

NEURONAL MODELLING OF SELECTED AGRICULTURAL OBJECTS WITH USAGE OF JOHAN GIELIS'S SUPERSHAPE

Summary

The aim of the work was to study the classifying possibilities of neural networks in the identification process of the wheat's, barley's and corn's kernel. Applied separation method depended on recognizing the shape differences of analysed objects. In order to identify the shape, and afterwards to encode the obtained empirical data into the training data sets the Johan Gielis's supershape formula was used. This formula permits for projection of any shape with a help of six independent parameters.

MODELOWANIE NEURONOWE WYBRANYCH OBIEKTÓW ROLNICZYCH Z WYKORZYSTANIEM SUPERFORMUŁY JOHANA GIELISA

Streszczenie

Celem pracy było badanie możliwości klasyfikacyjnych sieci neuronowych w procesie identyfikacji ziarniaków pszenicy, jęczmienia oraz kukurydzy. Wykorzystana metoda separacji polegała na rozpoznawaniu różnic kształtów analizowanych obiektów. W celu identyfikacji kształtu, a następnie zakodowania pozyskanych danych empirycznych do postaci zbiorów uczących, wykorzystano tzw. superformułę zaproponowaną przez Johana Gielisa. Formuła ta pozwala na odwzorowanie dowolnego kształtu za pomocą sześciu niezależnych parametrów.

Wprowadzenie

Modele neuronowe są bardzo skuteczne m.in. jako narzędzia obliczeniowe do rozwiązywania takich zadań, z którymi typowe komputery i typowe programy słabo sobie radzą. Dzieje się tak, ponieważ przetwarzanie w sieciach neuronowych wykonywane jest w sposób równoległy oraz rozproszony. Szybkość pracy modeli neuronowych na ogół znacznie przewyższa szybkość obliczeń sekwencyjnych realizowanych przez klasyczne maszyny cyfrowe, pracujące w sposób szeregowy. Ważną zaletą sieci neuronowych jest możliwość wytworzenia modelu badanego zagadnienia z pominięciem etapu konstruowania algorytmu rozwiązania problemu [1]. Przypomina to sposób funkcjonowania mózgu ludzkiego, którego działanie stanowi inspirację oraz pierwowzór dla modelowania neuronowego. Jednym z obszarów, w których człowiek wykazuje istotną przewagę nad komputerem, jest szeroko rozumiana, identyfikacja oraz rozpoznawanie [3].

Celem pracy było badanie możliwości klasyfikacyjnych sieci neuronowych w procesie identyfikacji wybranych obiektów rolniczych, na przykładzie klasyfikacji ziarniaków pszenicy, jęczmienia oraz kukurydzy. Proponowana metoda klasyfikacyjna polegała na rozpoznawaniu kształtów badanych obiektów występujących w postaci obrazów. W celu identyfikacji kształtu ziarniaków wykorzystano tzw. superformułę zaproponowaną przez belgijskiego inżyniera Johana Gielisa. Formuła ta pozwala na odwzorowanie dowolnego kształtu za pomocą niezależnych parametrów, które w niniejszej pracy uznano za cechy reprezentatywne, służące do budowy zbiorów uczących dla tworzonych modeli neuronowych.

Superformuła Johana Gielisa

W 1997 roku Johan Gielis, belgijski inżynier, matematyk oraz specjalista w dziedzinie biotechnologii, opubliko-

wał wzór (stanowiący uogólnienie wzoru superelipsy, który sformułował Gabriel Lamé), opisujący dowolny kształt w przestrzeni, zarówno dwu jak i trójwymiarowej [6]. Wzór ten zyskał miano superformuły, czasem określanej mianem superwzoru Gielisa. Dla przypadku dwuwymiarowego, w układzie biegunowym, równanie to przybiera następującą postać:

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

gdzie:

- r oraz ϕ – współrzędne punktu w układzie biegunowym,
- m – współczynnik symetrii,
- n_1, n_2, n_3 – współczynniki kształtu,
- a, b – wymiar poziomy i pionowy.

Przykładowe figury geometryczne 2D dla wybranych parametrów m, n_1, n_2, n_3 (przy ustalonych wartościach a oraz b) przedstawia rys. 1.

