

## CLASSIFICATION OF SELECTED APPLES VARIETIES AND DRIED CARROTS USING NEURAL NETWORK TYPE KOHONEN

### Summary

The purpose of this study was the analysis of ability classification neural model type Kohonen. Classification has been selected three varieties of apples, which often appear in Polish orchards in the area. For purposes of comparison, a similar analysis was performed to identify the quality of dried vegetables. Neural classification was based on the information encoded in the form of a set of digital images apples and dried. As the characteristics feature adopted color and shape of apples and dried carrots.

## KLASYFIKACJA WYBRANYCH ODMIAN JABŁEK ORAZ SUSZU MARCHWI Z WYKORZYSTANIEM SIECI NEURONOWYCH TYPU KOHONENA

### Streszczenie

Celem badań była analiza zdolności klasyfikacyjnych modelu neuronowego typu Kohonena, uczonego metodą „nie nadzorowaną”. Klasyfikacji poddano trzy wyselekcjonowane odmiany jabłek, które często występują w sadach na terenie Polski. Ze względów porównawczych, podobną analizę przeprowadzono w celu identyfikacji jakości suszu warzywnego. Neuronowej klasyfikacji dokonano w oparciu o informację zakodowaną w postaci zbioru cyfrowych obrazów jabłek oraz suszu marchwi. Jako cechy charakterystyczne, stanowiące podstawę do przeprowadzenia klasyfikacji, przyjęto reprezentacje w postaci palety dominujących barw występujących w kolorze owoców i suszu warzywnego oraz wybranych współczynników kształtu.

### 1. Wprowadzenie

Metody uczenia sieci neuronowych techniką „nie nadzorowaną” są ważną procedurą optymalizacyjną służącą do generowania wybranych topologii sztucznych sieci neuronowych, a w szczególności sieci zawierających w swojej strukturze neurony radialne. Są istotne zwłaszcza w sytuacji, gdy ze względu na charakter posiadanych danych empirycznych, nie można przeprowadzić procesu uczenia w sposób „nadzorowany”. Okoliczność taka może mieć miejsce w przypadku, gdy nie dysponuje się wyczerpującą wiedzą dotyczącą klasyfikowanych obiektów (np. nie są znane ich nazwy, parametry, wybrane charakterystyki itd.). W tej klasie metod uczenia sztucznych sieci neuronowych (zwanej też uczeniem „bez nauczyciela”) sieć, w trakcie optymalizacji wag, sama wypracowuje funkcje przetwarzania danych, np. uporządkowywania, wykrywania regularności w danych, ich klasyfikacji, kodowania itd. Tworzony w ten sposób model neuronowy nie wymaga w czasie uczenia posiadania informacji zwrotnej, korygującej jej działanie z zewnątrz (tj. oceny działania sieci). Jednym z typowych zastosowań wspomnianej procedury jest generowanie tzw. map cech, czyli przyporządkowywanie danych do poszczególnych klas według wcześniej wybranego kryterium podobieństwa. Popularnym modelem neuronowym uczonym „bez nadzoru” jest sieć zaproponowana w 1982 roku przez Tuevo Kohonena [2].

Jednokierunkowe, dwuwarstwowe sieci Kohonena, zwane często sieciami typu SOFM (ang. Self-Organizing Feature Maps: samoorganizujące się mapy cech) uznawane są m.in. jako efektywne instrumenty klasyfikacyjne. W trakcie procesu uczenia dostrajanie wag omawianej sieci neuronowej odbywa się za pomocą algorytmu wykorzystującego dwufazową metodę „bez wzorcową”. Zbiór uczący może być w tym wypadku zredukowany do przypadków

zawierających w swej strukturze jedynie zmienne wejściowe i nie posiadających zmiennych wyjściowych. Tworzony w ten sposób model neuronowy, podczas korekcji wag zachodzącej w trakcie procesu uczenia, w praktyce sam identyfikuje istniejące prawidłowości występujące w zbiorze uczącym. W istocie sieć Kohonena podczas uczenia dokonuje nieliniowej separacji jądrowej w zredukowanym zbiorze danych uczących. Jeśli taki zbiór posiada również odpowiedzi, wtedy mogą one być używane do etykietowania identyfikowanych centrów klasyfikacyjnych.

