

## NEURONOWA KLASYFIKACJA OBRAZÓW SUSZU WARZYWNEGO

Krzysztof Koszela, Jerzy Weres

*Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu*

**Streszczenie.** Celem pracy badawczej było opracowanie modelu neuronowego do oceny rodzaju suszu marchwiowego i jego klasyfikacji na podstawie cyfrowych fotografii. Analizie i klasyfikacji poddane zostały trzy rodzaje suszu marchwiowego, dla których wybrano cechy charakterystyczne, które umożliwiały klasyfikację ze względu na rodzaj oraz jakość suszu. W wyniku przeprowadzonych badań wygenerowano cztery modele neuronowe typu perceptron wielowarstwowy.

**Słowa kluczowe:** susz marchwiowy, rozpoznawanie obrazów, sztuczne sieci neuronowe

### Wprowadzenie

Powierzchnia uprawy warzyw w Polsce ulega ciągłym zmianom i przekształceniom. Każdego roku zmienia się struktura upraw poszczególnych warzyw. Niemniej jednak to właśnie uprawa marchwi odgrywa znaczącą rolę w grupie warzyw. Marchew (*Dacus carota*) stanowi znaczącą część produkcji wszystkich warzyw gruntowych. Jesteśmy postrzegani w świecie jako czołowy wytwórca marchwi z uwagi na czwartą pozycję w rankingu światowych producentów. Polska zajmuje pierwsze miejsce w uprawie tego warzywa wśród krajów Unii Europejskiej [Stępka 2004].

Również wśród warzyw suszonych strategiczną funkcję, z uwagi na szerokie spektrum zastosowania i wysokie wartości odżywcze, pełni susz marchwiowy. Zawiera on duże ilości karotenu i cukru, które występują w postaci kryształów. Marchew jest również najczęściej poddawana różnym metodom suszenia, co powoduje problemy w rzetelnej ocenie jakościowej i klasyfikacji tego suszu. Wśród wielu cech jakościowych suszu marchwi, które decydują o pozytywnej lub negatywnej ocenie jakościowej, jest barwa i kształt. Można stwierdzić, że zazwyczaj zabarwienie żywności jest jedną z istotnych cech, gdyż na podstawie wyglądu zewnętrznego konsument i klient decyduje o zakupie lub spożyciu danego produktu. Właściwa barwa, jak również odpowiedni kształt, który odpowiada tradycyjnie przyjętym normom, stanowią ważne kryteria oceny, ponieważ ich zmiany są zazwyczaj pierwszymi zauważalnymi wskaźnikami pogorszenia jakości pod względem innych cech sensorycznych - smaku, zapachu oraz wartości odżywczej.

Obecnie istnieje kilka możliwych sposobów pomiaru kształtu i barwy. Stosowane mogą być metody sensoryczne, wykonywane przez wykwalifikowane osoby weryfikujące, które w dużej mierze są ocenami mało powtarzalnymi bądź też subiektywnymi. Drugą grupę stanowią metody instrumentalne wykonywane przez urządzenia pomiarowe. Jednak

w przypadku metod instrumentalnych, w których są stosowane urządzenia dedykowane, badania są bardzo kosztowne i nie posiadają uniwersalnego charakteru pomiaru kilku cech, np. kształtu i barwy. Kolejną wadą w przypadku spektrofotometru jest pomiar barwy z małej powierzchni, co dla produktów pochodzenia roślinnego może być mało reprezentatywne.

Proces suszenia produktów rolniczych jest procesem skomplikowanym i energochłonnym. Prowadzone są w szerokim zakresie badania, które mają na celu opracowanie energooszczędnej technologii gwarantującej jednocześnie uzyskanie produktu o wysokiej jakości biologicznej jak również odżywczej [Pabis 1993, Weres 1991]. Większość produktów rolniczych, a w tym susze warzywne, w czasie obróbki termicznej zmienia barwę, teksturę oraz traci aromat i wartości odżywcze, gdyż w podwyższonej temperaturze następuje przyspieszenie szeregu reakcji chemicznych. Barwa warzyw kształtowana jest głównie przez chlorofile, karotenoidy i flawonoidy. Zbyt szybkie suszenie powoduje nierównomierną utratę wody, a tym samym twardnienie i brązowienie zewnętrznych cząstek suszu, przy jednocześnie wilgotnym wnętrzu [Hajduk i in. 1998].