Rozwijając własną koncepcję Johan Gielis zaproponował w roku 2003 uogólnioną postać superformuły, opisaną następującym wzorem:

$$r(\theta) = \varphi(\theta) \left[\left| \frac{\cos\left(\frac{1}{4}m\theta\right)}{a} \right|^{n_2} + \left| \frac{\sin\left(\frac{1}{4}m\theta\right)}{b} \right|^{n_3} \right]^{\frac{1}{n_1}} \quad (2)$$

gdzie:

- r, θ – współrzędne punktu w układzie biegunowym,
- $\varphi(\theta)$ – dowolna funkcja matematyczna.

m	n1=n2=n3=1	n1=1000; n2=n3		n1=n2=n3=1/2	n1=30 n2=n3=15	n1=80 n2=n3
0			2			
1			500			
2			500			
3			1980			
4			1000			
5			620			
6			390			
7			320			
8			250			


Rys. 1. Przykładowe obiekty 2D generowane z pomocą superformuły

Fig. 1. Exemplary 2D objects generated by means of super-shape

Podobnie jak w formule (1), tutaj również przypadku (2) manipulując powstającym kształtem za pomocą współczynników kształtu n_1 , n_2 i n_3 , oraz zmieniając zapis funkcji $\varphi(\theta)$ można uzyskać dowolnie złożone kształty (rys. 2).

Projektowanie oraz implementacja sztucznej sieci neuronowej

W celu wygenerowania kształtu ziarniaków, 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/> [15].

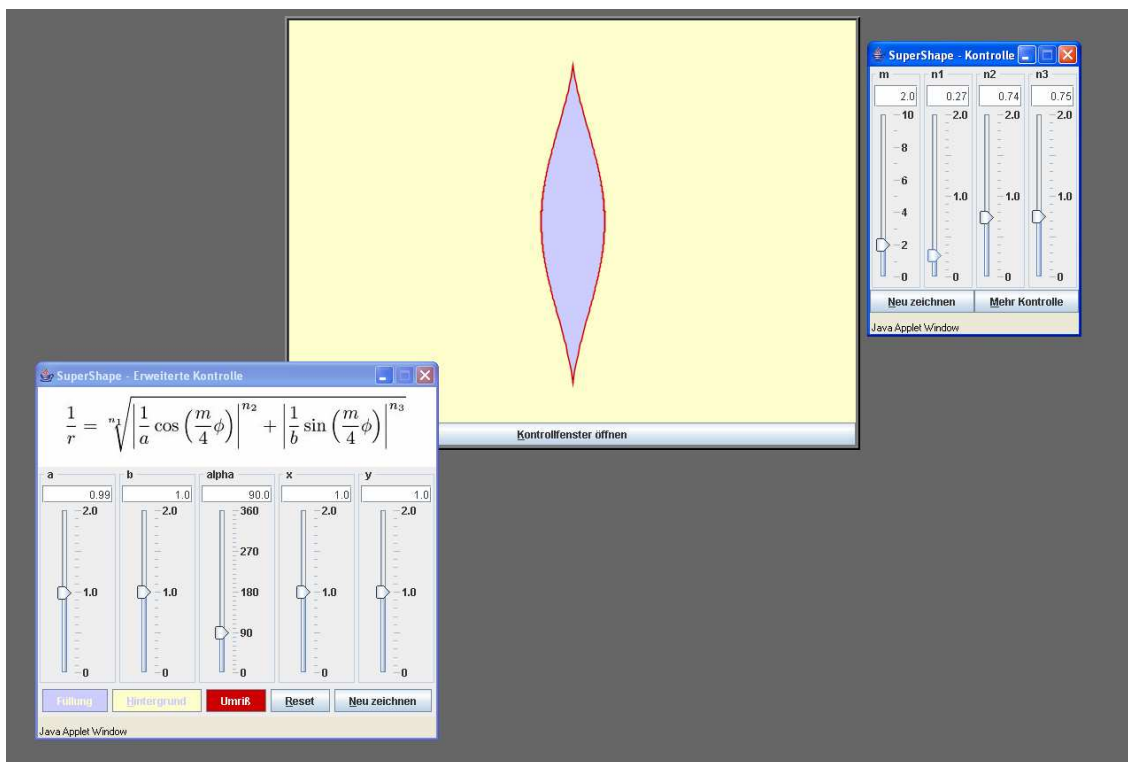


Rys. 2. Przykładowe figury wytworzone za pomocą superformuły (2)

Fig. 2. Exemplary figures generated by means of super-shape (2)

W oparciu o posiadane dane empiryczne w postaci zdjęć ziarniaków jęczmienia, kukurydzy oraz pszenicy, wygenerowano za pomocą apletu Hoffmanna zbiór adekwatnych kształtów ziarniaków. Jednocześnie zarejestrowano wartości parametrów a , b , m , n_1 , n_2 oraz n_3 opisujących analizowane kształty. Przykładowe zdjęcia ziarniaków oraz ich wirtualne postaci wygenerowane w oparciu o superformułę Gielisa pokazano na rys. 4, 5 oraz 6.