### 2. Metoda uczenia „bez nadzoru”

Jednym z ważniejszych zagadnień, które związane jest z procesem uczenia, jest próba automatycznego, czyli „nie nadzorowanego”, wytwarzania się reprezentacji postrzeganych danych. Człowiek obserwując kształty i kolory odwzorowuje sobie świat widziany w postaci sieci połączeń realizowanych bezpośrednio w korze mózgowej. Odzworowanie to wydaje się zachowywać pewne cechy topologiczne: neurony wrażliwe na podobne bodźce mają tendencję do koncentracji (grupowania się) oraz pewnej specjalizacji. Fakt ten powoduje powstawanie specjalizowanych obszarów w korze mózgowej, które umożliwiają proces rozpoznawania. Okazuje się, że wspomniana wyżej forma reprezentacji jest znacznie bardziej wyrafinowana u ludzi niż u zwierząt. Obserwacje nad zachowaniem zwierząt wskazują, że często wytwarzają sobie one jedynie bardzo ubogą reprezentację rzeczywistości, reagując na ogół na jeden rodzaj bodźca zewnętrznego, np. dźwięk lub wielkość poruszającego się obiektu.

Jednym z podstawowych sposobów uczenia „nie nadzorowanego” jest tzw. uczenie konkurencyjne (ang. *competitive learning*). W metodzie tej, w trakcie uczenia sieci neuronowej, poszczególne neurony „konkurują” ze sobą o

prawo do reprezentacji danych wejściowych. Obowiązuje przy tym zasada, że tylko jeden element wyjściowy może znajdować się w stanie aktywnym. Nazywany jest on zwycięzcą, natomiast schemat takiej reguły aktywacji neuronów określany jest mianem metody WTA (ang. *Winner Takes All*: zwycięzca bierze wszystko). Niestety, przy dużej liczbie neuronów, algorytmy WTA, w których tylko jeden neuron może podlegać adaptacji w bieżącej iteracji, są algorytmami słabo zbieżnymi. W praktyce więc zostały one zastąpione algorytmami WTM (ang. *Winner Takes*)

Most: zwycięzca bierze większość), w których oprócz zwycięzcy uaktualniają swoje wagi również neurony z jego sąsiedztwa [5].

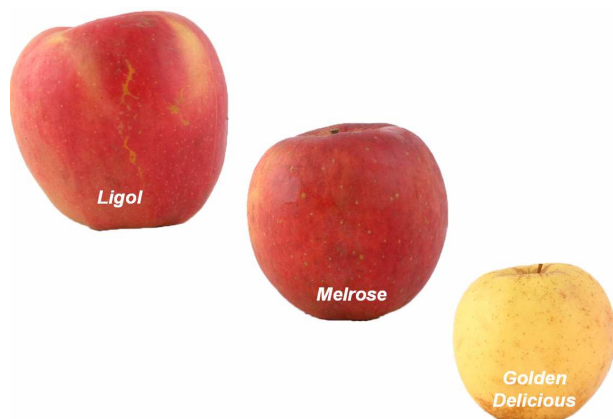
Tuevo Kohonen zaproponował zmodyfikowaną regułę uczenia konkurencyjnego, w której w odróżnieniu od reguły standardowej, modyfikacji wag dokonuje się nie tylko dla neuronu zwycięskiego, lecz również dla pewnej liczby neuronów z jego otoczenia. Reguła ta wymaga wprowadzenia tzw. topologicznego uporządkowania neuronów w warstwie wyjściowej (zwanej też mapą cech). W tym celu wprowadza się pojęcie otoczenia (radialnego sąsiedztwa) neuronu zwycięskiego, np. poprzez zaliczenie do tego otoczenia neuronów, których indeksy porządkujące nie różnią się o większą niż założona wartość, która wyznacza to otoczenie.

Celem pracy jest sprawdzenie efektywności modelu neuronowego typu *Kohonena* jako narzędzia do klasyfikacji wybranych produktów rolniczych, prezentowanych sieci w postaci obrazów cyfrowych.

### 3. Materiał badawczy

Klasyfikacji poddano trzy wybrane odmiany jabłek oraz dwa rodzaje konwekcyjnego suszu marchwi: prawidłowy oraz nieprawidłowy.


