

NEURAL MODEL FOR IDENTIFICATION OF DAMAGES OF CORN KERNELS

Summary

The realization of project enclosed construction and training neuronal model to identification of damages of corn kernels. Recognizing the damages was made on basis of digital photos converted by produced computer system to learning files dedicated for artificial neural network. The network was learned on chosen representative tags. The taught model marks abilities of identification approximate quality to human. Neural model can in real time identify larger number of kernels than man. The number of kernels is only limited by method of images acquisition and the computational power of applied equipment to implementation of model. Big advantage is also the lack of natural man limitations which for example are: fatigue and subjective opinion.

NEURONOWY MODEL DO IDENTYFIKACJI MAKROUSZKODZEŃ ZIARNIAKÓW

Streszczenie

Realizacja projektu obejmowała zbudowanie i wytrenowanie neuronowego modelu do identyfikacji makrouszkodzeń ziarniaków. Rozpoznawania uszkodzeń dokonywano na podstawie cyfrowych fotografii skonwertowanych przez wytworzony system informatyczny do postaci zbiorów uczących dedykowanych dla sztucznej sieci neuronowej. Do uczenia sieci wybrano zestaw reprezentatywnych cech. W zbiorze tym zawarto informacje o barwie (zakodowanej do postaci liczbowej), polu powierzchni, obwodzie i wybranych współczynnikach kształtu. Pojedynczy przypadek uczący zawierał 1031 zmiennych, z czego 1024 to zmienne zawierające informacje o barwie. Identyfikacji makrouszkodzeń dokonano na ziarniakach kukurydzy odmiany Clarica FAO 280.

1. Metodyka badań

Celem zrealizowanych badań było wytworzenie neuronowego modelu przeznaczonego do identyfikacji uszkodzeń ziarniaków w oparciu o ich cyfrowy obraz. Zbudowany model powinien osiągać jakość identyfikacji na poziomie zbliżonym do możliwości człowieka. Do budowy neuronowych modeli identyfikacyjnych wykorzystane zostały następujące zmienne:

- barwa, w postaci zakodowanej (informacja o każdego piksela z powierzchni ziarniaka kukurydzy),
- bezwymiarowy współczynnik kształtu

$$W1 = \frac{L^2}{4\pi S}, \quad (1)$$

- współczynnik *Fereta*

$$W2 = \frac{L_N}{L_V}, \quad (2)$$

- współczynniki cyrkularności

$$W3 = 2\sqrt{\frac{S}{\pi}}, \quad W4 = \frac{L}{\pi}, \quad (3)$$

- współczynnik *Malinowskiej*

$$W4 = \frac{L}{2\sqrt{\pi \cdot S}} - 1, \quad (4)$$

gdzie:

L – obwód rzutu obiektu,

S – pole rzutu obiektu,

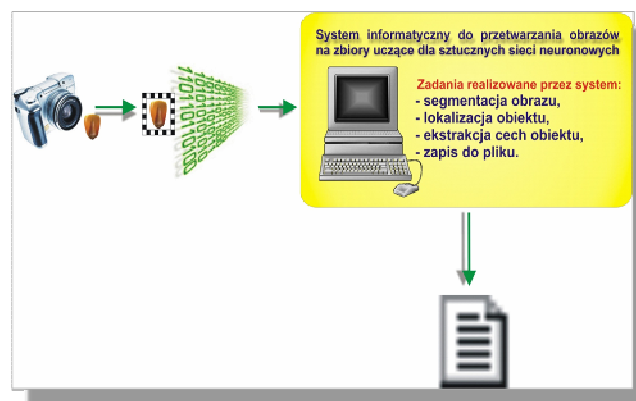
L_N – maksymalna długość rzutu obiektu,

L_V – maksymalna szerokość rzutu obiektu [4].

Doboru zmiennych wejściowych dokonano w oparciu o pozyskane dane empiryczne, w taki sposób, aby sieć funkcjonowała na podstawie informacji, podobnych do wyko-

rzystywanych przez człowieka w procesie identyfikacji uszkodzeń [1]. Zmienną wyjściową, czyli odpowiedzią sieci, była informacja o stanie ziarniaka: „Zdrowy” lub „Uszkodzony”. Do wytworzenia zbiorów uczących wykorzystano dedykowany system informatyczny (rys. 1).