W ciągu ostatnich dekad można zaobserwować szczególnie dynamiczny rozwój badań nad sztuczną inteligencją, a tym samym nad badaniami w zakresie systemów doradczych (ekspertowych), jak również nad sztucznymi sieciami neuronowymi [Stateczny i Praczyk 2002; Tadeusiewicz 1993; Kosiński 2002; Korbicz i in. 1994; Kavdir i Guyer 1995].


Celem projektu badawczego było opracowanie metody analizy obrazów suszu marchwi i zastosowanie ich do klasyfikacji poszczególnych frakcji w badanej próbce, zarówno pod względem rodzaju i jakości.

## **Materiały i metody**

Dla realizacji celu pracy wybrano odmianę marchwi *Karotan*. Odmiana *Karotan* firmy Rijk Zwaana należy do odmian późnych (rys. 1). Okres wegetacji, podczas uprawy przemysłowej wynosi 23 do 25 tygodni, długość korzenia od 20 do 30 cm, plon ogólny 94,4 t/ha. Charakteryzuje się korzeniem stożkowym o intensywnym wybarwieniu oraz wysokiej zawartości karotenu, cukru i suchej masy. Odmiana ta jest rekomendowana dla przemysłu do produkcji suszu i mrozonek. Oprócz powyższych czynników, motywacją doboru tej odmiany jest powszechność jej wykorzystania przez firmy zajmujące się suszarnictwem. Materiał badawczy został poddany obróbce wstępnej: mycia, obierania, krojenia i blanszowania, a następnie suszeniu następującymi metodami: konwekcyjną, liofilizacyjną, mikrofalowo-próżniową. Marchew przed procesem suszenia posiadał 88% wilgotności. Natomiast po procesie suszenia wilgotność wynosiła 6% dla suszu konwekcyjnego, 3% dla liofilizacyjnego oraz 8% dla mikrofalowo-próżniowego.

Do badań wykorzystano aparaturę badawczą oraz odpowiednio przygotowane stanowisko do akwizycji obrazu suszu marchwi. Stanowisko było wyposażone w: aparat cyfrowy, komorę bezcieniową, zestaw lamp oświetleniowych, statyw fotograficzny.

W celu przeprowadzenia analizy obrazów kostek suszu warzywnego wykonano zdjęcia dla poszczególnych metod suszenia. Do badań przygotowane zostały próby liczące 800 kostek z każdego rodzaju suszu. W poszczególnych próbach znajdowały się kostki suszu marchwi, zarówno spełniające kryteria jakościowe „dobre”, jak i kostki, które nie spełniały norm jakościowych, zarówno pod względem barwy, jak i kształtu - „niedobre”.



Rys. 1. Marchew odmiany *Karotan* w postaci surowca przed wysuszeniem  
Fig. 1. *Karotan* variety *Carrot* in form of material before drying

Kostki były umieszczane na jednolitym, kontrastującym tle, odseparowane od siebie. Wszystkie fotografie zapisywane były w formacie RAW a następnie konwertowane do formatu BMP w rozdzielczości (607x454). Kluczowym etapem był wybór cech charakterystycznych dla suszu marchwiowego za pomocą których możliwa była klasyfikacja przy pomocy sztucznych sieci neuronowych.

Do klasyfikacji wytypowano następujący zbiór cech: pole powierzchni, obwód, barwę w postaci zakodowanego kanału RGB, informację o kształcie opisanym wybranymi współczynnikami kształtu. Dedykowane współczynniki kształtu przedstawiono w tabeli 1.

