

CLASSIFICATION OF DRIED PARSNIP USING ARTIFICIAL NEURAL NETWORKS

Summary

In recent years, agricultural engineers working in research have been using modern modeling tools, such as artificial neural networks, with increasing frequency. This tool, as a universal approximator together with computer image analysis is used to create empirical models that describe phenomena and processes involved in extracting and processing plant materials. Artificial neural networks are able to generalize from acquired knowledge, and this is an important feature when analysing data involving a large range of factors to determine a given process. The objective of this research work was to develop a neural model allowing the assessment of dried parsnip quality and its classification on the basis of digital photos. Obtained by the convection method, the dried parsnip was analysed and classified. Its characteristic features were chosen, allowing classification according to quality. As the result of the research, a number of generated neural models were verified and validated.

Key words: computer applications; image analysis; artificial intelligence; neural networks; dried parsnip

KLASYFIKACJA SUSZU PIETRUSZKI Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH

Streszczenie

W ostatnich latach prace naukowo-badawcze realizowane w inżynierii rolniczej coraz częściej wykorzystują nowoczesne narzędzie modelowania, jakim są sztuczne sieci neuronowe. To narzędzie, jako uniwersalny aproksymator, w połączeniu z komputerową analizą obrazów, stosowane jest do tworzenia modeli empirycznych, opisujących zjawiska i procesy występujące w pozyskiwaniu i przetwarzaniu materiałów roślinnych. Szczególną cechą sztucznych sieci neuronowych jest zdolność uogólniania nabytej wiedzy, co jest ważnym aspektem w badaniach na obiektach o dużej liczbie czynników determinujących dany proces. Celem pracy badawczej było opracowanie modelu neuronowego do oceny jakości suszu pietruszki i jego klasyfikacji na podstawie cyfrowych fotografii. Do analizy i klasyfikacji wykorzystano susz pietruszki pozyskany metodą konwekcyjną. Do modelu klasyfikacyjnego wybrano cechy charakterystyczne, które umożliwiały klasyfikację ze względu na jakość suszu. W wyniku przeprowadzonych badań wygenerowano kilka modeli neuronowych, które poddano weryfikacji i walidacji.

Słowa kluczowe: zastosowanie komputerów; analiza obrazów; sztuczna inteligencja; sieci neuronowe; susz pietruszki

1. Wprowadzenie

Powierzchnia uprawy warzyw w Polsce ulega ciągłym zmianom i przekształceniom. Każdego roku zmienia się struktura upraw poszczególnych warzyw. Jednym z podstawowych warzyw przyprawowych powszechnie uprawianych w naszym kraju jest pietruszka korzeniowa. Można wyróżnić dwie części użytkowe: korzeniową i nadziemną. Warzywo to jest rośliną dwuletnią, tworzącą w pierwszym roku uprawy bujną rozetę złożoną z 15-30 liści oraz korzeń spichrzowy. Korzeń spichrzowy jest mniej lub bardziej wydłużony, cylindryczny lub zwężający się ku dołowi. Pietruszka jako warzywo, dzięki zawartości cennych składników, cieszy się dużym popytem. Dostępna jest w sprzedaży przez cały rok w postaci świeżej, mrożonej i suszonej. Na rynku świeżych warzyw poszukiwane są przede wszystkim korzenie zdrowe, kształtne i gładkie, bez rozwidleń i bocznych odgałęzień. Popyt na ten surowiec wzrasta z uwagi na szerokie możliwości zastosowania w przemyśle spożywczym [7]. Jego dynamiczny rozwój, szczególnie przetwórstwa mięsnego, koncentratów spożywczych, warzyw, przetwórstwa produktów mlecznych oraz żywności niskotłuszczowej, stymuluje wzrost zużycia przypraw, m.in. pietruszki. Jej sezonowa dostępność jako zioła i warzywa przyprawowego, a także aspekty ekonomiczne związane z kosztami

