

WPŁYW KOMPRESJI BARW NA DZIAŁANIE NEURONOWEGO MODELU IDENTYFIKACYJNEGO

Krzysztof Nowakowski, Piotr Boniecki, Andrzej Przybylak
Instytut Inżynierii Rolniczej, Uniwersytet Przyrodniczy w Poznaniu

Streszczenie. Analiza wrażliwości wytworzonego modelu neuronowego wskazała na kluczową rolę w procesie identyfikacji, informacji o kolorze ziarniaka. postanowiono sprawdzić wpływ kompresji kolorów na jakość działania neuronowego modelu identyfikacyjnego. Zaproponowano dwa autorskie sposoby kompresji informacji o kolorze ziarniaków. Obydwie metody znacząco zmniejszyły rozmiar wektora uczącego. Wyniki działania neuronowego modelu identyfikacyjnego, w oparciu o zmodyfikowane zbiory uczące, okazały się znacząco gorsze od modelu wytrenowanego na zbiorach uczących zawierających pełną informację o barwie.

Słowa kluczowe: neuronowa analiza obrazu

Wprowadzenie

Zaprezentowany w pracy Nowakowskiego i Bonieckiego neuronowy model służy do identyfikacji mechanicznych uszkodzeń ziarniaków kukurydzy na podstawie ich cyfrowych obrazów [Nowakowski, Boniecki 2007]. Wytworzony model funkcjonuje w oparciu o dwie technologie: komputerową analizę obrazu i sztuczne sieci neuronowe. Pierwsza z technologii analizuje cyfrowy obraz ziarniaków. Pozyskane w ten sposób informacje zapisywane są do postaci zbiorów uczących. Sztuczne sieci neuronowe na podstawie zbiorów uczących przeprowadzają proces identyfikacji uszkodzeń ziarniaków kukurydzy. W trakcie prac na modelem wyłoniony został zestaw cech charakterystycznych, dzięki którym możliwa jest identyfikacja makrouszkodzeń. Zmienne wejściowe sieci neuronowej zawierają informację o kształcie i barwie ziarniaków. Kształt ziarniaków opisują współczynniki kształtu. Z wielu znanych współczynników przyjęto te, które pomagają identyfikować kształty zbliżone do okręgu. Pierwszy z wybranych współczynników kształtu to bezwymiarowy współczynnik R_s do ilościowej charakterystyki kształtu obiektów:

$$R_s = \frac{L^2}{4\pi S} \quad (1)$$

gdzie:

- L – obwód obiektu,
- S – pole obiektu.

Kolejny to współczynnik Fereta (R_F) w literaturze nazywany również średnicami Fereta charakteryzujący wydłużenie obiektu:

$$R_F = \frac{L_N}{L_V} \quad (2)$$

gdzie:

- L_N – maksymalny rozmiar obiektu w pionie,
- L_V – maksymalny rozmiar obiektu w poziomie.

Dwa współczynniki cyrkularności R_{C1} i R_{C2} :

$$R_{C1} = 2\sqrt{\frac{S}{\pi}} \quad (3)$$

$$R_{C2} = \frac{L}{\pi} \quad (4)$$


Pierwszy z wyżej wymienionych (3) określa średnicę koła o obwodzie równym obwodowi analizowanego obiektu, drugi (4) natomiast średnicę, koła którego pole jest równe polu analizowanego obiektu. Ostatni wybrany współczynnik kształtu to współczynnik Malinowskiej R_M :

$$R_M = \frac{L}{2\sqrt{\pi - S}} - 1 \quad (5)$$

Ostatnie dwa parametry, pochodzące z analizy obrazu to obwód i pole ziarniaków. Niezbędne są do wyznaczania współczynników kształtu oraz dobrze charakteryzują ziarna, uszkodzone w sposób polegający na ubytku fragmentu.

Zbiór cech zawierał również informację o barwie, kodowanej według modelu przestrzeni barw RGB. Bezpośredni zapis modelu RGB do zbioru uczącego niesie ze sobą ryzyko zafałszowania informacji bądź jej błędnej interpretacji. Wynika to z faktu, że wszystkie trzy kolory składowe zapisywane są jako wartości od 0 do 255 każdy. Aby uniknąć błędów zaproponowano rozwiązanie polegające na zakodowaniu informacji o barwie zgodnie ze schematem przedstawionym poniżej (rys. 1) [Nowakowski 2008].