W celu utworzenia modelu neuronowego niezbędne było nie tylko zebranie odpowiednich danych wejściowych, które stanowią pewną liczbę przypadków, lecz również przetworzenie tych danych na wartości numeryczne. W tym celu wytworzono i zastosowano autorski program komputerowy „Digit”. Tak przygotowany zbiór danych był zapisywany w odpowiednim formacie zbioru uczącego dla sztucznych sieci neuronowych. Na podstawie danych wytworzono cztery modele klasyfikacyjne dla poszczególnych rodzajów suszu.

Każdy ze zbiorów danych podzielony został na podzbiory: uczący, walidacyjny i testowy. Podczas projektowania poddane testowaniu zostały następujące rodzaje sieci neuronowych:

- sieć liniowa,
- sieci PNN (Probabilistic Neural Network),
- sieci GRNN (General Regression Neural Network),
- sieci MLP (Multilayer Perceptron) z trzema (jedna warstwa ukryta) i czterema warstwami (dwie warstwy ukryte),
- sieci o radialnych funkcjach bazowych RBF (Radial Basis Functions).

W wyniku przeprowadzonych testów wybrano sieci o najlepszych charakterystykach regresyjnych. W tabeli 2 przedstawiono proces uczenia dla poszczególnych modeli wraz z informacją o stosowanej metodzie. W procesie uczenia stosowano dwie metody uczenia, a mianowicie metodę wstecznej propagacji błędów BP (*Back Propagation*) oraz metodę gradientów sprzężonych CG (Conjugate Gradient) w wyniku których uzyskiwano najlepsze efekty w zakresie błędów RMS (Root Mean Square) oraz charakterystyk regresyjnych.

Tabela.1. Zestawienie współczynników kształtu  
Table 1. Comparison of shape factors

| L.p. | Nazwa współczynnika                                  | Wzór   | Opis  |
|------|--|--|---|
| 1    | Współczynnik regularności                            | $Re = \frac{S}{ab}$  | S – pole powierzchni obiektu,<br>a – długość obiektu,<br>b – szerokość obiektu.   |
| 2.   | Współczynnik Malinowskiej                            | $R_M = \frac{L}{2\sqrt{\pi S}} - 1$                          | L – obwód obiektu,<br>S – pole powierzchni obiektu.   |
| 3    | Bezwymiarowy współczynnik kształtu                   | $R_s = \frac{L^2}{4\pi S}$                                   | L – obwód obiektu,<br>S – pole powierzchni obiektu.   |
| 4    | Współczynnik Fereta                                  | $R_F = \frac{L_h}{L_v}$                                      | $L_h$ – maksymalny rozmiar obiektu w poziomie,<br>$L_v$ – maksymalny rozmiar obiektu w pionie.                            |
| 5    | Współczynniki cyrkularności                          | $R_{c1} = 2\sqrt{\frac{S}{\pi}}$<br>$R_{c2} = \frac{L}{\pi}$ | L – obwód obiektu,<br>S – pole powierzchni obiektu.   |
| 6    | Współczynnik Blaira-Blissa względem środka ciężkości | $R_{bbc} = \frac{S}{\sqrt{2\pi \sum_i r_i^2}}$               | S – pole powierzchni obiektu,<br>r – odległość piksela obiektu od środka ciężkości obiektu,<br>i – numer piksela obiektu. |

Tabela. 2. Zestawienie zbiorów uczących z podziałem na zbiory  
Table 2. Comparison of teaching sets - division into sets

| Nazwa zbioru modelu neuronowego | Liczba przypadków uczących | Liczba przypadków w zbiorze uczącym | Liczba przypadków w zbiorze walidacyjnym | Liczba przypadków w zbiorze testowym |
|---------------------------------|----------------------------|-------------------------------------|--|--------------------------------------|
| KLMZU                           | 2034                       | 1017                                | 508                                      | 509                                  |
| KDZZU                           | 780                        | 390                                 | 195                                      | 195                                  |
| LDZZU                           | 600                        | 300                                 | 150                                      | 150                                  |
| MDZZU                           | 768                        | 384                                 | 192                                      | 192                                  |

gdzie:

KLMZU – konwekcyjny, liofilizacyjny, mikrofalowo-próżniowy zbiór uczący,  
KDZU – konwekcyjny „dobry” „nieprawidłowy” zbiór uczący,  
LDZU – liofilizacyjny „dobry” „nieprawidłowy” zbiór uczący,  
MDZZU – mikrofalowo-próżniowy „dobry” „nieprawidłowy” zbiór uczący.