dystrybucji (ograniczenie objętości, zmniejszenie kosztów przechowywania) stwarza konieczność utrwalania tego produktu w postaci suszu. Jedną z najczęstszych metod jest suszenie gorącym powietrzem. Pietruszka może być poddawana różnym metodom suszenia, co powoduje trudności w rzetelnej ocenie jakościowej i klasyfikacji suszu. Wśród wielu cech jakościowych suszu pietruszki, które decydują o pozytywnej lub negatywnej ocenie jakościowej, jest barwa i kształt. Można stwierdzić, że barwa żywności jest jedną z istotnych cech, gdyż na podstawie wyglądu zewnętrznego klienci i konsumenci decydują o zakupie lub spożyciu danego produktu. Właściwa barwa i odpowiedni kształt, który odpowiada tradycyjnie przyjętym normom, stanowią ważne kryteria oceny, ponieważ ich zmiany są zazwyczaj pierwszymi zauważalnymi wskaźnikami pogorszenia jakości pod względem cech sensorycznych – smaku, zapachu oraz pośrednio o wartości odżywczej [3].

Najczęściej stosowaną metodą w ocenie jakościowej suszu warzywnego w wielu przedsiębiorstwach, zajmujących się dalszym przetwarzaniem suszu, jest ocena sensoryczna. Sensoryka to interdyscyplinarna nauka, która obejmuje pomiary, interpretację oraz zrozumienie ludzkich odczuć i reakcji na właściwości produktu odbierane za pomocą zmysłów: wzroku, węchu, smaku, dotyku i słuchu. Łączy wzajemne oddziaływanie składu chemicznego i cech

fizykochemicznych produktu z cechami psychofizycznymi człowieka. Obecnie istnieje kilka możliwych sposobów pomiaru kształtu i barwy. Mogą być wykonywane przez wykwalifikowane osoby, które dokonują weryfikacji, ale są to oceny niepowtarzalne lub subiektywne. Drugą grupę stanowią metody instrumentalne za pomocą urządzeń pomiarowych. Jednak metody te są badaniami bardzo kosztownymi i nie są uniwersalne dla pomiaru kilku cech, np. kształtu i barwy [1, 3, 4, 5, 8].

Innym ważnym problemem jest skomplikowany i energochłonny proces suszenia produktów rolniczych. W szerokim zakresie prowadzone są badania, które mają na celu opracowanie technologii energooszczędnej, gwarantującej uzyskanie produktu o wysokiej jakości biologicznej i jednocześnie odżywczej [7, 9]. 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. Na barwę warzyw mają wpływ głównie: chlorofile, karotenoidy i flawonoidy. Zbyt szybkie suszenie powoduje nierównomierną utratę wody, a tym samym twardnienie i brązowienie zewnętrznych powierzchni cząstek suszu, przy jednocześnie wilgotnym wnętrzu [7].

Celem projektu badawczego było opracowanie metody z wykorzystaniem komputerowej analizy obrazów suszu pietruszki oraz sztucznych sieci neuronowych do klasyfikacji jakości poszczególnych cząstek suszu w badanej próbie.

2. Materiały i metody

Do realizacji celu pracy wybrano odmianę pietruszki Kinga (firmy Polan). Jest to odmiana późna w typie Berlińskiej (może być uprawiana z późnego siewu na zbiór pęczkowy). Cechami charakterystycznymi są: stożkowato-wydłużony korzeń, bujna, ciemnozielona nać, kora i walec osiowy – o jednolitej barwie, od białej do biało-kremowej, nie ciemniejący zwarty miąższ – aromatyczny i smaczny, skórka – biała, gładka do średnio gładkiej (rys. 1).



Rys. 1. Pietruszka odmiany Kinga w postaci surowca przed suszeniem

Fig. 1. The "King" parsnip variety in the form of raw material before drying

Odmiana ta jest rekomendowana dla przemysłu do produkcji suszu i mrozonek i to właśnie zdecydowało o jej wyborze do opisanych badań.

