

Metody pozyskiwania zbiorów uczących dla modelu neuronowego identyfikującego uszkodzenia ziarniaków

Streszczenie

Założeniem projektu wykonywanego przez autora była identyfikacja mechanicznych uszkodzeń ziarniaków za pomocą sztucznej sieci neuronowej wykorzystującej wcześniej wybrane cechy ziarniaka. Ponieważ do identyfikacji uszkodzeń wykorzystane zostały fotografie cyfrowe ziarniaków postanowiono wytworzyć system informatyczny, który wykorzystując metody analizy obrazu pozwala pozyskać z fotografii cechy, które umieszczone zostaną w zbiorach uczących sztucznych sieci neuronowych. Transformacja danych do takiej reprezentacji jest konieczna ze względu na niemożliwość odwzorowywania przez sieci neuronowe graficznych zbiorów wielowymiarowych.

Wprowadzenie

Jedną z najtrudniejszych decyzji, koniecznych przed procesem projektowania sztucznej sieci neuronowej jest wybór, spośród wszystkich dostępnych zmiennych opisujących problem, tych, które powinny stanowić wejście sieci. Trudność ta wynika z kilku powodów. W praktyce, sieci neuronowe stosuje się wtedy, gdy niejasne są powiązania pomiędzy dostępnymi zmiennymi wejściowymi a wyjściowymi. Zwykle mamy wtedy różnorodne dane, których część oceniamy jako ważne, inne mniej ważne, nie mając jednak, co do tego pewności. Kiedy wybór zostanie dokonany może zaistnieć sytuacja, w której pozyskane dane nie nadają się bezpośrednio na zbiory uczące sieci. Dokonując transformacji danych należy pamiętać, aby ich przekształcona postać niosła za sobą takie same informacje jak pierwotna. W przypadku obróbki obrazów do ekstrakcji pożądanych cech najefektywniejszą metodą jest analiza obrazu. Dużą zaletą jest łatwość pozyskania obrazów dzięki popularnym dziś różnym systemom wizyjnym. Podczas tego procesu wybrane cechy zapisywane są, za pomocą specjalnie wytworzonego, w ramach projektu systemu informatycznego, do postaci zbiorów uczących sieci.

Realizacja projektu badawczego

Celem projektu badawczego, realizowanego przez autora, była identyfikacja mechanicznych uszkodzeń ziarniaków za pomocą sztucznej sieci neuronowej, wykorzystującej w procesie uczenia wybrane cechy reprezentatywne. Po zapoznaniu się z dostępną literaturą na temat identyfikacji uszkodzeń ziarniaków dokonano wyboru następujących cech:

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


Aby wszystkie te cechy można było ekstrahować jednocześnie a następnie zapisywać do jednego zbioru uczącego, wytworzono oprogramowanie wspomagające przygotowanie zbiorów uczących. Kolejność operacji realizowanych przez zaprojektowany oraz wytworzony system informatyczny pokazano na rys. 1.

W celu efektywnego wykorzystania obrazu jako źródła informacji należy przetworzyć go na postać cyfrową, a następnie przeprowadzić jego szczegółowy proces analizy w skład, którego wchodzi: segmentacja, lokalizacja obiektów oraz wyznaczanie ich cech. System dopuszcza również przed rozpoczęciem tego procesu polepszenie jakości obrazu, a w


szczególności jego filtracje (eliminacja zakłóceń) oraz wyostrzenie. Dodatkowo możliwa jest automatyczna regulacja położenia i wielkości badanego obiektu w kadrze, co pozwala na maksymalne wykorzystanie informacji, jaką możemy uzyskać z systemu wizyjnego.

Jako pierwsza cecha wyznaczona zostaje barwa ziarniaka używając notacji RGB piksel po pikselu cały obiekt zostaje zapisany do zbioru uczącego. W celu ograniczenia rozmiarów pojedynczego przypadku uczącego postanowiono podzielić identyfikowany obiekt na segmenty. Takie podejście pozwala na 3 metody zapisu (rys. 2.) informacji o barwie:


- 1) zapis bez podziału obiektu na segmenty jeden przypadek uczący zawiera informacje o barwie całego obiektu,
- 2) zapis z podziałem na segmenty nabadowane na obiekt po wybraniu wcześniej przez użytkownika systemu rozmiaru segmentu (możliwe 8x8, 16x16, 32x32 piksele) na obiekcie zostają nabadowane segmenty. Jeden przypadek uczący zawiera informacje o barwie pojedynczego segmentu,
- 3) zapis z podziałem na segmenty po wybraniu przez użytkownika rozmiaru segmentu, cały obraz zostaje podzielony. Do zbioru uczącego zapisywane są tylko informacje o barwie zlokalizowanego obiektu, reszta obrazu to 0. Jeden przypadek uczący zawiera informacje o barwie obiektu występującego w segmencie.



