

THE CLASSIFICATION OF MAIZE'S KERNELS WITH SUPPORTING NEURONAL IDENTIFICATION OF SHAPE

Summary

The aim of work was producing the computer system helping the process of classification of corn kernels using neuronal image analysis. In the project was used method of identification of shapes differences using superformula proposed by John Gielis, permitting on representation of any shape with six independent parameters.

KLASYFIKACJA ZIARNIAKÓW KUKURYDZY W OPARCIU O NEURONOWĄ IDENTYFIKACJĘ KSZTAŁTU

Streszczenie

Celem pracy było wytworzenie systemu informatycznego wspomagającego proces klasyfikacji ziarniaków kukurydzy w oparciu o neuronową analizę obrazu. W pracy wykorzystano metodę identyfikacji różnic kształtów analizowanych obiektów w oparciu o tzw. superformułę, zaproponowaną przez Johana Gielisa, pozwalającą na reprezentację dowolnego kształtu za pomocą sześciu niezależnych parametrów.

1. Wprowadzenie

Identyfikacja obiektów w oparciu o metody rozpoznawania obrazu to problematyka znana i rozwijana od dawna. Metody analizy obrazu wykorzystywane są powszechnie w takich systemach informatycznych jak np. aplikacje typu *OCR (Optical Character Recognition)*, realizujących przetwarzanie mapy bitowej na tekst (rozpoznawanie pisma) czy programy *OMR (Optical Mark Recognition)* przeznaczone do odczytywania kodów kreskowych. Rozpoznawanie obrazów kojarzy się na ogół z identyfikacją dwuwymiarowej fotografii lub trójwymiarowej sceny, ale problem jest znacznie szerszy. Warto zauważyć, że w postaci graficznej można przedstawić różne wielkości, takie jak np. dźwięki, wahania temperatury, różnego rodzaju czynniki ekonomiczne i wiele innych rzeczy oraz zdarzeń.

Jedną z trudności w komputerowej analizie obrazu stanowi fakt, że nie istnieje uniwersalny algorytm pozwalający na uzyskanie pełnej informacji o obiektach, które prezentowane są w postaci graficznej. W konsekwencji proces rozpoznawania obrazu jest na ogół sekwencją wielu, następujących po sobie, złożonych działań. Dlatego też klasyczna analiza obrazu zazwyczaj wymaga sporych mocy obliczeniowych oraz dużego nakładu czasu pracy komputera. Z tych powodów poszukiwano innych, bardziej efektywnych metod analizy oraz przetwarzania informacji zakodowanej w postaci graficznej. Jednym z obiecujących kierunków takich działań wydaje się być wykorzystanie modelowania neuronowego w procesie analizy obrazu.

Dziedzina rozpoznawania obrazów za pomocą sztucznych sieci neuronowych to stosunkowo nowa gałąź informatyki i ściśle wiąże się z badaniami prowadzonymi nad sztuczną inteligencją. Celem tych badań było m.in., wykorzystanie komputerów do rozwiązywania problemów w podobny sposób jak czyni to człowiek. Od dawna bowiem wiadomo, że np. w dziedzinie rozpoznawania obrazów w czasie rzeczywistym, mózg jest niezastąpiony.

Jednym z nurtów badań naukowych, prowadzonych w powyższym kontekście, była próba budowania modeli neu-

ronowych, których działanie inspirowane było mechanizmem przetwarzania informacji w taki sposób, w jaki czyni to mózg ludzki. W efekcie doprowadzono do sytuacji, w której zadania rozwiązywane do niedawna przede wszystkim przez ludzi, dzisiaj wykonują automaty, wykorzystujące sprzętowe lub programowe symulatory sztucznych sieci neuronowych.