Materiał badawczy poddano obróbce wstępnej: myciu, obieraniu, krojeniu i blanszowaniu, a następnie suszeniu meto-

dą konwekcyjną w temp. 850°C, w czasie 200 min. Wilgotność pietruszki przed procesem suszenia wynosiła 88%, a po suszeniu zmniejszyła się do 6%.

Do badań wykorzystano odpowiednio przygotowane stanowisko do akwizycji obrazu suszu marchwi. Wyposażeniem stanowiska były: aparat cyfrowy, komora bezcieniowa, zestaw lamp oświetleniowych, statyw fotograficzny.

W celu przeprowadzenia analizy obrazów cząstek suszu warzywnego wykonano zdjęcia dla poszczególnych frakcji suszu pietruszki (rys. 2). Ustalono następujące parametry aparatu cyfrowego: tryb fotografowania manualny, oświetlenie – światło sztuczne białe, balans bieli 3000 OK, tryb wykonywania zdjęć – makro, czułość ISO – 50, ogniskowa obiektywu F-34,7 mm, przesłona f-7,8, czas otwarcia migawki 1/8 s.

Przygotowano próby liczące 1200 cząstek z każdej frakcji suszu prawidłowego, jak też nieprawidłowego, definiowanego wg PN-71/A-75101. Cząstki, odseparowane od siebie, umieszczono na jednolitym, kontrastującym tle (rys. 2).



Rys. 2. Cząstki suszu pietruszki

Fig. 2. Dried parsnip cubes

Wszystkie fotografie zapisywane były w formacie RAW a następnie konwertowane do formatu BMP w rozdzielczości (607x454). Wybór cech charakterystycznych dla suszu pietruszki był kluczowym etapem klasyfikacji przy wykorzystaniu sztucznych sieci neuronowych.

W celu dokonania klasyfikacji wytypowano następujący zbiór cech: pole powierzchni, obwód, barwę w postaci zakodowanego kanału RGB, informację o kształcie opisaną wybranymi współczynnikami kształtu. Współczynniki kształtu zestawiono w tab. 1.

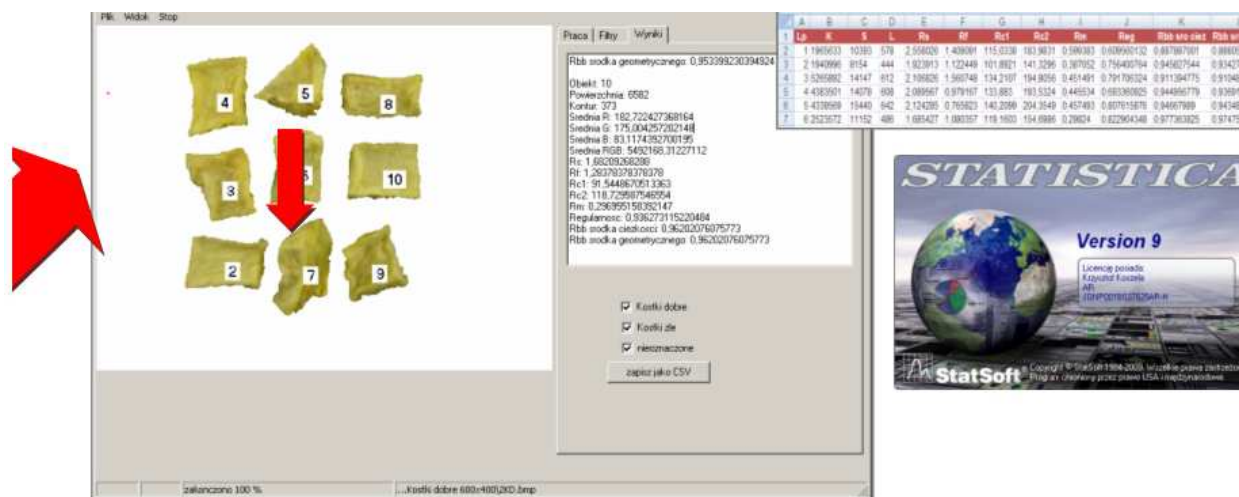
Pierwszym etapem tworzenia neuronowego modelu klasyfikacyjnego była akwizycja obrazów suszu warzywnego i transformacja na dane numeryczne. Wykorzystując autorskiego program komputerowy o nazwie „VegImage”, wygenerowano dane wejściowe dla środowiska symulatora sztucznych sieci neuronowych Statistica firmy StatSoft ver. 9.0 (rys. 3).