Rys. 1. Uproszczony schemat działania aplikacji przygotowującej zbiory uczące dla potrzeb edukacji sztucznych sieci neuronowych



Rys. 2. Metody zapisu barwy



Rys. 3. Pomiar jednego ze współczynników kształtu

Kolejną cechą, jaką wyselekcjonowano, jest pole powierzchni definiowane przez liczbę pikseli, jaką wypełniony jest obiekt. Jest to kolejny składnik przypadku uczącego. Trzecia cecha zapisywana do zbioru uczącego to kształt. Korzystając ze sprawdzonych metod analizy obrazu wybrano 4 współczynniki kształtu opisujące ziarniaka.

Pierwszy definiowany jest jako stosunek wysokości ziarniaka do jego szerokości i wyznaczana jest w maksymalnych mierzonych wartościach.

Kolejne dwa to współczynnik cyrkularności. Współczynnik W1 (1) jest jednym z dwóch wykorzystanych współczynników cyrkularności. Wyznacza on średnicę koła o obwodzie równym obwodowi analizowanego obiektu:

$$R_{C1} = 2 \cdot \sqrt{\frac{S}{\pi}} \quad (1)$$

Drugi współczynnik W2 (2) wyznacza średnicę koła, którego pole równe jest polu analizowanego obiektu:

$$R_{C2} = \frac{L}{\pi} \quad (2)$$

Współczynników W1 i W2 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 W3 (rys. 3). Współczynnik W3 jest także zwany współczynnikiem Malinowskiej:

$$R_M = \frac{L}{2 \cdot \sqrt{\pi \cdot S}} - 1 \quad (3)$$

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*. Zbiory uczące mogą podlegać dalszej obróbce np.: zmniejszaniu ilości zmiennych przy pomocy SSN uczonej algorytmem PCA, badaniu poziomu istotności zmiennych na jakość identyfikacji przy pomocy algorytmów genetycznych.

Wnioski

W trakcie wykonanych badań symulacyjnych nasunęły się następujące uwagi:

1. Zastosowanie wytworzonego systemu informatycznego pozwoliło na przekształcenie danych prezentowanych w postaci cyfrowych zdjęć do reprezentacji danych, która jest odpowiednia dla wykorzystania w procesie uczenia sieci neuronowej;
2. Wykorzystanie analizy obrazu do identyfikacji oraz ekstrakcji reprezentatywnych cech pozwoliło na przygotowanie zbiorów uczących zawierających adekwatne dane;
3. Wykorzystanie różnych metod zapisu obrazu do zbioru uczącego pozwala na redukcję rozmiaru przypadku uczącego bez istotnego wpływu na jakość uczenia.

Literatura

- [1] Tadeusiewicz R., Flasiński M. (1991): Rozpoznawanie obrazów PWN Warszawa 1991
- [2] Ryszard S. Choraś: Komputerowa wizja. Metody interpretacji i identyfikacji obiektów - Wydawnictwo EXIT 2005
- [3] Marciniak A., Korbicz J. : Diagnostowanie dynamicznych obiektów nieliniowych z wykorzystaniem statycznych sieci neuronowych. Mat. XIII Krajowej Konferencji Automatyki 1999
- [4] Malina W., Smiatcz M.: Metody cyfrowego przetwarzania obrazów Wydawnictwo EXIT 2005.

Method of learning sets extraction for identification neural model of kernel damages

Summary

Foundation of project executed by author was identification of mechanical kernel damages by using the artificial neural networks which make use of earlier chosen kernel features. Because identification of damages was made on the basis of digital photos of kernels, author decided to elaborate computer system, which using methods of image analysis permits to gain from photo, the features which will be put in learning sets of artificial neural network. The transformation of data to such representation is necessary for the sake of impossibility of imitating through neural network of graphic multidimensional sets.