

KONWERSJA OBRAZÓW CYFROWYCH DO POSTACI ZBIORÓW UCZĄCYCH DLA POTRZEB MODELOWANIA NEURONOWEGO

Andrzej Przybylak, Piotr Boniecki, Krzysztof Nowakowski

Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu

Streszczenie. Wykorzystanie sztucznych sieci neuronowych na potrzeby analizy obrazu wymaga prawidłowego przygotowania zbiorów uczących. W przypadku pozyskiwania informacji z obrazów cyfrowych konieczna jest ich konwersja do postaci akceptowanej przez sztuczną sieć neuronową. Niezwykle istotne jest, aby do struktury zbioru uczącego trafiły cechy reprezentatywne, pozwalające na poprawne działanie modelu neuronowego. W przedstawionym w pracy systemie użytkownik ma możliwość wyboru danych, które umieści w zbiorze uczącym. W aktualnej wersji systemu mogą to być informacje o barwie, na które składają się: histogram, tekstura oraz składowe modelu RGB.


Słowa kluczowe: przetwarzanie i analiza obrazu, piksel, zbiór uczący, sieci neuronowe

Wstęp

Obraz coraz częściej staje się źródłem informacji wykorzystywanych w wielu zastosowaniach praktycznych. Pozyskanie zdjęć obiektów nie stanowi obecnie problemu. Aby efektywnie wykorzystać dane zawarte w obrazie (często niemożliwe dla wykrycia przez człowieka), należy je przed przystąpieniem do procesu analizy odpowiednio przetworzyć. Aby obraz mógł być analizowany przez urządzenie cyfrowe np. komputer, musi on być przetworzony z postaci analogowej na postać cyfrową. Dokonuje się tego przez dyskretyzację i kwantyzację obrazu. Operacje te są wykonywane przez specjalizowane urządzenia wejściowe, takie jak skanery, karty wizyjne, aparaty cyfrowe itp. [Malina 2005].

Oba procesy: przetwarzanie i analiza mają na celu zbudowanie zbioru danych, tzw. zbioru cech reprezentatywnych, które to cechy w dalszym etapie posłużą do budowy modeli neuronowych. Informacje zawarte w zbiorach uczących mają bezpośredni wpływ na jakość wytworzonych modeli neuronowych.

Celem pracy jest wytworzenie zbiorów uczących do generowania sztucznych sieci neuronowych przeznaczonych do identyfikacji poziomu zawartości tłuszczu śródmięśniowego wybranych zwierząt gospodarskich w oparciu o informacje zakodowaną w postaci zdjęć ultrasonograficznych oraz zdjęć przekroi tusz poubojowych. Aby tego dokonać konieczne było zbudowanie systemu informatycznego IMG.2.CSV, który wykorzystując metody analizy oraz przetwarzania obrazów cyfrowych, umożliwi pozyskanie zbioru reprezentatywnych danych empirycznych.



Rys. 1. Schemat ideowy działania systemu do przetwarzania i analizy obrazu (IMG.2.CSV)
 Fig. 1. Schematic diagram showing operation of a system for image processing and analysis

Przetwarzanie obrazów cyfrowych

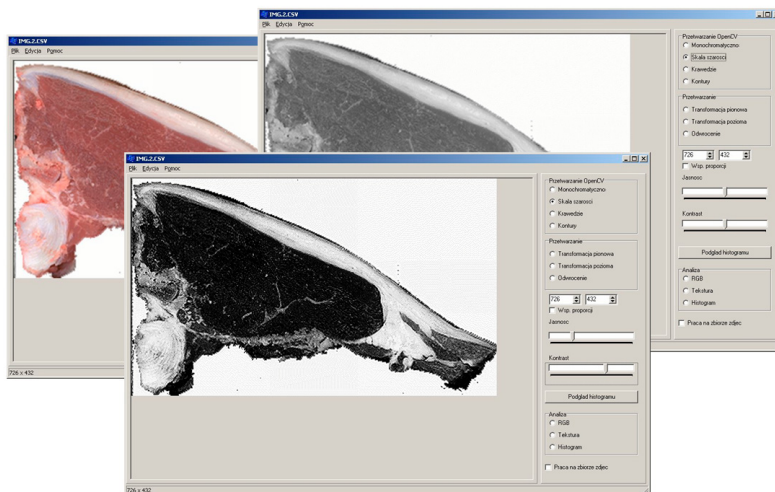
Zdjęcia cyfrowe pozyskane w procesie akwizycji obrazu można poddać przetwarzaniu w celu: uzyskania jak najlepszej jakości materiału do dalszej analizy, ujednoczenia kluczowych parametrów (np. rozdzielczość, kontrast, jasność), eliminacji zbędnych danych, filtracji wstępnej, eliminacji zakłóceń, zastosowania kompresji obrazu, wyeksponowania ważnych cech, pozycjonowania oraz selekcji kluczowego fragmentu materiału. Możliwe jest to dzięki przekształceniom geometrycznym, punktowym lub morfologicznym. Przykładowe przekształcenia pokazano na rys. 2, gdzie przedstawione zostały kolejne etapy uwydatniania cech charakterystycznych obrazu.