Zbiór danych podzielono na podzbiory: uczący, walidacyjny i testowy (tab. 2). Podczas projektowania testowaniu poddano następujące rodzaje sieci neuronowych:

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

Tab. 1. Zestawienie współczynników kształtu
 Table 1. Setting-up of shape-determining factors

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



Rys. 3. Okno programu po identyfikacji cząstek suszu pietruszki wraz wynikami (źródło: opracowanie własne)
 Fig. 3. Window presenting dried parsnip cubes after identification and the results (source: own work)

Tab. 2. Zestawienie zbiorów uczących z podziałem na zbiory (źródło: opracowanie własne)
 Table 2. Setting-up of teaching sets and their subdivision (source: own work)

Nazwa zbioru modelu neuronowego	Liczba przypadków uczących	Liczba przypadków w zbiorze uczącym	Liczba przypadków w zbiorze walidacyjnym	Liczba przypadków w zbiorze testowym
PDZZU	2400	1200	600	600

Oznaczenia: PDZZU – pietruszka „dobry” „nieprawidłowy” zbiór uczący

3. Wyniki badań

W pierwszej fazie badań najlepszym typem sieci okazał się perceptron wielowarstwowy z dziesięcioma neuronami w warstwie ukrytej (tab. 3). Dla tej sieci następnie realizowano proces uczenia. W trakcie tego procesu stosowano dwie metody: 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.

Po procesie uczenia omawiany model był weryfikowany i walidowany. W wyniku przeprowadzonych testów uzyskano następujące wyniki: dla całego zbioru poprawnie

sklasyfikowano 86,99% cząstek suszu, natomiast 13,01% model sklasyfikował niepoprawnie. Najlepsze wyniki, bo 92,66% poprawnie sklasyfikowanych cząstek, uzyskano dla cząstek o prawidłowej jakości. Natomiast większy błąd klasyfikacji uzyskano dla cząstek nieprawidłowych (tab. 4).

Kolejnym etapem była analiza wrażliwości dla wybranego modelu neuronowego. Ocena została przeprowadzona w oparciu o wszystkie cechy, które były wykorzystywane do procesu konstruowania modelu. W modelu tym odnotowano, że większość cech posiada iloraz powyżej 1, co oznacza, że w procesie modelowania ważne są wszystkie cechy. W tab. 5 zestawiono ocenę wrażliwości poszczególnych modeli.

Tab. 3. Zestawienie topologii sieci dla modelu PDZZU (źródło: opracowanie własne)
 Table 3. Setting-up of network topologies for model PDZZU (source: own work)

Numer modelu	Nazwa zbioru modelu neuronowego	Typ sieci	Liczba warstw ukrytych	Liczba neuronów w warstwach ukrytych	Liczba neuronów wejściowych	Liczba neuronów wyjściowych
1	PDZZU	MLP	1	10	11	3

Tab. 4. Zestawienie wyników klasyfikacyjnych dla modelu (źródło: opracowanie własne)
 Table 4. Setting-up of classification results for a model (source: own work)

Numer modelu	Nazwa zbioru modelu neuronowego	Wyniki	Jakość dobra	Jakość nieprawidłowa	Jakość wszystkie
1	PDZZU	Poprawne [%]	92,66	89,32	86,99
		Niepoprawne [%]	7,34	10,68	13,01

Tab. 5. Zestawienie analizy wrażliwości dla modelu (źródło: opracowanie własne)
 Table 5. Setting-up of sensitivity analysis for a model (source: own work)

	K	S	L	Rs	Rf	Rc1	Rc2	Rm	Reg	Rbbsc	Rbbsg
PDZZU											
Iloraz	1,0248	1,1322	1,0001	1,0074	1,0024	1,2237	1,0006	1,0227	1,0133	1,0446	1,0011
Ranga	4	2	11	7	8	1	10	5	6	3	9

Na podstawie analizy wszystkich modeli można zaobserwować, że w procesie klasyfikacji wysoką rangę mają współczynnik cyrkularności i współczynnik Blaira-Blissa. Jednak nie bez znaczenia jest informacja o barwie cząstki suszu.