Użytkownik systemu ma możliwość wyboru informacji, które zostaną zawarte w strukturze zbioru uczącego (rys. 2).

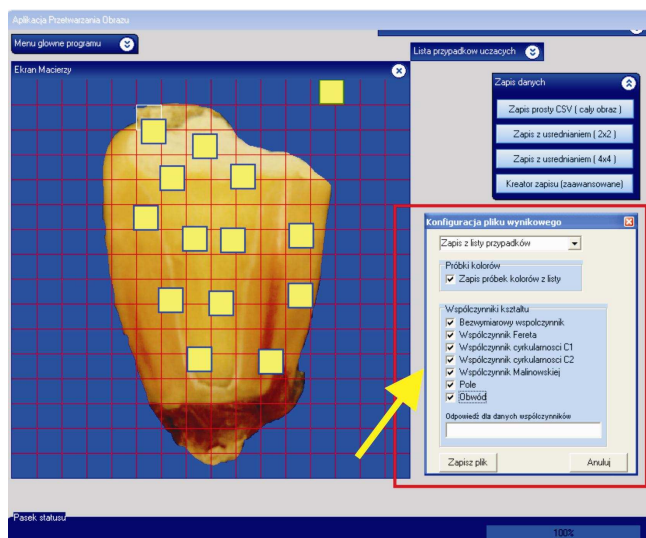


Rys. 1. Schemat systemu informatycznego do przetwarzania obrazów na zbiory uczące

Fig. 1. Scheme of computer system to processing images on learning files

Zastosowanie symulatora sztucznych sieci neuronowych z pakietu *Statistica* v. 7.1 pozwoliło na przetestowanie sieci o różnych topologiach, uczonych różnymi metodami. Dla wygenerowanych zbiorów danych przetestowano sieci o różnych topologiach. Wybór topologii sieciowej nastąpił w oparciu o najlepsze parametry jakościowe sztucznej sieci neuronowej. Przy wyborze topologii sieci neuronowej i metody uczenia zwrócono uwagę na zdolność do aproksymacji i uogólniania opierając się na miarach ich jakości przy za-

łożeniu, że dla najlepszej sieci błędy **RMS** (*Root Mean Square* – pierwiastek z błędu średniokwadratowego) dla zbiorów: uczącego, testowego i walidacyjnego, będą najmniejsze [3].



Rys. 2. Interfejs systemu do wytwarzania zbiorów uczących
Fig. 2. System interface to production of learning files

Tab. 1. Struktura zbiorów uczących
Tab. 1. Structure of learning files

Nazwa zbioru	Liczba przypadków uczących	Liczba przypadków w zbiorze uczącym	Liczba przypadków w zbiorze walidacyjnym	Liczba przypadków w zbiorze testowym
α	9200	4600	2300	2300
β	3702	1852	925	925
γ	9216	4602	2304	2304
δ	3072	1536	768	768
ε	1952	976	488	488
ζ	3200	1600	800	800

Etap testowania różnych topologii sztucznych sieci neuronowych wykazał, że najlepiej zadanie identyfikacji uszkodzeń mechanicznych ziarniaków kukurydzy realizuje sieć typu **MLP** (*Multi Layer Perceptron* – perceptron wielowarstwowy) z jedną warstwą ukrytą. Fakt powyższy wynika z dwuklasowego charakteru, jaki reprezentuje realizowane zagadnienie identyfikacyjne. Pozostałe z przetestowanych topologii charakteryzowały się znacząco gorszą jakością identyfikacji oraz kilkukrotnie większym błędem uczenia.