Elementarne operacje na obrazie dokonywane są na pojedynczych pikselach, bez uwzględnienia ich sąsiedztwa (tzw. operacje bezkontekstowe). Przyjmując założenie, że dane o obrazie przechowywane są w tablicy $M \times N$, której elementy przyjmują wartości od 0 do 255. Każdemu pikselowi obrazu odpowiada określony element tablicy. Przykładowa zmiana jasności polegać będzie na dodaniu (lub odjęciu) zadanych wartości do poszczególnych elementów.

Do podstawowych zadań analizy należy segmentacja obrazu. Jest to podział obrazu na obszary spełniające pewne kryteria jednorodności. Wyznaczona zostaje spójna grupa punktów obrazu mających pewną wspólną cechę, która nie występuje poza najbliższym sąsiedztwem. Najprostszą metodą wydzielenia obszarów jest progowanie, czyli porównywanie wartości każdego punktu obrazu z zadaną wartością progową. Przykładem może tu być binaryzacja. Punktom tworzącym tło zostaje przypisana biel, natomiast punktom obiektu znajdującego się na obrazie przypisana zostaje czerń. Możliwe jest zdefiniowanie wielu wartości progowych. Rezultatem tego typu przekształceń jest obraz, który może być łatwiejszy do dalszej analizy [Tadeusiewicz 1991].

Bardziej skomplikowanym narzędziem, niż wspomniane powyżej przekształcenia jednopunktowe, są filtry cyfrowe. Filtry korzystają z operacji kontekstowych, gdzie do wyznaczenia wartości jednego piksela należy dokonać obliczeń na wielu sąsiednich pikselach

w obrazie źródłowym. Przykładowe wykorzystanie filtrów to: poprawa ostrości obrazu, usunięcie określonych wad obrazu, poprawa obrazu o złej jakości technicznej, redukcja szumu w obrazie. Wyróżniamy filtry liniowe i nieliniowe. Filtrację można również stosować do wykrywania krzywych.



Rys. 2. Przykład przygotowania zdjęcia do analizy
Fig. 2. An example of preparing images for analysis

Wytworzony system informatyczny IMG.2.CSV wykorzystuje wieloplatformową bibliotekę *OpenCV*, która jest zbiorem funkcji wykorzystywanych podczas obróbki obrazu (oparta o otwarty kod i zapoczątkowana przez Intel). Po przetworzeniu zdjęcia cyfrowego, użytkownik ma możliwość zapisania wynikowego obrazu, względnie przejścia do analizowania z pominięciem zapisu do pliku.

Analiza obrazu cyfrowego

Z uwagi na zastosowanie omawianego systemu IMG.2.CSV, największy nacisk położony został na pracę nad zdjęciami w skali odcieni szarości, jednak funkcjonalność systemu pozwala również na pracę z obrazami w pełnej palecie RGB.

Na chwilę obecną system dokonuje analizy pod kątem barwy badanego obrazu. Możliwy jest zapis składowych modelu *RGB*, gdzie informacja o kolorze w punkcie x, y opisana jest za pomocą trzech składowych: $R(x, y)$, $G(x, y)$, $B(x, y)$.

Każda składowa zakodowana jest za pomocą ośmiu bitów (jednego bajtu). Każdy z kolorów podstawowych może przyjąć dowolną z 256 wartości, co oznacza, że łączna liczba możliwych do zakodowania barw wynosi 16,7 mln.

