 6,91 |
| Zawartość wolnych kwasów<br>Free acids content   | 14-10-1                                     | 4,09                  | 20,85          | 3,96                    | 4,06             | 1,51            | 5,22            | 6,94          | 3,37           | 3,42         | 1,89         | 5,48            | 4,22         | 9,23                      | 3,44 |
| Zawartość proliny<br>Proline content   | 14-9-1                                      | 2,32                  | 3,53           | 1,29                    | 1,31             | 2,26            | 1,00            | 2,79          | 1,39           | 1,11         | 1,44         | 1,73            | 2,88         | 1,27                      | 1,19 |

Na rysunkach 1–4 przedstawiono wartości ilorazów błędu dla czterech badanych modeli. Parametry wejściowe uszeregowano zgodnie z malejącą wartością ilorazu.




Rys. 1. Wartości ilorazu błędu opisujące wpływ parametrów wejściowych modelu na przewodność elektryczną patoki

Fig. 1. Error quotient values describing the input parameters influence on strained honey conductivity

W przypadku modelu opisującego zależność przewodności elektrycznej patoki od zawartości wody i składu pyłkowego (rys. 1), iloraz błędu przyjmuje wartości z zakresu 1–1,5. Zmienną objaśniającą o największym wpływie na wartość zmiennej objaśnianej jest zawartość pyłku *Centaurea cyanus*, jednak generalnie wartości ilorazu utrzymują się na podobnym poziomie dla wszystkich zmiennych objaśniających.


W przypadku modelu opisującego zależność stosunku zawartości glukozy do zawartości fruktozy od zawartości wody i składu pyłkowego (rys. 2), iloraz błędu przyjmuje wartości z zakresu 1,2–37,26. Najbardziej znaczącą zmienną objaśniającą jest zawartość pyłku *Brassica napus* (rzepak) oraz kapustowatych. W tym przypadku wartość ilorazu błędu jest wyraźnie wyższa niż dla innych zmiennych.



Rys. 2. Wartości ilorazu błędu opisujące wpływ parametrów wejściowych modelu na stosunek zawartości glukozy do zawartości fruktozy


Fig. 2. Error quotient values describing the input parameters influence on glucose/fructose content ratio

W przypadku modelu opisującego zależność stosunku zawartości wolnych kwasów od zawartości wody i składu pyłkowego (rys. 3), iloraz błędu przyjmuje wartości z zakresu 1,51–20,85. Również w tym przypadku zawartość pyłku *Brassica napus* (rzepak) oraz kapustowatych ma wyraźnie większy wpływ na wartość zmiennej objaśnianej niż pozostałe parametry wejściowe modelu.



Rys. 3. Wartości ilorazu błędu opisujące wpływ parametrów wejściowych modelu na zawartość wolnych kwasów

Fig. 3. Error quotient values describing the input parameters influence on free acids content



Rys. 4. Wartości ilorazu błędu opisujące wpływ parametrów wejściowych modelu na zawartość proliny

Fig. 4. Error quotient values describing the input parameters influence on proline content

W przypadku modelu opisującego zależność stosunku zawartości proliny od zawartości wody i składu pyłkowego (rys. 4), iloraz błędu przyjmuje wartości z zakresu 1–3,53. Jako parametry wejściowe wpływające w największym stopniu na zawartość proliny można wskazać zawartość pyłku *Brassica napus* (rzepak) oraz kapustowatych, *Solidago* (typ nawłoci), *Phacelia* (facelia), *Fagopyrum* (gryka) oraz procentową zawartość wody w próbce.



## WNIOSKI

Sztuczne sieci neuronowe są wygodnym narzędziem do modelowania zależności pomiędzy cechami chemicznymi i elektrycznymi miodu a jego składem pyłkowym oraz zawartością wody. Uzyskane modele można z powodzeniem wykorzystać do celów praktycznych. Modele o zadowalającej dokładności otrzymywane są wyłącznie na podstawie danych doświadczalnych. Na podstawie przeprowadzonych badań symulacyjnych można sformułować następujące wnioski:

1. Dla przedstawionych w pracy zależności większą dokładność modelu uzyskuje się wykorzystując perceptron wielowarstwowy z jedną warstwą ukrytą i liczbą neuronów w tej warstwie od 8 do 10. Sieci RBF generują model o znacznie niższej dokładności.