Celem pracy było badanie własności klasyfikacyjnych modeli neuronowych w procesie identyfikacji wybranych ziarniaków. Proponowana metoda klasyfikacyjna polegała na neuronowym rozpoznawaniu obiektów występujących w postaci dwuwymiarowych obrazów. Do identyfikacji kształtu ziarniaków wykorzystano tzw. superformułę zaproponowaną przez belgijskiego inżyniera *Johana Gielisa*. Formuła ta pozwala na odwzorowanie dowolnego kształtu za pomocą sześciu niezależnych parametrów. Zmienne te w niniejszej pracy wykorzystano jako cechy charakterystyczne, służące do budowy zbiorów uczących. Te zaś wykorzystano następnie w procesie tworzenia modeli neuronowych. Zaproponowano aby proces identyfikacji został zrealizowany w oparciu o trzy wybrane cechy reprezentatywne, za jakie uznano wybrane współczynniki kształtu. Stanowią one parametry równania *Gielisa*. Dodatkowym celem utylitarnym podjętych badań było wytworzenie interaktywnego systemu informatycznego „*Klastifikator*”, wspomagającego procesy decyzyjne w zakresie klasyfikacji jakościowej ziarniaków kukurydzy.

2. Podstawy teoretyczne


Superelipsa, zwana również krzywą Lamé (od nazwiska francuskiego matematyka i inżyniera *Gabriela Lamé*) to krzywa płaska, która jest opisana we współrzędnych kartezjańskich następującym równaniem:

$$\left| \frac{x}{a} \right|^n + \left| \frac{y}{b} \right|^n = 1, \quad (1)$$

gdzie:

$n \gg 0$,
 a, b - „promienie” superelipsy.

W przypadku gdy $n = 2$ otrzymuje się „zwykłą” elipsę, natomiast gdy $n = 1$ uzyskuje się romb o przekątnych: $2a$ oraz $2b$. Zwiększając n do nieskończoności ($n \rightarrow \infty$), krzywa opisana równaniem (1) zaczyna coraz bardziej przypominać prostokąt. Natomiast gdy n dąży do zera ($n \rightarrow 0$), krzywa dąży do kształtu „krzyża” (rys. 1).



Źródło: <http://pl.wikipedia.org/wiki/Grafika:Superelipsa.png>

Rys. 1. Graficzna interpretacja wzoru (1) dla różnych n
 Fig. 1. Graphic interpretation of formula (1) for different n

Superelipsę można także opisać w postaci układu równań parametrycznych, które w układzie biegunowym reprezentowane są następująco:

$$\begin{aligned} x(\theta) &= \pm a \cdot \cos^{2/n} \theta, \\ y(\theta) &= \pm b \cdot \sin^{2/n} \theta, \end{aligned} \quad (2)$$

gdzie:

$$0 \leq \theta < \frac{\pi}{2},$$

a, b - „promienie” superelipsy.

Wygodnie jest przekształcić (2) do następującej postaci:


$$\begin{aligned} x(\theta) &= r_x \cos^n \theta \\ y(\theta) &= r_y \sin^n \theta \end{aligned} \quad (3)$$

gdzie:

$$0 \leq \theta \leq 2\pi,$$


$$0 < n < \infty,$$

r_x, r_y - składowe wektora wodzącego (rys. 2).



Rys. 2. Graficzna interpretacja układu równań (3) dla $n = 2$
 Fig. 2. Graphic interpretation of simultaneous equations (3) for $n = 2$

Zakładając np., że $r_x = r_y$ oraz uwzględniając różne wartości parametru n można otrzymać różne kształty (rys. 3).



Rys. 3. Graficzna interpretacja układu równań (3) dla różnych wartości parametru n

Fig. 3. Graphic interpretation of simultaneous equations (3) for different values $n = 2$

Powyższe rozważania można uogólnić dla trzech wymiarów. Wtedy układ równań (3) przyjmuje postać (4):

$$\begin{aligned} x &= r_x \cos^{n_1} \theta \cos^{n_2} \varphi \\ y &= r_y \cos^{n_1} \theta \sin^{n_2} \varphi, \\ z &= r_z \sin^{n_1} \theta \end{aligned} \quad (4)$$


gdzie:

$$-\frac{\pi}{2} \leq \theta \leq \frac{\pi}{2}$$

$$-\pi \leq \varphi \leq \pi$$

$$0 < n_1, n_2 < \infty$$

Aby uzyskać różne figury przestrzenne, do manipulowania dostępne są teraz dwa parametry: n_1 oraz n_2 . Przykłady powierzchni uzyskanych w oparciu o wybrane wartości parametrów n_1 i n_2 przedstawiono na rys. 4.