Proces uczenia sieci zrealizowano dwuetapowo. Na początku sieci uczone były metodą wstecznej propagacji błędów **BP** (*Back Propagation* – wsteczna propagacja). Jest to metoda sprawdzona i często używana do uczenia sieci typu **MLP**. Nazwa tego algorytmu wynika z kolejności obliczania sygnałów błędów δ , która przebiega w kierunku odwrotnym niż przechodzenie sygnałów przez sieć (tzn. od warstwy wyjściowej, poprzez warstwy ukryte w kierunku warstwy wejściowej). Metoda ta ma mniejsze wymagania dotyczące pamięci, niż większość innych algorytmów, co w przypadku tak dużych zbiorów uczących było istotne. Zwykle również szybko osiąga akceptowalny poziom błędów. Ponieważ precyzyjne osiągnięcie minimalnej wartości błędów może być przy wykorzystaniu tego algorytmu bardzo

czasochłonne drugi etap uczenia przeprowadzono za pomocą metody gradientów sprzężonych **CG** (*Conjugate Gradient – gradienty sprzężone*). Jest ona zaawansowaną metodą uczenia perceptronów wielowarstwowych. Algorytm ten działa zwykle efektywniej niż algorytm wstecznej propagacji błędów. Metoda gradientów sprzężonych szczególnie polecana jest dla sieci o dużej liczbie wag (więcej niż kilkadziesiąt) [2].

W trakcie uczenia sztucznych sieci neuronowych kontrolowany był błąd średniokwadratowy (**RMS**) dla zbioru walidacyjnego, testowego i uczącego. Jeżeli podczas procesu uczenia krzywa błędów dla zbioru walidacyjnego zaczynała wzrastać to był to sygnał zjawiska przeuczenia sieci. Zjawisko to jest niekorzystne i polega na zbytym dopasowaniu się sieci do danych uczących. Skutkuje to błędnym działaniem sieci dla danych nieprezentowanych w trakcie jej uczenia. W przypadku wystąpienia takiej sytuacji proces uczenia był przerywany i następowała jego modyfikacja. Jeśli uzyskane, podczas testowania sztucznych sieci neuronowych, wyniki identyfikacji były niezadowolające (zbyt duża wartość błędów uczenia bądź testowego czy walidacyjnego) wracano do etapu budowy modelu. Analizując poszczególne parametry wpływające na proces uczenia starano się je modyfikować w taki sposób, aby stopień identyfikacji osiągał zadowalający poziom. Jeśli jednak mimo to sieć nie odpowiadała stawianym wymaganiom budowana odbyła nowa i poddawana procedurze uczenia.

2. Wyniki

Wybór sieci najlepiej realizującej zadanie identyfikacji mechanicznych uszkodzeń ziarniaków dokonano w oparciu o wyniki dla trzech zbiorów: uczącego, walidacyjnego oraz testowego. Oceniano następujące charakterystyki wygenerowanych modeli:


- wielkość błędów uczącego,
- wielkość błędów walidacyjnego,
- wielkość błędów testowego,
- jakość uczenia sieci neuronowej,
- jakość walidacyjna sieci neuronowej,
- jakość testowa sieci neuronowej,
- krzywa **ROC** (*Receiver Operating Characteristic*),
- statystyki dla problemów klasyfikacyjnych.

Błąd uczący, walidacyjny oraz testowy są błędami otrzymanymi przy uruchamianiu sieci na podzbiore, odpowiednio, uczącym, walidacyjnym i testowym. Algorytmy uczące dążą do minimalizacji błędów uczącego. Błąd testowy stanowi ostateczną ocenę sieci.

Jakości uczenia, walidacyjna i testowa są miarą jakości wytrenowanej sieci. Sposób mierzenia jakości zależy od natury sieci. Dla sieci klasyfikujących miarą jakości jest proporcja poprawnie zaklasyfikowanych przypadków. Jest to niekorzystne dla sieci z konserwatywnymi progami akceptacji i odrzucenia, które pozostawiają niesklasyfikowane niepewne przypadki, siłą rzeczy nie klasyfikując ich poprawnie. Przy klasyfikowaniu za pomocą sieci neuronowych, o przydziale przypadku do klasy decyduje położenie progów akceptacji i odrzucenia. W przypadku klasyfikacji dwustanowej, domyślnie, wynikowa klasa wskazywana jest przez aktywację pojedynczego neuronu wyjściowego, wysoka dla jednej klasy i niska dla drugiej. Jeżeli próg odrzucenia jest niższy od progu akceptacji to sieć może dać wynik nieokreślony, gdy aktywacja mieści się między progami.