1. Jabłoń to rodzaj roślin wieloletnich z rodziny różowatych, szeroko rozpowszechnionych w strefie klimatów umiarkowanych. Jest jedną z najstarszych roślin uprawnych. Obecnie na świecie znanych jest ok. dwadzieścia pięć dziko rosnących gatunków, z czego tylko kilka występuje w Polsce. Kilka tysięcy odmian powstałych w skutek krzyżowania różnych gatunków wyjściowych, łączy się w jeden gatunek jabłoni domowa (*Malus domestica*). Ze względu na barwne owoce oraz kwiaty, jabłoni znajduje także zastosowanie jako roślina ozdobna. Klasyfikacji poddano wyselekcjonowane odmiany jabłek, które często występują w sadach na terenie Polski, tzn. odmiany: *Ligol*, *Melrose* oraz *Golden Delicious* (rys. 1).



Rys. 1. *Ligol*, *Melrose*, *Golden Delicious*  
Fig. 1. *Ligol*, *Melrose*, *Golden Delicious*

2. Warzywa, a w szczególności susz warzywny, stanowią nieodzowny składnik żywienia, głównie ze względu na swą dużą wartość żywieniową. W ostatnich latach susze warzywno stały się cenionym i poszukiwanym komponentem, występującym m.in. w przetwórstwie warzywnym. W dobie rosnącej popularności dań gotowych popyt na susze warzywno wzrasta. Szczególnie duże zapotrzebowanie występuje na susz marchwi. Ze względu na różnorodność stosowanych odmian uprawowych oraz metod suszenia, jakość suszu marchwi jest zróżnicowana pod względem jakościowym. Głównym celem suszenia marchwi jest wydłużenie okresu jej trwałości przez obniżenie aktywności wodnej, dzięki czemu następuje zahamowanie rozwoju drobnoustrojów i aktywności enzymatycznej.

Klasyczne systemy suszenia żywności można podzielić na naturalne (suszenie słoneczno-wietrzne, suszenie wietrzno-powietrzne) oraz sztuczne (suszenie konwekcyjne, konwekcyjne, dielektryczne, próżniowe, liofilizacyjne, rozpyłowe, mikrofalowe). W praktyce najczęściej stosowane są: suszenie konwekcyjne, liofilizacyjne oraz mikrofalowo-próżniowe [6]. W pracy badano susz marchwi odmiany *Karotan* firmy *Rijk Zwaana*, należącej do tzw. odmian późnych (rys. 2).



Rys. 2. Marchew odmiany *Karotan* w postaci surowca przed wysuszeniem

Fig. 2. *Karotan* carrots in a variety of raw dehydration

Neuronowej klasyfikacji poddano susz marchwi odmiany *Karoten* uzyskany metodą suszenia konwekcyjnego, który ze względu na przebieg procesu suszenia występował w dwóch umownych stanach jakościowych: prawidłowym i nieprawidłowym (rys. 3).

### 4. Metodyka badawcza


1. W celu identyfikacji odmian jabłek jako cechy reprezentatywne dla procesu separacyjnego uznano następującą wielkość:

- 9 kolorów charakterystycznych,
- 5 wybranych współczynników kształtu.

Stanowiły one 14 zmiennych wejściowych dedykowanych dla tworzonej sieci typu *Kohonena* o przyjętym wymiarze kwadratowej mapy topologicznej:  $14 \times 14 = 196$  (rys. 4).



Rys. 3. Przykładowe zdjęcie suszu konwekcyjnego  
Fig. 3. Sample image converters dried



Rys. 4. Struktura sieci neuronowej typu Kohonena  
Fig. 4. The structure of Kohonen neural network