Parametry a , b , m , n_1 , n_2 przyjęto jako cechy reprezentatywne badanych obrazów ziarniaków. Na ich podstawie skonstruowano zbiór uczący przeznaczony do budowy modelu neuronowego służącego do klasyfikacji ziarniaków pszenicy, żyta oraz kukurydzy. Fragment tego zbioru przedstawia rys. 7.



Rys. 3. Generowanie kształtu za pomocą apletu Holgera Hoffmanna

Fig. 3. Shape generating with usage of Holger Hoffmann's applet



Rys. 4. Ziarniak jęczmienia oraz jego wirtualny kształt wygenerowany za pomocą superformuły
 Fig. 4. The barley's kernel and its virtual shape generated with usage of supershape



Rys. 5. Ziarniak pszenicy oraz jego wirtualny kształt wygenerowany za pomocą superformuły
 Fig. 5. The wheat's kernel and its virtual shape generated with usage of supershape



Rys. 6. Ziarniak kukurydzy oraz jego wirtualny kształt wygenerowany za pomocą superformuły
 Fig. 6. The corn's kernel and its virtual shape generated with usage of supershape

cechy reprezentatywne - zmienne wejściowe						zmienna wyjściowa
a	b	m	n ₁	n ₂	n ₃	nazwa
1,06	0,95	2	0,33	0,78	0,84	1
1,06	0,92	2	0,32	0,94	0,92	1
1,07	0,95	2	0,58	1,16	1,19	2
1,07	1,16	2	0,64	1,17	1,12	2
1,07	1,16	2	0,56	1,16	1,15	2
1,1	0,98	2	0,6	1,15	1,2	2
1,1	0,99	2	0,87	1,8	1,08	3
1,1	0,95	2	0,95	0,81	0,96	3
1,13	1,19	2	0,62	1,14	1,21	2
1,15	0,98	2	0,88	2	1,05	3
1,16	1,2	2	0,64	1,13	1,22	2
1,16	1,13	2	0,54	1,22	1,17	2
1,16	0,98	2	0,52	1,14	1,13	2
1,16	1,1	2	0,63	1,17	1,17	2


Rys. 7. Fragment zbioru uczącego
 Fig. 7. Training data set fragment

gdzie: **a**, **b** – wymiar poziomy i pionowy, **m** – krotność symetrii, **n₁**, **n₂**, **n₃** – współczynniki kształtu, **nazwa** – nazwa danego gatunku (1 – jęczmień, 2 – pszenica, 3 – kukurydza)

Zbiór uczący składał się z 210 przypadków (na każdą odmianę ziarniaka przypadło 70 przypadków uczących). Badane przypadki umieszczono w zbiorze uczącym w sposób losowy. Tak przygotowany zbiór danych stanowił podstawę do uczenia tworzonego neuronowego modelu klasyfikacyjnego.

Do wygenerowania poszukiwanej topologii sieci neuronowej wykorzystano moduł „Sieci neuronowe” zaimple-

mentowany w komercyjnym systemie informatycznym *Statistica v.7.0.* [7]. W pierwszym etapie skorzystano z efektywnego narzędzia, jakim jest „Automatyczny projektant sieci”. Ze zbioru wygenerowanych dziesięciu najlepszych topologii sieci neuronowych wybrano sieć typu *MLP (MultiLayer Perceptron)* charakteryzującą się najmniejszym błędem średniokwadratowym *RMS (Root Mean Square)*, której strukturę przedstawia rys. 8.



Rys. 8. Topologia wytworzonej sieci neuronowej typu MLP
Fig. 8. Topology of developed MLP type neural network

Następnie sieć została poddana procesowi “douczenia” z wykorzystaniem algorytmu gradientów sprzężonych (500 epok) oraz algorytmem Lovenberga-Marquardta (1000 epok). W efekcie otrzymano efektywny model neuronowy, którego jakość zdolności klasyfikacyjnych przedstawia rys. 9.