$n_1 = n_2$ $n_1 = 1, n_2 \text{ duże}$ $n_1 \text{ duże}, n_2 = 1$
 Źródło: http://local.wasp.uwa.edu.au/~pbourke/surfaces_curves/

Rys. 4. Graficzna interpretacja równań (4) dla różnych wartości parametrów n_1 oraz n_2

Fig. 4. Graphic interpretation of equations (4) for different values n_1 and n_2

Tworzeniem różnych form (również użytkowych) w oparciu o wzór superelipsy zajmował się Piet Hein, duński uczony, filozof i artysta. Był wyrazicielem poglądu: „Sztuka jest rozwiązaniem tych problemów, których nie da się jasno sformułować, zanim zostaną rozwiązane”. Od roku 1959 próbował on znaleźć tzw. formę perfekcyjną i tym samym rozwiązać odwieczne przeciwieństwo kwadratu oraz koła. W roku 1997, podczas prowadzonych badań botanicznych, belgijski inżynier, matematyk oraz specjalista w dziedzinie biotechnologii Johan Gielis, uogólniając rozważania Pieta Heina na temat superelipsy, zaproponował równanie tzw. superformuły:

$$\frac{1}{r} = \sqrt[n_1]{\left| \frac{1}{a} \cos\left(\frac{m}{4} \theta\right) \right|^{n_2}} + \sqrt[n_2]{\left| \frac{1}{b} \sin\left(\frac{m}{4} \theta\right) \right|^{n_3}}, \quad (5)$$

gdzie:

r oraz θ – współrzędne punktu w układzie biegunowym (odległość punktu od pozycji środka dla danego kąta θ),
 m – współczynnik symetrii,
 n_1, n_2, n_3 – współczynniki kształtu,
 a, b – wymiar poziomy i pionowy.

Poprzez odpowiedni dobór wyżej wymienionych współczynników (traktowanych jako parametry) wzór ten pozwala odtworzyć różne kształty, również takie, które w sposób naturalny występują w naturze, jak np. kwiaty, zwierzęta, ziarniaki itd. [3].

3. Implementacja wygenerowanego kodu źródłowego sztucznej sieci neuronowej w środowisku Microsoft Visual Studio 2005

Jako cechy reprezentatywne badanych obrazów ziarniaków przyjęto trzy parametry n_1, n_2 oraz n_3 superformuły (5). Jako wzorce przyjęto obrazy ziarniaków, których wybrane zdjęcia pokazane na rys. 5.

W celu wygenerowania kształtu wybranych ziarniaków kukurydzy, a następnie identyfikacji właściwych współczynników superformuły, wykorzystano generator kształtu w formie apletu JAVA (napisany przez *Holgera Hoffmanna*) i dostępny w postaci interaktywnej m.in. pod internetowym adresem: <http://www.activeart.de/dim-shops/training/SuperShape/>.

Na ich podstawie skonstruowano zbiór uczący do budowy klasyfikacyjnego modelu neuronowego służącego do identyfikacji wybranych ziarniaków (Boniecki, Olszewski 2008). W tym celu wykorzystano komercyjny pakiet *Statistica v.7.0.* z zaimplementowanym modułem dedykowanym do tworzenia różnych topologii jednokierunkowych

sieci neuronowych (Tadeusiewicz, Lula 2001). Wytworzoną optymalną topologię sieci neuronowej (typu perceptron wielowarstwowy) poddano serii testów, zarówno weryfikacyjnych jak również walidacyjnych (Boniecki, Olszewski 2008). Korzystając z opcji „Generator kodu” dokonano ekstrakcji kodu wygenerowanego modelu neuronowego. Pozysskany kod w języku C został następnie zaimplementowany w budowanej aplikacji „Klasyfikator”. Spośród wielu dostępnych narzędzi programistycznych wybrane zostało środowisko *Microsoft Visual Studio 2005*. Wytworzony system informatyczny „Klasyfikator” oparty został na pozyskanym kodzie, który stanowił jądro wytworzonej aplikacji internetowej.