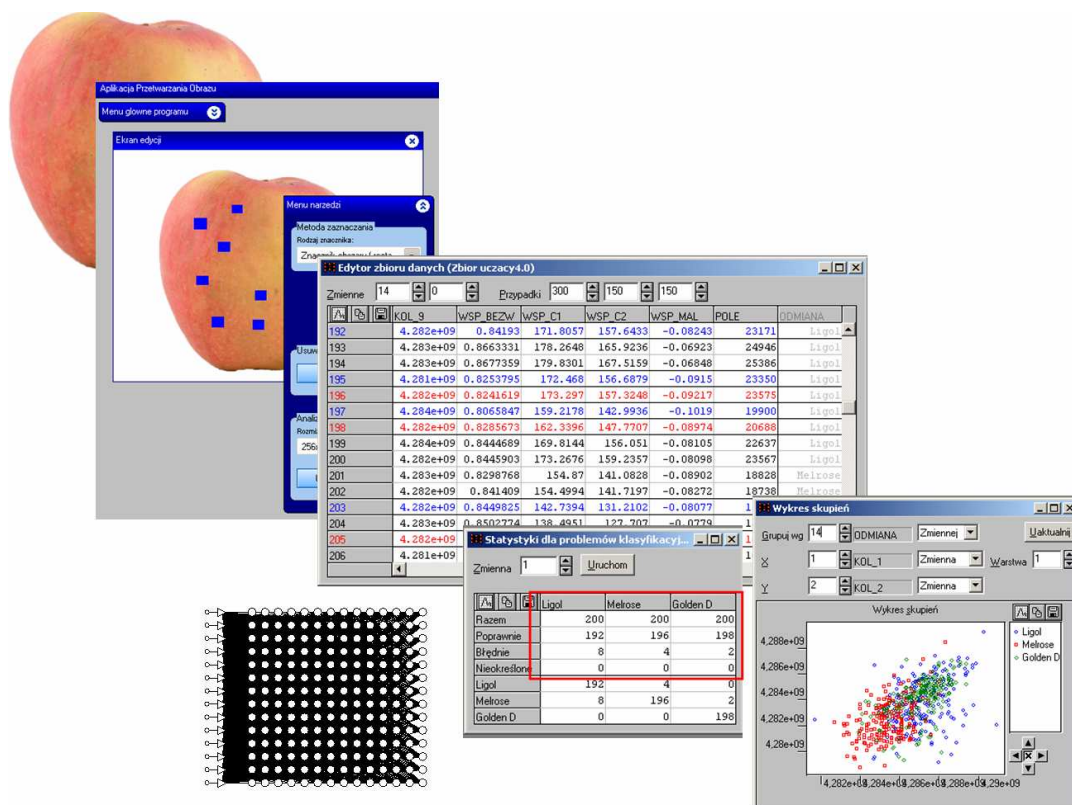
W celu wygenerowania zbioru uczącego wykorzystano narzędzie „Próbnik”, zaimplementowane jako funkcjonalny moduł w zbudowanym systemie informatycznym: „Przetwarzanie Obrazu v.1.0” [3]. Pozwala on m.in. na wygenerowanie zbioru wektorów (przypadków) uczących zapisanych w formie akceptowalnej do dalszego przetwarzania w komercyjnym pakiecie „STATISTICA v. 4.0”. Wytworzony zbiór uczący zawierał 600 niezależnych wektorów, standardowo podzielonych losowo na zbiory: uczący, walidacyjny oraz testowy, w proporcji 300:150:150 przypadków (rys. 5). Numeryczne zmienne wejściowe stanowiło 9 zakodowanych barw charakterystycznych oraz 5 współczynników kształtu [4]:

- wsp. bezwymiarowy,
- wsp. cyrkularności 1,
- wsp. cyrkularności 2,
- wsp. Malinowskiej,
- oraz pole powierzchni.

Za pomocą nominalnej, trzystanowej zmiennej wyjściowej (służącej do etykietowania klas) oznaczono wytypowane odmiany jabłek: *Ligol*, *Melrose* oraz *Golden Delicious*. Proces uczenia przeprowadzono w oparciu o algorytm zaproponowany przez Tuevo Kohonena, którego zadaniem jest określenie centrów skupień neuronów w wyjściowej warstwie radialnej sieci *Kohonena*. Uczenia sieci neuronowej dokonano w dwóch fazach:

- w pierwszej zastosowano mały współczynnik uczenia w zakresie od 0.9 do 0.1 w połączeniu z dużym zasięgiem sąsiedztwa w zakresie od 2 do 1 (100 epok),
- w drugiej ustabilizowano współczynnik uczenia na poziomie 0.01, w połączeniu z małym sąsiedztwem na poziomie 0 (10000 epok).

Proces tworzenia neuronowego klasyfikatora typu *Kohonena* przedstawiono na rys. 5.



Rys. 5. Proces generowania sieci neuronowej typu Kohonena do klasyfikacji odmian jabłek  
Fig. 5. Process of generating Kohonen neural network to varieties of apples classification

Wytworzony model neuronowy poprawnie klasyfikował trzy odmiany jabłek („statystyki dla problemów klasyfikacyjnych”- rys. 5). Pomimo podobnego koloru oraz zbliżonego kształtu odmian *Melrose* oraz *Ligol* (rys. 1) ich wzajemna separacja była wyraźna (znacznik czerwony oraz niebieski na „wykresie skupień” - rys. 5).