2. Na podstawie analizy wrażliwości uzyskanych modeli możliwa jest ocena wpływu parametrów wejściowych modelu na poszczególne wielkości wyjściowe. Analiza ta wskazała, że wszystkie parametry wejściowe modeli są istotne dla wszystkich parametrów wyjściowych (wartość ilorazu błędu  $\geq 1$ ).

3. W przypadku modelu opisującego zależność przewodności elektrycznej patoki od zawartości wody i składu pyłkowego nie można wyróżnić dominujących zmiennych objaśniających. W przypadku trzech pozostałych modeli, analiza wrażliwości wykazała jeden lub grupę parametrów wejściowych o wyraźnie dominującym wpływie na parametr wyjściowy modelu. Na stosunek zawartości glukozy do zawartości fruktozy, zawartość wolnych kwasów oraz zawartość proliny największy wpływ ma zawartość pyłków *Brassica napus* (rzepak) oraz kapustowatych.

## LITERATURA

- Agatonovic-Kustrin S., Beresford R., 2000. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *Journal of Pharmaceutical and Biomedical Analysis* 22(5), 717–727.
- Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R., 2000. *Sieci neuronowe*. Exit, Warszawa.
- Gardner M.W., Dorling S.R., 1998. Artificial neural Networks (the multilayer perceptron) – a review of applications in the atmospheric sciences. *Atmospheric Environment* 32(14/15), 2627–2636.
- Guo W., Zhu X., Liu Y., Zhuang H., 2010. Sugar and water contents of honey with dielectric property sensing. *Journal of Food Engineering* 97, 275–281.
- Górski M., Kaleta J., Langman J., 2008. Zastosowanie sztucznych sieci neuronowych do oceny stopnia dojrzałości jabłek. *Inżynieria Rolnicza* 7(105), 53–57.
- Hadzima-Nyarkoa M., Nyarko E.K., Moric D., 2011. A neural network based modelling and sensitivity analysis of damage ratio coefficient. *Expert Systems with Applications* 38, 13405–13413.
- Hebda T., Francik S., 2006. Model twardości ziarniaków pszenicy wykorzystujący Sztuczne Sieci Neuronowe. *Inżynieria Rolnicza* 13(88), 139–146.
- Jasim A., Prabhu S.T., Raghavan G.S.V., Ngadi M., 2007. Physico-chemical, rheological, calorimetric and dielectric behavior of selected Indian honey. *Journal of Food Engineering* 79, 1207–1213.
- Kędzia B., Hołderna-Kędzia E., 2008. *Miód. Skład i właściwości biologiczne*. Przedsiębiorstwo Wydawnicze Rzeczpospolita SA, Warszawa.