Wymagania funkcjonalne systemu „Klasyfikator”

Wymagania te opisują czynności i operacja wykonywane przez system. Dla każdego wymagania funkcjonalnego został utworzony formularz opisu wymagania [1]. Poniżej przedstawiono przykład wymagań dla funkcji *Zastosuj*:

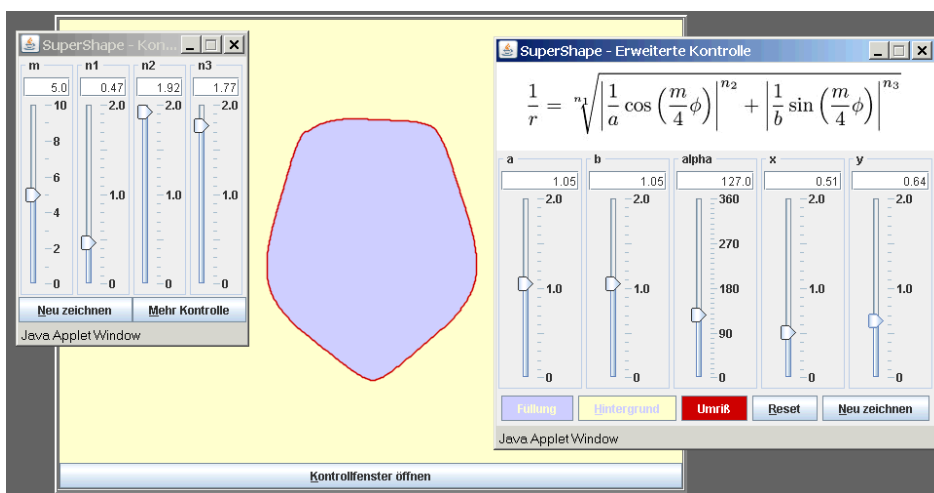
Tab. 1. Wymagania funkcjonalne: *Zastosuj*
 Tab. 1. Functional requirements: Apply

Nazwa funkcji	<i>Zastosuj</i>
Opis	Uruchamia model neuronowy, analizuje wprowadzone dane i zwraca wynik w postaci nazwy rośliny.
Warunek wstępny	Naciśnięcie przycisku <i>Zastosuj</i> .
Warunek końcowy	Wyświetlenie wyniku pracy sztucznej sieci neuronowej.
Powód	Umożliwia rozpoznanie gatunku na podstawie współczynników kształtu.

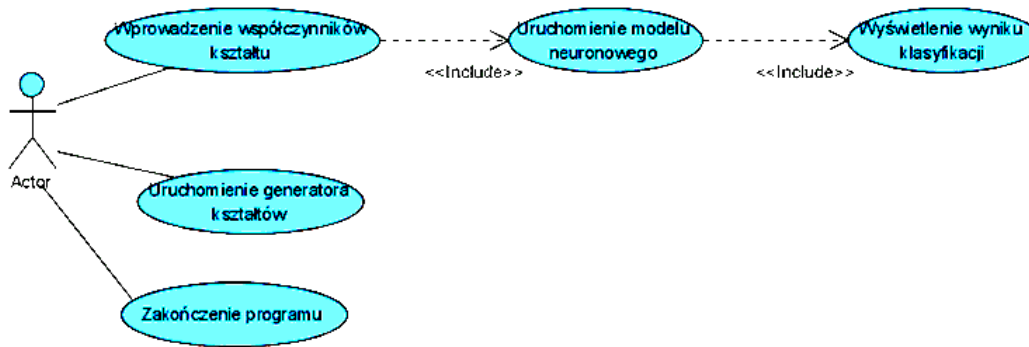


Źródło: Nowakowski K.: Neuronowa identyfikacja wybranych mechanicznych makrouszkodzeń ziarniaków. Praca doktorska, Poznań 2007

Rys. 5. Zdjęcia wybranych ziarniaków kukurydzy
 Fig. 5. Pictures of chosen maize's kernels



Rys. 6. Generowanie kształtu ziarniaka za pomocą apletu *Holgera Hoffmanna*
 Fig. 6. Generating of kernel shape using *Holger Hoffmann's* applet



Rys. 7. Diagram przypadków użycia
Fig. 7. Use case diagram

Wymagania niefunkcjonalne:

