

WYBÓR REPREZENTATYWNEJ STRUKTURY ZBIORÓW UCZĄCYCH DLA POTRZEB NEURONOWYCH MODELI IDENTYFIKACYJNYCH WYKORZYSTYWANYCH W INŻYNIERII ROLNICZEJ

Krzysztof Nowakowski, Piotr Boniecki, Jerzy Weres, Wojciech Mueller
Instytut Inżynierii Rolniczej, Akademia Rolnicza w Poznaniu

Streszczenie. Wykorzystanie sztucznych sieci neuronowych do identyfikacji mechanicznych uszkodzeń ziarniaków na podstawie ich fotografii wymaga doboru odpowiednich cech charakterystycznych na podstawie, których zostanie przeprowadzony proces rozpoznawania. Ponieważ stosowanie sieci neuronowych do bezpośredniego mapowania zbiorów graficznych jest nieefektywne, wskazane jest użycie bloku przetwarzania wstępnego, tzw. preprocesora. Zaprojektowanie i wytworzenie właściwego systemu informatycznego dla tak sformułowanego celu pozwoliło na dokonanie transformacji danych pierwotnych (zdjęcia fotograficzne) do reprezentacji danych, która będzie odpowiednia dla wykorzystania w procesie uczenia sieci neuronowej.

Słowa kluczowe: reprezentatywne dane uczące, sieci neuronowe, analiza obrazu

Wprowadzenie

Przed procesem projektowania sztucznej sieci neuronowej konieczny jest wybór zmiennych, które powinny stanowić wejście sieci. Jak wybrać najlepiej spośród wszystkich dostępnych zmiennych opisujące problem? Trudność zadania wynika z kilku przyczyn. Sieci neuronowe stosuje się najczęściej wtedy, gdy niejasne są powiązania pomiędzy dostępnymi zmiennymi wejściowymi a wyjściowymi. Zwykle mamy wtedy różnorodne dane, których część oceniamy jako ważne, inne mniej, nie mając jednak, co do tego pewności. Po podjęciu decyzji dotyczącej zastosowania sieci neuronowych do rozwiązania określonego problemu należy zebrać dane niezbędne w procesie uczenia. Zbiór danych uczących zawiera pewną liczbę przypadków, z których każdy zawiera wartości dostępnych zmiennych wejściowych. Pierwsze z podejmowanych strategicznych decyzji muszą określać, które zmienne powinny zostać uwzględnione oraz ile a także, jakie przypadki należy zgromadzić. Wybierając zmienne (przynajmniej początkowy ich zestaw) użytkownik kieruje się na ogół intuicją. Posiadana przez niego znajomość specyfiki badanych zagadnień jest podstawą do pewnych wyobrażeń dotyczących wyboru sygnałów oddziałujących na wyjścia sieci, którym zamierzamy nadać status zmiennych wejściowych. Przy pierwszej próbie tworzenia sieci neuronowych właściwych dla rozwiązania określonego zadania, użytkownik powinien uwzględnić wszystkie zmienne, które, według niego, mogą mieć istotne znaczenie [Tadeusiewicz i in. 1991]

Projekt badawczy

Realizowany projekt badawczy ma za zadanie identyfikację mechanicznych uszkodzeń ziarniaków kukurydzy za pomocą sztucznej sieci neuronowej. Do identyfikacji, z uwagi na wykorzystanie systemu wizyjnego, wybrano charakter ubytków ziaren w postaci makrouszkodzeń. W uproszczeniu można powiedzieć, że jeżeli uszkodzenie ziarna polega na widocznej utracie jego części bądź deformacji pierwotnego kształtu, jest to makrouszkodzenie. W szczególności mowa tu o rozdrobnieniu, zgnieceniu i pokaleczeniu ziarniaków. Po przeglądzie literatury tematu i dokonano wyboru trzech cech reprezentatywnych, którymi są:

- barwa (model RGB),
- pole powierzchni,
- kształt ziarniaka (opisany za pomocą współczynników kształtu).