W celu określenia wagi znaczenia poszczególnych zmiennych wejściowych (*a priori* przyjętych cech reprezentatywnych), wykonano analizę wrażliwości wygenerowanego modelu neuronowego [7]. W oparciu o zaimplementowany w pakiecie Statistica v.7.0 moduł „Analiza wrażliwości” wykazano, że najwyższe rangi posiadają zmienne wejściowe reprezentujące kształt ziarniaków, tzn. współczynniki n_1 , n_2 , n_3 . Oznacza to, że wytworzony model neuronowy jest mało wrażliwy na zmiany wartości cech a ,

b oraz m , opisujących wymiar oraz orientację przestrzenną modelowanych ziarniaków.

Uwagi końcowe

1. Wytworzony model neuronowy spełnia swoją rolę jako instrument klasyfikujący ziarniaki pszenicy, jęczmienia oraz kukurydzy.
2. Sztuczna sieć neuronowa typu **MLP** wykazuje umiejętność generalizacji wiedzy, bezproblemowo klasyfikując przypadki z poza zbioru uczącego.
3. Superformuła *Johana Gielisa* jest efektywnym narzędziem, przydatnym w procesie definiowania reprezentatywnych cech klasyfikowanych ziarniaków. Wytworzony, w oparciu o nią, model neuronowy upraszcza wybór tych cech, identyfikując związek pomiędzy danymi wejściowymi (w postaci współczynników kształtu) a sygnałem wyjściowym.
4. Podczas procesu uczenia model neuronowy odrzucił składowe równania odpowiadające za opis rozmiaru badanego obiektu oraz jego orientację przestrzenną. Wynika z tego, że podczas opisywania obiektów za pomocą współczynników pozyskanych w oparciu o superformułę, można pominąć proces normalizacji obrazów, co przyspiesza generowanie zbiorów danych uczących.

Klasyfikacja (5) (ziarenka)			
	nazwa.2.5	nazwa.1.5	nazwa.3.5
Wszystk.	40,0000	40,0000	40,0000
Popraw.	40,0000	40,0000	40,0000
Niepopr.	0,0000	0,0000	0,0000
Nieznane	0,0000	0,0000	0,0000
Popraw.(%)	100,0000	100,0000	100,0000
Niepopr.(%)	0,0000	0,0000	0,0000
Nieznane(%)	0,0000	0,0000	0,0000

Rys. 9. Zrzut ekranu pakietu Statistica v.7.0.: „Statystyki opisowe” – klasyfikacja
Fig. 9. The screenshot of Statistica v.7.0 platform.: “Descriptive statistics” – classification

Literatura

- [1] Osowski S.: Sieci neuronowe do przetwarzania informacji: Warszawa: Oficyna Wydawnicza Politechniki Warszawskiej, 2000.
- [2] Hertz J., Krogh A., Palmer R. G.: Wstęp do teorii obliczeń neuronowych. Warszawa: WNT, 1993.
- [3] Boniecki P.: Sieci neuronowe typu MLP oraz RGB jako komplementarne modele aproksymacyjne w procesie predykcji plonu pszenżyta. Journal of Research and Applications in Agricultural Engineering, 2004, Vol. 49(1), s. 28-33.
- [4] Boniecki P., Weres J.: Wykorzystanie technik neuronowych do predykcji wielkości zbiorów wybranych płodów rolnych: Journal of Research and Applications in Agricultural Engineering, 2003, Vol. 48(4), s. 56-60.
- [5] Jaskiewicz A.: Inżynieria oprogramowania. Gliwice: Wydawnictwo Helion S.A., 1997.
- [6] Cieślak K., Superwzór. Foton, 2004, nr 85, s. 27-28, Kraków: Instytut Fizyki Uniwersytetu Jagiellońskiego.
- [7] Tadeusiewicz R., Lula P.: Statistica Neural Networks PL: wprowadzenie do sieci neuronowych. StatSoft Polska, Kraków, 2001.
- [8] <http://www.kik.pcz.czesz.pl/nn/index.php>
- [9] http://edward_ch.republika.pl/
- [10] <http://www.digitalstar.net/microecologies/?cat=3>
- [11] http://local.wasp.uwa.edu.au/~pbourke/surfaces_curves/supershapes3d/
- [12] <http://www.north.one.pl/~tmp-bit/neuronki/>
- [13] http://pl.wikipedia.org/wiki/Johan_Gielis
- [14] http://local.wasp.uwa.edu.au/~pbourke/surfaces_curves/supershapes/
- [15] <http://www.activeart.de/dim-shops/training/SuperShape/>