4. Podsumowanie

Na podstawie przeprowadzonych badań i analizy ich wyników sformułowano następujące wnioski:

- Opracowany model neuronowy suszu konwekcyjnego pietruszki w zakresie klasyfikacji oraz jakości, przy wykorzystaniu analizy obrazów, umożliwił zidentyfikowanie charakterystycznych cech cząstek do klasyfikacji.
- Badania potwierdzają zasadność stosowania metody modelu neuronowego jako klasyfikatora. Uzyskane wyniki modelu klasyfikacyjnego suszu pietruszki pozwoliły na wybór cech charakterystycznych, ważnych dla oceny jakościowej, co potwierdza przeprowadzona analiza wrażliwości.
- Przeprowadzone badania oraz analiza zbudowanych modeli neuronowych wskazują, że zadanie klasyfikacji najlepiej zrealizował perceptron z trzema warstwami i 10 neuronami w warstwie ukrytej. W trakcie procesu uczenia wszystkich sieci neuronowych wykorzystywano dwa algorytmy: wstecznej propagacji błędów oraz gradientów sprzężonych. Wybór ten umożliwił najlepsze postępy uczenia, czego wynikiem były wartości błędu RMS. Jego zakres znajdował się w przedziałach od 7 do 13%. Wyniki te świadczą o dobrej jakości procesu uczenia.
- Zastosowana metoda może być zaimplementowana w warunkach przemysłowych. Niezbędna jest tylko fotografia wybranego suszu. Metoda może zdecydowanie wyeliminować czynniki naturalnych ograniczeń człowieka, takie jak: zmęczenie, choroba, ocena subiektywna. A w znaczeniu

użytecznym – umożliwi zbudowanie systemu wspomagania decyzji w zakresie oceny i klasyfikacji suszu warzywnego.

5. Bibliografia

- Kavdir I., Guyer D. E.: Apple sorting using artificial neural networks and spectral imaging. ASAE Meeting 2000, Presentation Paper Number: Vol. 45(6). ISSN 0001-23512000.
- Korbicz J., Obuchowicz A., Uciski D.: Sztuczne sieci neuronowe – Podstawy i zastosowania. Warszawa: Akad. Oficyna Wyd. RM, 1994.
- Koszela K., Weres J.: Neuronowa klasyfikacja obrazów suszu warzywnego. Inżynieria Rolnicza, 2009, Nr 8 (117).
- Koszela K., Boniecki P., Weres J.: Neural predicting of the farm product distribution exemplified by the marjoram and carrot. Journal of Research and Applications in Agricultural Engineering, 2004, Vol. 49(1).
- Koszela K., Boniecki P., Weres J.: Ocena efektywności neuronowego prognozowania w oparciu o wybrane metody na przykładzie dystrybucji produktów rolniczych. Inżynieria Rolnicza, 2005, 2(62).
- Orłowski M., Kołota E.: Uprawa warzyw. Szczecin: Wydawnictwo BRASiKa, 1999.
- Pabis J.: Wymagania jakościowe i technologiczne surowców i suszu owoców i warzyw. Projekt badawczy KBN Nr 5 55149102. SGGW Warszawa, 1993.
- Tadeusiewicz R.: Sieci neuronowe. Warszawa: Akad. Oficyna Wyd. RM, 1993.
- Weres J.: 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, 1991. ISSN 0208-8436.
- Zaborowicz M., Koszela K., Boniecki P.: Koncepcja wykorzystania sztucznych sieci neuronowych w procesie oceny jakości pomidorów. Journal of Research and Applications in Agricultural Engineering, 2011, Vol. 56(1): 147-149.