- Krawiec K., Stefanowski J., 2003. *Uczenie maszynowe i sieci neuronowe*. Wydawnictwo Politechniki Poznańskiej, Poznań.
- Langman J., 1999. Zastosowanie sztucznych sieci neuronowych w inżynierii rolniczej. *Inżynieria Rolnicza* 1(7), 153–158.
- Łapczyńska-Kordon B., Francik S., Frączek J., Ślipek Z., 2006. Modelowanie skurczu suszarniczego wybranych warzyw korzeniowych za pomocą sieci neuronowych. *Inżynieria Rolnicza* 13(88), 303–311.
- Łapczyńska-Kordon B., Francik S., Ślipek Z., 2008. Model neuronowy zmian temperatury podczas konwekcyjnego suszenia zrębków wierzby energetycznej. *Inżynieria Rolnicza* 11(109), 149–155.
- Łapczyńska-Kordon B., Francik S., 2008. Model neuronowy zmian zawartości wody w zrębkach wierzby podczas konwekcyjnego suszenia. *Inżynieria Rolnicza* 11(109), 143–148.
- Łuczycza D., 2009. Methodological aspect of testing electrical properties of honey. *Acta Agrophysica* 14(2), 367–374.
- Łuczycza D., Pentoś K., 2010. Zastosowanie sztucznych sieci neuronowych do opisu przenikalności elektrycznej mąki. *Inżynieria Rolnicza* 2(120), 43–47.
- Madden J.E., Avdalovic N., Haddad P.R., Havel J., 2001. Prediction of retention times for anions in linear gradient elution ion chromatography with hydroxide eluents using artificial neural networks. *Journal of Chromatography A* 910(1), 173–179.
- Osowski S., 2006. *Sieci neuronowe do przetwarzania informacji*. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa.
- Pastor-Bárceñas O., Soria-Olivas E., Martín-Guerrero J.D., Camps-Valls G., Carrasco-Rodríguez J.L., del Valle-Tascón S., 2005. Unbiased sensitivity analysis and pruning techniques in neural networks for surface ozone modelling. *Ecological Modelling* 182, 149–158.
- Patterson, D.W., 1996. *Artificial neural networks theory and application*. Printice Hall, New York.
- Rutkowska D., Piliński M., Rutkowski L., 1999. *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*. Wydawnictwa Szkolne PWN, Warszawa.
- Rutkowski L., 2011. *Metody i techniki sztucznej inteligencji*. Wydawnictwo Naukowe PWN, Warszawa.
- Samborska K., Bieńkowska B., 2013. Physicochemical properties of spray dried honey preparations. *Zeszyty Problemowe Postępów Nauk Rolniczych* 575, 91–105.
- Szaleniec M., 2008. Sieci neuronowe i regresja wieloraka – czyli jak określić złożoność w badaniach naukowych?, <http://www.statsoft.pl/czytelnia/czytelnia.html> (data dostępu: 20.03.2014).
- Tadeusiewicz R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa.
- Terrab A., González G., Díez M.J., Heredia F.J., 2003. Mineral content and electrical conductivity of the honeys produced in Northwest Morocco and their contribution to the characterisation of unifloral honeys. *Journal Sci Food Agric* 83, 637–643.

## THE USE OF ARTIFICIAL NEURAL NETWORKS FOR MODELING OF THE RELATIONSHIPS BETWEEN PHYSICO-CHEMICAL AND ELECTRICAL PROPERTIES OF HONEY

**Summary.** Pollen content and water content may influence the chemical and electrical parameters of honey. Water content can be related to analysed parameters by functional relationship but the influence of pollen content on honey chemical and electric parameters

is more complicated. In one honey sample may be a few or several pollen of various plant types. The analysis only primary pollen influence is not adequate. The subject of this work is the use of two types of artificial neural networks to obtain accurate mathematical models describing the relationship between honey parameters like the content of sugars, amino acids, free acids, strained honey conductivity and both pollen content and water content. A total of 50 honey samples were used for this study. The honey samples with different production origin and varieties have been collected. Regarding the type of honey, in the samples group there were nectar, nectar-honeydew and honeydew honeys. Artificial neural networks are an useful tool for modeling relationships between chemical and electrical honey features as the output model parameters and both pollen content and water content as the input model parameters. Two neural network types were used for modeling task – multilayer perceptron and RBF network. Several dozen network structures were investigated and model quality assessment was based on the value of average relative error and standard deviation of the relative error calculated for both, training and test data sets. The values of average relative error as well as standard deviation of the relative error calculated for best network structures obtained in simulation tests prove the practical utility of neural models. The results obtained for RBF network show that the practical utility of this model is lower than multilayer perceptron (the values of average relative error exceed 20% for all structures tested).

Using the multilayer perceptron as a mathematical model of these relationships, sensitivity analysis were executed. On the basis of this analysis, the assessment of the influence of model input parameters on some selected output parameters was possible. The results of the sensitivity analysis show that all input model parameters are statistically significant for all output model parameters (error quotient  $\geq 1$ ). In case of the model describing relationship between strained honey conductivity and both, water content and pollen content, one can not identify dominant explanatory variables. The most significant influence on glucose/fructose content ratio, free acids content and proline content was observed for content of two pollen: *Brassica napus* and *Brassicaceae*.

**Key words:** honey, artificial neural networks, sensitivity analysis, electrical parameters