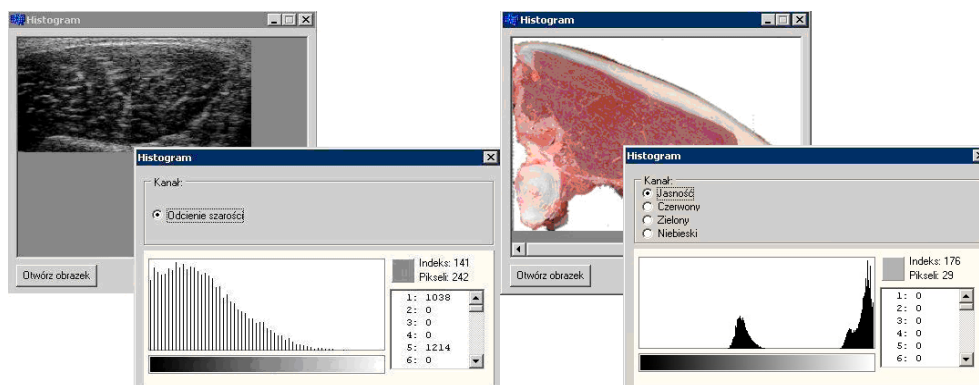
System IMG.2.CSV pozwala na pewną swobodę w sposobie wyboru kodowania danych. Z racji tego, że w przypadku grafik nawet niewielkich rozmiarów zapis informacji o każdym pikselu powodowałby utworzenie ogromnej ilości zależnych od siebie danych

w zbiorze wynikowym (przykładowo w wyniku analizy obrazu o rozdzielczości 20×20 pikseli wynikiem byłby zbiór uczący składający się z 400 zmiennych) dodany został moduł uśredniający wartości sąsiadujących pikseli. Dostępne są następujące uśrednienia: od 2×2 do 20×20 pikseli. Możliwy jest również zapis bez uśredniania.

Zbliżona do uprzednio omawianej jest analiza tekstury badanego obiektu. Różnica tkwi w dodaniu do informacji o kolorze współrzędnych danego piksela (lub współrzędnych piksela początkowego i końcowego w przypadku obiektu uśrednionego).

O tym, jak licznie występują w obrazie punkty o różnych poziomach jasności, można dowiedzieć się na podstawie histogramu, który reprezentuje globalną informację o obrazie.

W przypadku analizy rozkładu cech w pliku wynikowym znajdować się będzie (w zależności od rodzaju zdjęcia – jego palety barw) zapis wartości histogramu. Domyślnie zapisywanych jest 256 zmiennych (w przypadku zdjęć kolorowych ilość zmiennych wzrasta trzykrotnie), jednak użytkownik ma możliwość redukcji danych do odpowiednio 128, 64 lub 32 zmiennych.



Rys. 3. Przykład histogramów dla grafiki w skali odcieni szarości oraz o pełnej paletce RGB
 Fig. 3. Example of grayscale and full RGB palette image's histograms

Dodatkowo dostępny jest moduł wizualizacji rozkładu poszczególnych składowych RGB. Wyświetlane informacje zależą od rodzaju wczytanej grafiki. Wygenerowany (na podstawie zdjęcia) histogram obrazuje rozkład udziału poszczególnych składowych barw obrazu. W przypadku zdjęć zrealizowanych w skali szarości, wykres ten przedstawia informację o liczbie pikseli danego odcienia, występującego w obrazie (np: dla prezentowanego zdjęcia USG na rys. 3, dominują wartości odpowiadające zakresowi 0-127, gdzie: 0 = czarny, 255=biały). Dla zdjęć w pełnej paletce *RGB* dostępne są wykresy udziału poszczególnych składowych oraz jasności.

Tworzenie zbiorów uczących

Wykorzystując system informatyczny IMG.2.CSV można wytworzyć zbiory uczące dla sieci neuronowych. Podstawę do ich budowy stanowią zbiory danych empirycznych w postaci plików .csv (rys. 4.)

Konwersja obrazów cyfrowych...