2. Podczas oceny jakościowej suszu istotne są wymagania organoleptyczne oraz fizykochemiczne. Do podstawowych wyróżników jakości suszu marchwi zaliczane są m.in. barwa oraz kształt (PN-72 A-77603). Zazwyczaj dokonuje się podziału na dwie klasy: susz prawidłowy oraz susz nieprawidłowy. W celu przeprowadzenia klasyfikacji jakościowej suszu marchwi jako cechy reprezentatywne dla procesu separacyjnego uznano:

- barwę w postaci zakodowanego kanału RGB z powierzchni kostki K,
- pole powierzchni kostki S,
- obwód kostki L,
- bezwymiarowy współczynnik kształtu  $R_s$ ,
- współczynnik Fereta  $R_F$ ,
- współczynniki cyrkularności R,
- współczynnik Malinowskiej  $R_M$ ,
- współczynnik regularności Reg,
- współczynnik Blaira-Blissa wg środka ciężkości  $R_{bbsc}$ ,
- współczynnik Blaira-Blissa wg środka geometrycznego  $R_{bbsg}$ .

Wybrane cechy stanowiły 10 zmiennych wejściowych przeznaczonych dla tworzonej sieci typu *Kohonen* o przyjętym wymiarze mapy topologicznej:  $10 \times 10 = 100$  (rys. 6).

Za pomocą nominalnej, dwustanowej zmiennej wyjściowej (służącej do etykietowania klas) umownie oznaczono dwa rodzaje suszu konwekcyjnego marchwi:

- susz prawidłowy,
- susz nieprawidłowy (rys. 3).



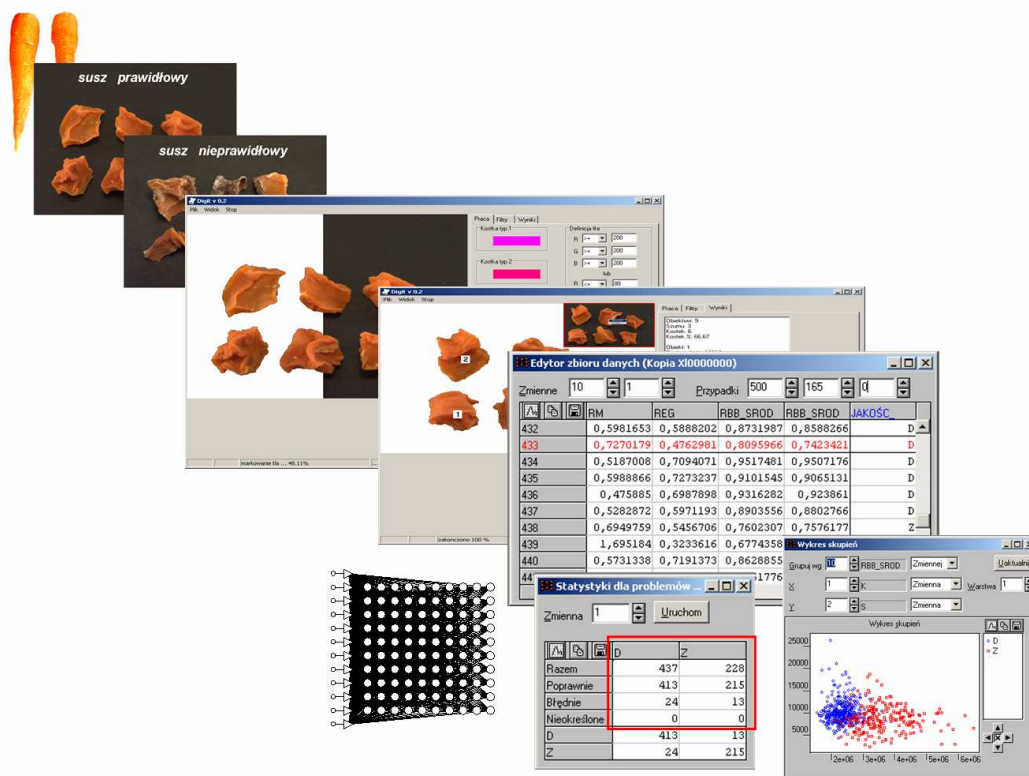
Rys. 6. Struktura sieci neuronowej typu *Kohonen*  
Fig. 6. The structure of *Kohonen* neural network

Ze względu na optyczne podobieństwo obu rodzajów suszu, dokonano analizy oraz przetwarzania obrazów cyfrowych, w celu uwypuklenia wytypowanych cech reprezentatywnych. W tym celu wytworzono a następnie wykorzystano oryginalny system informatyczny „*Digit v.2.0*”. Po dokonaniu konwersji obrazów cyfrowych suszu wygenerowano zbiór uczący, zawierający 665 przypadków. Podzielono go na zbiór uczący (zawierający 500 wektorów) oraz zbiór walidacyjny (posiadający 165 przypadków).