Źródło: Fotografia autora

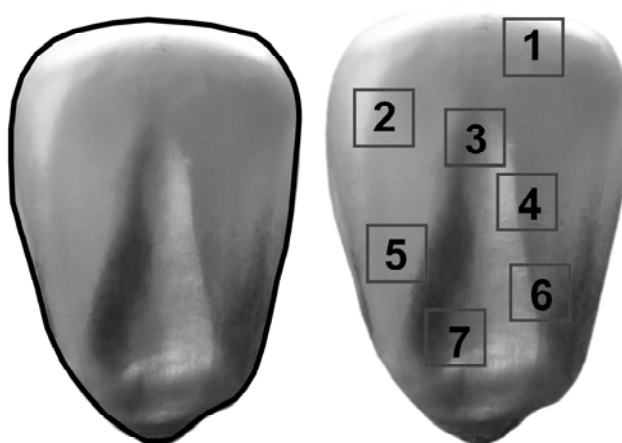
Rys. 1. Ziarniak kukurydzy

Fig. 1. Corn grains

Pierwszą wybraną cechą jest kolor ziarniaka. Jest to parametr, który łatwo można przedstawić w postaci numerycznej wykorzystując model RGB. Niestety, taki zapis wiąże się dużą liczbą danych dla pojedynczego przypadku uczącego (dotyczących tylko tej jednej cechy). Liczba ta może przekroczyć możliwości techniczne symulatora wykorzystywanego do procesu uczenia sieci. Konieczną jest, więc albo kompresja danych, co niestety niesie ze sobą ryzyko utraty informacji, albo podział obiektu na mniejsze obszary [Malina i in. 2005].

Autorzy w swojej pracy proponują zapis danych do zbioru uczącego na dwa sposoby (rys. 2.):

- zapis informacji o barwie dla całego ziarniaka (jeden przypadek uczący) i późniejsza redukcja jego rozmiaru, np. przy pomocy algorytmu PCA,
- zapis informacji o barwie dla wybranego fragmentu obrazu o wcześniej zdefiniowanym rozmiarze, np. 8x8, 16x16 pikseli.



gdzie 1,2,3..., 7 – pola o rozmiarze 16 × 16 pikseli

Źródło: zrzut ekranowy z aplikacji

Rys. 2. Metody zapisu barwy

Fig. 2. Colour recording method

W związku z przyjętym modelem koloru RGB informacja o barwie piksela złożona jest z trzech podstawowych składowych.

W trybach o większej liczbie kolorów niż 256 paleta nie występuje, a kolor piksela w obrazie zapisywany jest przy pomocy numeru kolejnego koloru, który jest wyliczany ze wzoru (1).

$$\text{numer_koloru} = R + 2^8 * G + 2^{16} * B \quad (1)$$

Kolejną wybraną cechą jest pole powierzchni ziarniaka. Definiowane przez liczbę pikseli, jaką wypełniony jest obiekt. Jest to kolejny składnik przypadku uczącego. Żeby wykorzystać tę cechę jako zmienną uczącą konieczne było znormalizowanie rozmiaru analizowanego obrazu w celu uzyskania wiarygodnych wyników. Wszystkie zdjęcia ziarniaków zostały przeskalowane do rozdzielczości 256 na 256 pikseli (rys. 3).



Źródło: zrzut ekranowy z aplikacji

Rys. 3. Wyznaczanie pola powierzchni
Fig. 3. Determination of area

Ostatnią wybraną cechą jest kształt. Zapisywany jest do zbioru uczącego pod postacią 4 współczynników kształtu. Pierwszy definiowany jest jako stosunek wysokości ziarniaka do jego szerokości i mierzona jest w maksymalnych mierzonych wartościach. Kolejne dwa to współczynnik cyrkularności. Współczynnik W_1 (2) jest jednym z dwóch wykorzystanych współczynników cyrkularności. Wyznacza on średnicę koła o obwodzie równym obwodowi analizowanego obiektu. Drugi współczynnik W_2 (3) wyznacza średnicę, koła, którego pole równe jest polu analizowanego obiektu.