Analiza wrażliwości neuronowego modelu identyfikacyjnego wskazała jako parametry kluczowe, o najwyższych rangach, informacje o kolorze. Liczba tych informacji w zależności od przyjętej metodyki wynosiła od 256 do 1024 zmiennych. Celowym więc wydaje się podjęcie próby kompresji tych informacji i zbadanie wpływu takiego działania na jakość pracy neuronowego modelu identyfikacyjnego.



Rys. 1. Schemat kodowania informacji o barwie
Fig. 1. Diagram showing colour information coding


Cel badań

Celem pracy było zbadanie wpływu kompresji informacji o kolorach na działanie identyfikacyjnego modelu neuronowego. Informacja o kolorze jest jedną z cech charakterystycznych, dzięki której możliwa jest poprawna identyfikacja uszkodzeń ziarniaków kukurydzy przez model neuronowy. Kompresja tej informacji powoduje zmniejszenie liczby danych. Z punktu widzenia czasu uczenia modelu a później szybkości jego działania jest to operacja pożądana. Jednak kompresja zmniejsza również szczegółowość informacji w wektorze uczącym. W związku z tym postanowiono zbadać wpływ tej operacji na jakość działania identyfikacyjnego modelu neuronowego.

Metodyka

Pierwotnie przygotowane zbiory uczące zawierały dane o stanie ziarniaków na podstawie ich obrazów cyfrowych o rozdzielczości 512x512 pikseli.

Następnie zdjęcia poddano przetwarzaniu i komputerowej analizie obrazu. W skład parametrów charakterystycznych odczytywanych z obrazu i zapisywanych do zbiorów uczących wchodziły między innymi informacje o barwie każdego piksela według autorskiego systemu kodowania kolorów z formatu RGB. Aby znormalizować rozmiar wektora uczącego podzielono fotografię na fragmenty o stałych rozmiarach 32x32 piksele (rys. 2). Takie podejście daje wektor uczący złożony z 1024 zmiennych, które zawierają informację o barwie. Dodatkowo wektor uczący zawierał 9 zmiennych opisujących kształt ziarniaka. Znaczny rozmiar wektora uczącego powoduje wydłużenie czasu uczenia sztucznej sieci neuronowej. Pożądane więc jest poszukiwanie metody zmniejszenia informacji wektora uczącego przy jednoczesnym zachowaniu parametrów jakościowych neuronowego modelu identyfikacyjnego.




Rys. 2. Podział obrazu na fragmenty
Fig. 2. Image division into fragments


Redukcję informacji o kolorach przeprowadzono na dwa sposoby:

1. Uśrednianie informacji o barwie pikseli w obrębie jednego segmentu obrazu (rozmiar 32x32 piksele) (rys. 3).
2. Procentowy udział trzech kolorów podstawowych (format R – czerwony G – zielony B – niebieski) w obrębie jednego segmentu obrazu (rys. 4).

Pierwsza metoda zredukowała wektor uczący do 10 zmiennych, a druga do 12.



Rys. 3. Wynik kompresji informacji o kolorze pierwszą metodą
Fig. 3. Result of colour information compression carried out using the first method



Rys. 4. Wynik kompresji informacji o kolorze drugą metodą
Fig. 4. Result of colour information compression carried out using the second method

Wyniki

Wyniki neuronowego modelu identyfikacyjnego działającego w oparciu o zmodyfikowane zbiory uczące, okazały się znacząco gorsze od modelu uczonego na zbiorach uczących zawierających pełną informację o barwie.

Model działający w oparciu o zbiory uczące wytworzone pierwszą metodą z uśrednieniem kolorów w obrębie przypadku uczącego wykazywał większy błąd działania niż model drugi, działający na podstawie zbiorów uczących z procentowym udziałem kolorów podstawowych. Wysoki błąd pierwszego modelu wskazuje na kluczową rolę informacji o kolorze w identyfikacji uszkodzeń ziarniaków. Uśrednienie kolorów spowodowało efekt „rozmycia” na obrazie. Ponieważ model do wykrycia uszkodzenia szuka informacji o dużych zmianach kolorów przy uśrednianiu takich zmian nie zarejestrował.