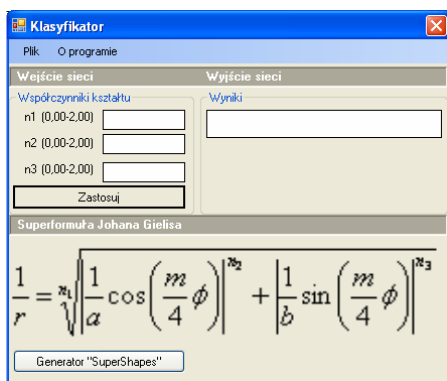
- komputer klasy PC,
- system operacyjny *Microsoft Windows 2000/XP*,
- dostęp do Internetu,
- zainstalowane środowisko *.NET Framework*,
- pamięć operacyjna RAM 512MB lub więcej,
- około 1GB wolnej przestrzeni dyskowej.

Diagram przypadków użycia przedstawiony poniżej obrazuje możliwości pracy w systemie „Klasyfikator”.

4. Budowa i obsługa aplikacji „Klasyfikator”

Obszar okna głównego programu podzielono na dwie części (rys. 9.):

- część dotycząca działania modelu neuronowego,
- część dodatkowa, przedstawiająca superformułę *Johana Gielisa* i zawierająca przycisk dostępu do generatora kształtów.



Rys. 8. Interfejs użytkownika aplikacji „Klasyfikator”
Fig. 8. User interface of „Klasyfikator” system

Część górną interfejsu podzielono na dwie ramki:

- ramka: wejście sieci zawierająca pola w które należy wprowadzić współczynniki kształtu badanego obiektu,
- ramka: wyjście sieci zawierająca wyniki, to jest pole w którym wyświetlona zostaje nazwa rośliny po dokonaniu klasyfikacji.

5. Uwagi końcowe

Na podstawie przeprowadzonych rozważań, odnośnie wykorzystania sieci neuronowych typu perceptron wielowarstwowy jako instrumentu klasyfikacyjnego, można sformułować następujące wnioski:

1. Wytworzona aplikacja „Klasyfikator” spełnia oczekiwania stawiane narzędziom wspomagającym procesy decyzyjne w rolnictwie. Jej intuicyjny i prosty interfejs oraz zawarty plik pomocy mogą być pomocne dla użytkowników chcących praktycznie zapoznać się jakością działania sztucznych sieci neuronowych typu perceptron, pracujących jako instrumenty klasyfikacyjne.
2. Superformuła *Johana Gielisa* umożliwia identyfikację ziarniaków kukurydzy na podstawie wygenerowanych współczynników kształtu. Wytworzona internetowa aplikacja „Klasyfikator”, działająca w oparciu o wygenerowany neuronowy model klasyfikacyjny typu perceptron, pozwala na rozpoznawanie ziarniaków kukurydzy w czasie rzeczywistym.
3. Neuronowe systemy wspomagające podejmowanie decyzji dla potrzeb szeroko rozumianego rolnictwa są coraz bardziej efektywne w praktyce. Mogą one w najbliższej przyszłości stać się istotnym ogniwem w gospodarstwach wysoko rozwiniętych, charakteryzujących się dużym stopniem automatyzacji produkcji.

6. Literatura

- [1] Jaskiewicz A.: Inżynieria oprogramowania. Wydawnictwo Helion S.A., Gliwice 1997.
- [2] Tadeusiewicz R., Lula P.: *Statistica Neural Networks PL: wprowadzenie do sieci neuronowych*. StatSoft Polska, Kraków 2001.
- [3] Boniecki P., Olszewski T.: Modelowanie neuronowe wybranych obiektów rolniczych z wykorzystaniem superformuły *Johana Gielisa*. *Journal of Research and Applications in Agricultural Engineering*, 2008, Vol. 53(1), str. 22-26.
- [4] http://pl.wikipedia.org/wiki/Johan_Gielis
- [5] http://local.wasp.uwa.edu.au/~pbourke/surfaces_curves/supershape/
- [6] <http://www.activeart.de/dim-shops/training/SuperShape/>
- [7] <http://pl.wikipedia.org/wiki/Grafika:Superelipsa.png>
- [8] http://local.wasp.uwa.edu.au/~pbourke/surfaces_curves/