Rys. 4. Przykłady utworzonych plików .csv zawierających dane do zbiorów uczących
 Fig. 4. Examples of generated .csv files that contains data for datasets

Wartą podkreślenia jest możliwość zautomatyzowania procesu generowania tych zbiorów. Użytkownik systemu ma możliwość m.in. wyboru zbioru danych graficznych i wskazania jednej z dostępnych analiz (w tym przypadku niedostępna jest analiza z opcją ręcznego wyboru fragmentów zdjęć). Tak przygotowane zbiory danych zawierające dane wejściowe dla sieci neuronowej wymagają jeszcze w przypadku uczenia z nauczycielem, dodania wartości wyjściowej (odpowiedzi) sieci neuronowej. Edycja zbioru danych możliwa jest zarówno za pomocą modułu zaimplementowanego w system IMG.2.CSV, jak również posługując się zewnętrznym edytorem tekstu lub arkuszem kalkulacyjnym.

	51	52	53	54	55	56	57	58	59	60	61	62	63	64	65
1	73	55	65	44	61	45	32	19	11	11	21	0	4	0	2,71
2	88	81	83	95	71	39	42	41	32	22	21	19	37	0	4,4
3	0	0	0	0	0	0	0	0	0	0	0	0	0	0	6,15
4	22	27	21	10	7	10	5	6	3	3	2	3	0	0	3,43
5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	3,00
6	22	17	10	10	4	5	1	0	1	0	0	0	0	0	2,03
7	49	37	18	24	20	15	15	17	10	7	8	5	1	0	3,37
8	13	3	4	0	0	0	0	0	0	0	0	0	0	0	3,28
9	42	42	39	30	47	18	19	14	4	11	9	14	20	0	3,22
10	44	53	40	11	9	9	0	6	4	0	0	0	0	0	3,43

Zmienne wejściowe (64szt.) Zmienna wyjściowa

Wyjście:
zawartość
tłuszczu

Wyjście: histogram obrazu

Rys. 5. Przykładowy fragment zbioru uczącego
 Fig. 5. An example of a teaching set fragment

Wygenerowane zbiory uczące mogą następnie podlegać dalszej obróbce, np. kompresji zmiennych wejściowych, np.: przy pomocy algorytmów genetycznych lub redukcji zmiennych skorelowanych z wykorzystaniem metody PCA [Boniecki 2008].

Uwagi końcowe

Zbiory uczące, przygotowane przy pomocy wytworzonego systemu informatycznego IMG.2.CSV, umożliwiły rozpoczęcie kolejnego etapu prac dotyczących budowy systemu informatycznego przeznaczonego do identyfikacji stopnia przetłuszczenia śródmięśniowe-

go wybranych zwierząt gospodarskich. Wygenerowany (na podstawie zbiorów uczących) model neuronowy typu MLP wykazał zadowalające zdolności klasyfikacyjne, pozwalające m.in. na orientacyjną identyfikację zawartości tłuszczu u żywych zwierząt. Należy podkreślić, że rodzaj i struktura danych zawartych w zbiorach uczących ma kluczowe znaczenie dla efektywności działania wytworzonego (na ich podstawie) modelu neuronowego.

Bibliografia

- Boniecki P.** 2008. Elementy modelowania neuronowego w rolnictwie. Wydawnictwo Akademii Rolniczej im. Augusta Cieszkowskiego w Poznaniu. ISBN 978-83-7160-473-7.
- Malina W., Smiatacz M.** 2005. Metody cyfrowego przetwarzania obrazów. Akademicka oficyna Wydawnicza EXIT. Warszawa. ISBN 83-87674-93-1.
- Tadeusiewicz R., Flasiński M.** 1991. Rozpoznawanie obrazów – PWN Warszawa. ISBN 83-01-10558-5.

CONVERSION OF DIGITAL IMAGES INTO THE FORM OF TEACHING SETS FOR THE PURPOSES OF NEURAL MODELLING

Abstract. Using artificial neural networks for image analysis purposes requires proper preparation of teaching sets. In case of information acquisition from digital images it is necessary to convert them into the form accepted by an artificial neural network. It is extremely important to incorporate representative features allowing correct operation of neural model into the teaching set structure. In the system presented in this work user is able to select data, which will be included in the teaching set. In current system version this may be information on colour, which includes: histogram, texture and the RGB model components.

Key words: image processing and analysis, pixel, teaching set, neural networks

Adres do korespondencji:

Andrzej Przybylak; andrzej.przybylak@up.poznan.pl
Uniwersytet Przyrodniczy w Poznaniu
Instytut Inżynierii Rolniczej
ul. Wojska Polskiego 50
60-637 Poznań