## Wyniki

Ostateczny wybór sieci neuronowej realizującej zadanie klasyfikacyjne dokonywano w oparciu o wyniki dla trzech podzbiorów: uczącego, walidacyjnego oraz testowego. Dla wszystkich modeli najlepszym rodzajem sieci okazał się perceptron wielowarstwowy z różną liczbą warstw i neuronów ukrytych. Także dla danego rodzaju sieci testowano i wybierano najlepszy model klasyfikacyjny o odpowiedniej topologii sieci, realizującej funkcję klasyfikacyjną tabela 3. Natomiast doboru najlepszej sieci dokonywano w oparciu

## Neuronowa klasyfikacja obrazów...

o statystyki regresyjne danych modeli oraz błąd sieci dla przypadków walidacyjnych i testowych tabela 4.

Tabela 3. Zestawienie topologii sieci dla modeli  
Table 3. Comparison of network topologies for models

| Numer modelu | Nazwa zbioru modelu neuronowego | Typ sieci | Liczba warstw ukrytych | Liczba neuronów w warstwach ukrytych | Liczba neuronów wejściowych | Liczba neuronów wyjściowych |
|--------------|---------------------------------|-----------|------------------------|--------------------------------------|-----------------------------|-----------------------------|
| 1            | KLMZU                           | MLP       | 1                      | 31                                   | 11                          | 3                           |
| 2            | KDZZU                           | MLP       | 2                      | 13:5                                 | 11                          | 1                           |
| 3            | LDZZU                           | MLP       | 1                      | 7                                    | 11                          | 1                           |
| 4            | MDZZU                           | MLP       | 2                      | 9:5                                  | 11                          | 1                           |

Tabela 4. Zestawienie statystyk regresyjnych dla modeli  
Table 4. Comparison of regression statistics for models

| Model [KLMZU] |              |                   |               |
|---------------|--------------|-------------------|---------------|
|               | Zbiór uczący | Zbiór walidacyjny | Zbiór testowy |
| ILODST        | 0,3445       | 0,3244            | 0,3001        |
| KOR           | 0,8138       | 0,8753            | 0,8061        |
| RMS           | 0,3024       | 0,3495            | 0,3340        |
| Model [KDZZU] |              |                   |               |
|               | Zbiór uczący | Zbiór walidacyjny | Zbiór testowy |
| ILODST        | 0,2019       | 0,2964            | 0,2040        |
| KOR           | 0,9156       | 0,8685            | 0,9156        |
| RMS           | 0,1881       | 0,2442            | 0,1866        |
| Model [LDZZU] |              |                   |               |
|               | Zbiór uczący | Zbiór walidacyjny | Zbiór testowy |
| ILODST        | 0,5297       | 0,5897            | 0,5276        |
| KOR           | 0,7968       | 0,7783            | 0,8003        |
| RMS           | 0,2800       | 0,3195            | 0,2934        |
| Model [MDZZU] |              |                   |               |
|               | Zbiór uczący | Zbiór walidacyjny | Zbiór testowy |
| ILODST        | 0,3705       | 0,3352            | 0,3711        |
| KOR           | 0,8418       | 0,8722            | 0,8027        |
| RMS           | 0,3165       | 0,3100            | 0,3484        |

gdzie::

ILODST – iloraz odchyłeń standardowych,

KOR – współczynnik korelacji,

RMS – błąd średniokwadratowy (spierwiastkowany).