W tabeli 1 zestawiono parametry dwóch omawianych powyżej modeli oraz trzeci model, który uczono na podstawie pełnej informacji o kolorach. Wszystkie modele zbudowano w oparciu o topologię Perceptronu wielowarstwowego z jedną warstwą ukrytą. Do oceny modeli wykorzystane zostały wartości błędów: uczenia, walidacyjnego i testowego. Zwrócono również uwagę na jakości modeli. Ostatecznej kwalifikacji dokonano na podstawie krzywej **ROC** (Receiver Operating Characteristic). Im pole pod krzywą bliższe wartości 1 tym dokładniejsza jest klasyfikacja ziarniaków. Poniższe wyniki również potwierdzają kluczowe znaczenie informacji o kolorze w procesie identyfikacji uszkodzeń ziarniaków.

Tabela 1. Zestawienie neuronowych modeli identyfikacyjnych

Table 1. The list of neural identification models

Typ sieci	Metody uczenia	Liczba neuronów w warstwie ukrytej	Błąd			Jakość			Pole pod krzywą ROC
			uczenia	walidacyjny	testowy	uczenia	walidacyjna	testowa	
MLP**	BP50CG173*	43	0,2868	0,3071	0,3152	0,7453	0,7423	0,7705	0,8161
MLP**	BP50CG173*	43	0,2252	0,2431	0,2568	0,8961	0,9073	0,8912	0,8901
MLP**	BP50CG173*	43	0,1069	0,2371	0,2384	0,9907	0,9385	0,9118	0,9713

* BP (Back-Propagation) – algorytm wstecznej propagacji błędów, CG (Conjugate Gradient) – algorytm gradientów sprzężonych, wartość oznacza liczbę epok uczenia

** MLP (Multi Layer Perceptron) – sieć typu perceptron wielowarstwowy

Źródło: opracowanie własne autora

Zaproponowane metody kompresji nie przyniosły spodziewanych rezultatów. Model neuronowy nie istnieje więc konieczność dalszych poszukiwań efektywnych metod kompresji, które pozwolą na zachowanie jakościowych parametrów pracy neuronowego modelu identyfikacyjnego.

Praca finansowana ze środków na naukę w latach 2009-2012 jak projekt badawczy – NN 313 264136

Bibliografia

- Nowakowski K.** 2008. Neuronowa analiza obrazu. Elementy inżynierii systemów rolnictwa - Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu Wyd. I. ISBN 978-83-7160-501-7. Poznań.
- Nowakowski K., Boniecki P.** 2008. Neuronowy model do identyfikacji makrouszkodzeń ziarniaków - Journal of Research and Applications in Agricultural Engineering vol. 53. Poznań s. 79-81.
- Osowski S.** 2000. Sieci neuronowe do przetwarzania informacji - Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa. ISBN: 83-7207-615-4.
- Tadeusiewicz R.** 1997. Komputerowa analiza i przetwarzanie obrazów - Wydawnictwo Fundacji Postępu Telekomunikacji. Kraków. ISBN: 83-86476-15-X.

COLOUR COMPRESSION IMPACT ON OPERATION OF A NEURAL IDENTIFICATION MODEL

Abstract. Sensitivity analysis of a developed neural model has indicated key role in the process of identifying information on seed colour. The researchers decided to check the impact of colour compression on quality of neural identification model operation. The authors proposed two own methods allowing to compress information concerning colour of seeds. Both methods significantly reduced the size of teaching vector. Results for the neural identification model operation on the basis of modified teaching sets have proven to be considerably worse than for the model trained using teaching sets containing complete information on colour.

Key words: neural image analysis

Adres do korespondencji:

Krzysztof Nowakowski: krzysztof.nowakowski@up.poznan.pl
Uniwersytet Przyrodniczy w Poznaniu
Instytut Inżynierii Rolniczej
ul. Wojska Polskiego 50
60-637 Poznań