Tab. 2. Parametry wybranych neuronowych modeli identyfikacyjnych
 Tab.2. Parameters of chosen neuronal identification models

Numer modelu	Typ sieci	Metody uczenia	Liczba neuronów w warstwie ukrytej	Błąd uczenia	Błąd walidacyjny	Błąd testowy	Jakość uczenia	Jakość walidacyjna	Jakość testowa	Pole pod krzywą ROC
1	MLP	BP50 CG168	26	0,3368	0,3471	0,4152	0,8453	0,8423	0,7705	0,8861
2	MLP	BP50 CG165	33	0,3752	0,3731	0,3768	0,7961	0,8073	0,8012	0,8901
3	MLP	BP50 CG217	29	0,2067	0,2980	0,3120	0,9436	0,8995	0,8737	0,9281
4	MLP	BP50 CG255	41	0,2155	0,2806	0,3233	0,9497	0,9077	0,8643	0,9146
5	MLP	BP50 CG173	43	0,1069	0,2371	0,2884	0,9907	0,9385	0,9118	0,9713
6	MLP	BP50 CG289	33	0,1281	0,2476	0,3262	0,9784	0,9364	0,9043	0,9583



Rys. 3. Topologia neuronowego modelu identyfikacyjnego
 Fig. 3. Topology of neuronal identification model

Krzywa **ROC** podsumowuje działanie dwustanowego klasyfikatora, dla wszystkich możliwych progów. Wrażliwość sieci wykreślona jest tu względem wielkości: jeden minus specyficzność. Idealny klasyfikator daje krzywą przylegającą do lewego i górnego brzegu wykresu, z polem pod krzywą równym 1,0. Dla losowych klasyfikacji pole wynosiłoby około 0,5. Krzywa **ROC** dobrze służy porównywaniu klasyfikatorów, jako że nie zależy od arbitralnego wyboru progu decyzyjnego [2].

Dla całego zbioru danych, wyznaczane są statystyki określające jakości klasyfikacji sieciowej. Statystyki te obejmują:

- liczbę przypadków zaklasyfikowanych prawidłowo oraz liczbę przypadków zaklasyfikowanych nieprawidłowo a także liczbę przypadków, które wcale nie zostały zaklasyfikowane (odpowiedzi typu "nie wiem"),
- liczbę przypadków należących w rzeczywistości do każdej z klas i zaklasyfikowanych do konkretnej innej klasy (rozkład błędów, pozwalający na ocenę, co się z czym najbardziej myli).

Statystyki te wyznaczane są oddzielnie dla zbioru uczącego, walidacyjnego i testowego. Statystyki klasyfikacyjne mogą być wyznaczane tylko dla tych zbiorów danych, w

których występuje wyjściowa zmienna nominalna informująca o przynależności każdego przypadku do jednej z klas.

Do końcowych testów wybrano 6 modeli neuronowych o różnej liczbie neuronów w warstwie ukrytej. Optymalny jest model nr 5 charakteryzujący się najlepszymi parametrami identyfikacji.

3. Podsumowanie

Przeprowadzone badania wskazują na celowość zastosowania technologii sztucznych sieci neuronowych i komputerowej analizy obrazów do realizacji zadania identyfikacji uszkodzeń. Wskazują na to satysfakcjonujące charakterystyki modelu piątego, najlepiej realizującego zadanie identyfikacji. Optymalny model cechuje się średnim poziomem błędu globalnego na poziomie 8%. Oznacza to, że na 100 ziarniaków błędnie sklasyfikowanych zostanie 8. Wykazuje on więc przewagę nad człowiekiem w zastosowaniach, gdzie ważne są czas oraz powtarzalność procesu identyfikacji. Zbudowany model może w czasie rzeczywistym identyfikować dużo większą liczbę ziarniaków niż człowiek. Liczba ta ograniczona jest tylko sposobem akwizycji obrazu i mocą obliczeniową zastosowanego sprzętu do implementacji modelu. Jego zdecydowaną zaletą jest również brak naturalnych ograniczeń, które posiada człowiek. Model neuronowy może pracować bez przerwy ponieważ m.in. nie odczuwa zmęczenia.

4. Literatura

- [1] Malina W., Smiatacz M.: Metody cyfrowego przetwarzania obrazów. Wydawnictwo EXIT, Warszawa 2005.
- [2] Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [3] Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
- [4] Tadeusiewicz R.: Komputerowa analiza i przetwarzanie obrazów. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków 1997.