## Wnioski

1. Opracowane modele neuronowe do klasyfikacji suszu w zakresie metody suszenia oraz jakości danego suszu, przy wykorzystaniu analizy obrazów, umożliwiły zidentyfikowanie charakterystycznych cech kostek do klasyfikacji.
2. Przeprowadzone w tym zakresie badania, potwierdzają zasadność stosowania tej metody jako klasyfikatora. Uzyskane wyniki z wykorzystaniem neuronowego modelu klasyfikacyjnego suszu marchwi pozwoliły dokonać wyboru cech charakterystycznych ważnych dla oceny jakościowej. Badania wskazują na duże znaczenie barwy kostki suszu oraz kształtu.
3. Przeprowadzone badania oraz analiza zbudowanych modeli neuronowych wskazują, że zadanie klasyfikacji najlepiej zrealizował perceptron z czterema warstwami i 18 neuronami w warstwie ukrytej. W trakcie procesu uczenia wszystkich sieci neuronowych wykorzystywano dwa algorytmy: wstecznej propagacji błędów oraz gradientów sprzężonych. Wybór ten umożliwiał najlepsze postępy uczenia, czego wynikiem były wartości błędu RMS. Jego zakres kształtował się w przedziałach od 0,18 do 0,4. Wyniki te świadczą o dobrej jakości procesu uczenia.
4. Uniwersalność wykorzystanego modelowania umożliwia wdrożenie tego rozwiązania w warunkach przemysłowych. Do oceny i analizy suszu niezbędna jest tylko fotografia wybranego suszu. Działanie to może zdecydowanie wyeliminować czynniki naturalnych ograniczeń, które charakteryzują człowieka, takie jak: zmęczenie, choroba, subiektywna ocena. Tak więc w znaczeniu użytecznym umożliwia to zbudowanie systemu wspomaganego decyzji w zakresie oceny i klasyfikacji suszu warzywnego.

## Bibliografia

- Kavdir I. Guyer D. E.** 2000. Apple sorting using artificial neural networks and spectral imaging. ASAE Meeting Presentation Paper Number: Vol. 45(6). ISSN 0001-2351
- Korbicz J. Obuchowicz A. Uciski D.** 1994. Sztuczne sieci neuronowe – Podstawy i zastosowania. Akad. Oficyna Wyd. RM, Warszawa. s. 35-55.
- Kosiński R. A.** 2002. Sztuczne sieci neuronowe, dynamika nieliniowa i chaos. WNT. Warszawa. s. 35-41.
- Pabis J.** 1993. Wymagania jakościowe i technologiczne surowców i suszu owoców i warzyw. Projekt badawczy KBN Nr 5 55149102. SGGW. Warszawa. s. 14-37.
- Stateczny A. Praczyk T.** 2002. Sztuczne sieci neuronowe w rozpoznawaniu obiektów morskich. Gdańskie Towarzystwo Naukowe. Gdynia. s. 139-157.
- Stępka G.** 2004. Polska liderem w uprawie marchwi. Warzywnictwo. Kraków. s. 10-18.
- Tadeusiewicz R.** 1993. Sieci neuronowe. Akad. Oficyna Wyd. RM. Warszawa. s. 34-46.
- Weres J.** 1991. Analiza wpływu materiałowych właściwości suszonego ośrodka na transport wody w procesach konwekcyjnego suszenia ziarna kukurydzy w cienkiej warstwie. Roczniki Akademii Rolniczej w Poznaniu. Rozprawa doktorska. Poznań. ISSN 0208-8436.

## **NEURAL CLASSIFICATION OF IMAGES SHOWING DRIED VEGETABLES**

**Abstract.** The purpose of this research work was to develop a neural model allowing to assess dried carrot type and to classify it on the basis of digital photographs. Three dried carrot types were analysed and classified. Their specific qualities were selected, allowing classification according to dried carrot type and quality. Completed research allowed to generate four neural models of multilayer perceptron type.

**Key words:** dried carrot, identification of images, artificial neural networks

**Adres do korespondencji:**

Krzysztof Koszela; e-mail: [koszela@up.poznan.pl](mailto:koszela@up.poznan.pl)  
Instytut Inżynierii Rolniczej  
Uniwersytet Przyrodniczy w Poznaniu  
Ul. Wojska Polskiego 50  
60-627 Poznań