Podobnie jak w poprzednim przypadku, uczenie sieci przeprowadzono w oparciu o algorytm *Tuevo Kohonen*. Zgodnie z przyjętą wyżej procedurą dostrajanie wag neuronów radialnych tworzących mapę topologiczną wykonano w dwóch fazach:

- w pierwszej zastosowano współczynnik uczenia w zakresie: od 0.9 do 0.1, w połączeniu z dużym sąsiedztwem w zakresie: od 2 do 1 (100 epok),
- w drugiej ustabilizowano współczynnik uczenia na poziomie 0.01, w połączeniu z małym sąsiedztwem na poziomie 0 (10000 epok).

Proces tworzenia neuronowego klasyfikatora typu *Kohonen* przedstawiono na rys. 7.



Rys. 7. Proces tworzenia neuronowego klasyfikatora suszu typu *Kohonen*  
Fig. 7. Process of creating dried neural classifier type *Kohonen*

Wygenerowany model neuronowy poprawnie klasyfikował susz prawidłowy od suszu nieprawidłowego („statystyki dla problemów klasyfikacyjnych”- rys. 7). Pomimo podobnego koloru oraz zbliżonego kształtu suszu (rys. 3) ich wzajemna separacja była wyraźna (znacznik czerwony oraz niebieski na „wykresie skupień” - rys. 7). Jednak do prawidłowej klasyfikacji konieczna była konwersja cyfrowych obrazów suszu przeprowadzona w celu ekstrakcji cech reprezentatywnych. Pomimo tych zabiegów efektywność modelu neuronowego do klasyfikacji suszu była nieco gorsza w stosunku do wyników uzyskanych z klasyfikatora odmian jabłek.

## 5. Wnioski

1. Została wykazana przydatność sieci neuronowych typu *Kohonena* do klasyfikacji wybranych produktów rolniczych dokonywanej na podstawie ich cyfrowych obrazów.
2. Lepsze wyniki otrzymano z wykorzystaniem klasyfikatora odmian jabłek, co wynikało z większego zróżnicowania cech charakterystycznych badanych odmian.
3. Przeprowadzone badania wykazały, że istotny wpływ na jakość identyfikacji ma struktura danych wejściowych, a w szczególności właściwy dobór cech reprezentatywnych, charakteryzujących klasyfikowane obiekty.

4. W przypadku niewielkiego zróżnicowania cech reprezentatywnych (klasyfikacja suszu marchwi) konieczne było przetworzenie obrazów w celu uwypuklenia a następnie ekstrakcji parametrów charakterystycznych.

## 6. Literatura

- [1] Boniecki P., Piekarska-Boniecka H.: The SOFM type neural networks in the proces sof identification of selected orchad pests. *Journal of Research and Applications in Agricultural Engineering*, 2004, Vol. 49(4), pp.19-23.
- [2] Boniecki P.: *Elementy modelowania neuronowego w rolnictwie*. WUP, Poznań 2008.
- [3] Nowakowski K., Boniecki P., Weres J., Mueller W.: Przetwarzanie graficznych danych empirycznych dla potrzeb edukacji sztucznych sieci neuronowych, modelujących wybrane zagadnienia inżynierii rolniczej. *Inżynieria Rolnicza*, 2007, 2(90), s. 243-248.
- [4] Nowakowski K., Boniecki P.: Wpływ liczby zmiennych na jakość działania neuronowego modelu do identyfikacji wybranych uszkodzeń ziarniaków. *Inżynieria rolnicza*, 2008, Vol. 6(104), s. 145-151.
- [5] Ossowski S.: *Sieci neuronowe do przetwarzania informacji*. Warszawa 2000.
- [6] Pijanowski E., Dłużewski M., Dłużewska A., Jarczyk A.: *Ogólna technologia żywności*. Warszawa: WNT, 1997.
- [7] Tadeusiewicz R.: *Rozpoznawanie obrazów*. Warszawa: PWN, 1991.