$$W_1 = \frac{L}{\pi} \quad (2)$$

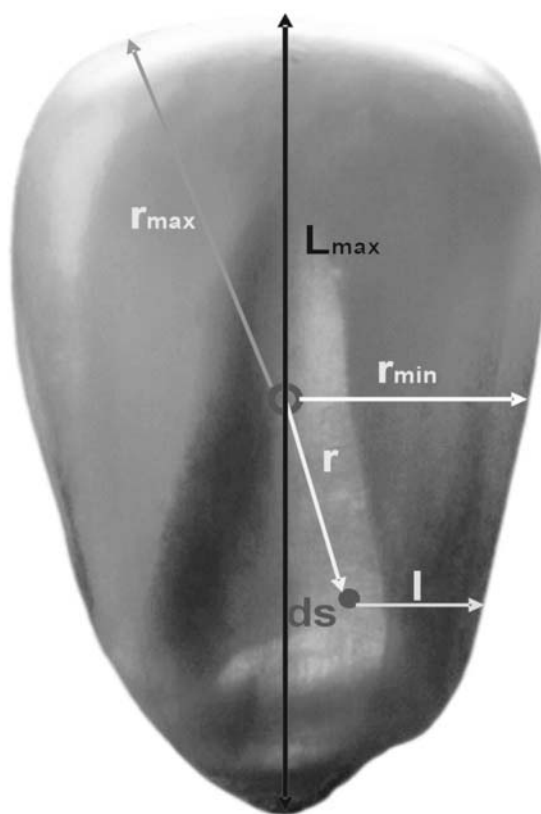
$$W_2 = 2 * \sqrt{\frac{S}{\pi}} \quad (3)$$

gdzie:

- s – pol powierzchni analizowanego obiektu,
- L – obwód analizowanego obiektu.

Współczynników W_1 i W_2 nie rozpatruje się oddzielnie. Są one silnie zależne od wielkości obiektu i w związku z tym bez przeprowadzenia normalizacji mają niewielkie zastosowanie w trakcie analiz obrazu. Aby zniwelować znaczenie normalizacji wprowadza się wielkość zwaną współczynnikiem cyrkularności W_3 (4). Współczynnik W_3 jest także zwany współczynnikiem Malinowskiej

$$W_3 = \frac{L}{2 * \sqrt{\pi * S}} - 1 \quad (4)$$



gdzie:

- r_{\max} – maksymalny promień obiektu,
- r_{\min} – minimalny promień obiektu,
- L_{\max} – maksymalna długość obiektu,
- ds – wybrany punkt,
- r – odległość od środka obiektu do wybranego punktu
- l – najkrótsza odległość od wybranego punktu do krawędzi

Źródło: zrzut ekranowy z aplikacji

Rys. 4. Podstawowe wymiary wykorzystywane do obliczania współczynników kształtu

Fig. 4. Basic dimensions used for shape coefficient calculations

Tak przygotowane dane są zapisywane przez system do pliku, który posłuży jako zbiór uczący dla sztucznych sieci neuronowych. Projektowanie i trening sieci neuronowych przebiega w symulatorze *SSN Statistica v.7.0*.

Podsumowanie

Wykorzystanie analizy obrazu do identyfikacji oraz ekstrakcji reprezentatywnych cech makrouszkodzeń ziarniaków, pozwoliło na przygotowanie zbiorów uczących zawierających adekwatne dane empiryczne. Zastosowanie różnych metod zapisu obrazu do zbioru uczącego pozwoliło na redukcję rozmiaru przypadku uczącego bez istotnego wpływu na jakość uczenia. Zrealizowany został, więc cel projektu, jakim była, ekstrakcja wybranych cech reprezentatywnych: koloru, kształtu i pola powierzchni oraz uzyskanie reprezentatywnego zbioru informacji o ziarniaku zapisanego w możliwie najmniejszym wymiarze.

Bibliografia

- Tadeusiewicz R., Flasiński M. 1991. Rozpoznawanie obrazów – PWN Warszawa. s. 4-50.
Malina W., Smiatacz M. 2005. Metody cyfrowego przetwarzania obrazów. Wyd. EXIT. s. 1-40.
Choraś R. 2005. Komputerowa wizja. Metody interpretacji i identyfikacji obiektów. Wyd. EXIT. s. 10-30.

SELECTION OF REPRESENTATIVE STRUCTURE OF LEARNING SETS FOR PURPOSE OF NEURON IDENTIFICATION MODELS USED IN AGRICULTURAL ENGINEERING

Summary. Use of artificial neural networks for identification of the mechanical damages to grains based on photographs requires a selection of appropriate characteristic features in order to conduct a recognition process. Since the application of neural networks for direct mapping of graphic sets is not really effective, it is recommended to use the initial processing block, so called preprocessor. Design and creation of a proper information system for this particular purpose allowed to transform raw data (photographic images) for data representation, appropriate to be used in the learning process of neural network.

Key words: representative learning data, neural networks, analysis of image

Adres do korespondencji:

Krzysztof Nowakowski; e-mail: krzysztof.nowakowski@wsnhid.pl
Instytut Inżynierii Rolniczej w Poznaniu
ul. Wojska Polskiego 50
60-627 Poznań