

ZASTOSOWANIE SIECI NEURONOWYCH DO ZLICZANIA OWADOBÓJCZYCH NICIENI

Jerzy Chojnacki

Katedra Agrotechnologii, Politechnika Koszalińska

Dariusz Tomkiewicz

Katedra Automatyki, Politechnika Koszalińska

Streszczenie. Przeprowadzono badania nad wykorzystaniem sieci neuronowych w komputerowej analizie obrazu do zliczania owadobójczych nicieni. Został opracowany klasyfikator składający się z sieci neuronowej, który na podstawie wektora cech otrzymanych z obrazu klasyfikował obiekty na zdjęciu określając z czy obiekty są nicieniami i z jakiej ilości nicieni się składają. W celu optymalnego wyboru wektora cech zastosowano metodę Optimal Brain Surgeon.

Słowa kluczowe: biologiczny środek ochrony roślin, nicienie, komputerowa analiza obrazu, sieci neuronowe

Wstęp

Sztucznie hodowane larwy inwazyjne owadobójczych nicieni są biologicznym środkiem ochrony roślin stosowanym w rolnictwie ekologicznym i klasycznym [Grewal i in. 2005]. Zmieszane z wodą jako ciecz robocza rozpraszane są za pomocą opryskiwaczy. Obliczone stężenie nicieni w rozpylanej wodzie, mierzone ilością sztuk w 1 mililitrze lub w 1 litrze cieczy, jest miarą zdolności zastosowanego środka do szybkiego zniszczenia agrofaga. Przemysłowa hodowla i przygotowanie owadobójczych nicieni jako środków ochrony roślin wymaga również wyznaczania stężenia larw w cieczy.

Obecnie określanie koncentracji nicieni odbywa się poprzez zliczanie nicieni w niewielkich próbkach cieczy, o pojemności do ok. 1 ml. Wykonują tę czynność obserwatorzy pod mikroskopem. Dokładność liczenia zależy nie tylko od spostrzegawczości obserwatora ale także np. od jego zmęczenia. Sam proces jest długi i żmudny. Konieczne wydaje się więc zastosowanie metody komputerowej analizy obrazu do zliczania nicieni.

Na dokładność metody komputerowej analizy obrazu wpływa w dużej mierze „zdolność rozróżnienia metody” umożliwiającej rozróżnienie nicieni od zanieczyszczeń znajdujących się w próbce oraz w przypadku gdy nicienie znajdują się blisko siebie (tak, że tworzą jeden obiekt) określenie liczby nicieni w pojedynczym obiekcie. Do tego zadania została zastosowana sztuczna sieć neuronowa która pełniła rolę klasyfikatora. Klasyfikator na podstawie zbioru cech opisujących obiekty znajdujące się na obrazie cyfrowym określał czy dany obiekt jest nicieniem i z ilu nicieni się składa.

Celem przeprowadzonych badań było opracowanie aplikacji wykorzystującej metody komputerowego przetwarzania obrazu oraz sztuczne sieci neuronowe, umożliwiającej przyspieszenie określania koncentracji owadobójczych nicieni.

Materiały i metoda

Do badań użyto biopreparatu „Steinernema System” zawierającego larwy inwazyjne owadobójczych nicieni *Steinernema feltiae*. Są one stosowane jako biologiczny środek ochrony roślin do zwalczania ziemiórek [Tomalak 2000].


Stanowisko pomiarowe służące do pozyskiwania obrazu składało się z mikroskopu stereoskopowego „Motic 168”, kamery cyfrowej Moticam 2300” o rozdzielczości 3.0 Megapikseli i komputera z oprogramowaniem do akwizycji obrazu. Zdjęcia nicieni wykonywano się za pomocą kamery cyfrowej zamontowanej na okularze mikroskopu. Kamera przyłączona została za pomocą adaptera z soczewką 0,65 x do mikroskopu. Do wykonania obrazu cieczy z nicieniami używano znajdującego się w mikroskopie obiektywu o powiększeniu 0,7 x. Objętość próby cieczy, poddanej analizie zależała od „pola powierzchni widzenia” kamery i wynosiła 0,1 ml. Liczba zliczanych nicieni zależała od objętości cieczy, którą można było umieścić w „polu widzenia” kamery oraz od stężenia nicieni w próbce.

Obraz cyfrowy próbek cieczy ze znajdującymi się w niej nicieniami był zapisywany na dysku twardym komputera w formacie BMP. Całość operacji związanych z przetwarzaniem obrazu była wykonana przy pomocy aplikacji napisanej w środowisku LabView 7.1 firmy National Instruments. Natomiast obliczenia związane z doбором optymalnego zbioru cech oraz struktury sieci neuronowej były wykonane w środowisku Matlab 6.5 firmy Mathworks. Wyniki klasyfikacji były prezentowane ekspertowi. Równoległe ekspert określał liczbę nicieni znajdujących się w danej próbce oraz czy obiekty wyróżnione przez aplikację są nicieniami a jeżeli są to z ilu nicieni składa się pojedynczy obiekt. Poprawność działania aplikacji określano na podstawie różnicy pomiędzy wskazaniem klasyfikatora i eksperta.

Akwizycja i przetwarzanie obrazu cyfrowego

Pierwszym etapem procesu pomiaru za pomocą metod przetwarzania obrazu jest pozyskanie obrazu. W trakcie etapu pozyskania obrazu głównym problemem było uzyskanie powtarzalnych warunków pomiaru. Sposób oświetlenia został tak dobrany aby uzyskać jak największy kontrast między nicieniami a tłem (rys. 1a).

Kolejnym etapem procesu przetwarzania obrazu była poprawa jakości obrazu. Uzyskane z pierwszego etapu zdjęcia próbek z nicieniami charakteryzowały się niejednorodnym tłem z wyraźnie widoczną nieciągłą krawędzią obszaru zajmowanego przez kroplę wody. Ponadto w cieczy znajdowały się zanieczyszczenia w postaci drobin kurzu. Do wyeliminowania tych zakłóceń zastosowano operacje erozji, dylatacji i filtrację medianową. W następnym kroku przeprowadzono segmentację histogramową umożliwiającą wyodrębnienie obiektów oraz etykietowanie obiektów (rys. 1b).



Rys. 1. Obraz cyfrowy nicieni a) obraz po akwizycji z mikroskopu, b) obraz po operacji etykietowania

Fig. 1. Digital image of nematoda: a) image after acquisition from microscope, b) image after labelling operation

Owadobójcze nicienie, w zależności od gatunku, mają długość od 0,5–1,45 mm a szerokość od ok. 0,018–0,046 mm [Poinar 1990]. Taka rozpiętość rozmiarów larw wymaga wstępnego wprowadzenia danych w programie, dotyczących klasyfikowanych obiektów, dla poszczególnych gatunków nicieni.

Obszary wyodrębnione na obrazie zawierały oprócz pojedynczych nicieni grupy składające się z kilku nicieni, zanieczyszczenia o rozmiarze zbliżonym do powierzchni pojedynczego nicienia oraz odbicia światła na krawędzi kropli. Powodowało to powstawanie błędów podczas zliczania nicieni na podstawie liczby obiektów. W celu eliminacji tego błędów zastosowano klasyfikator w postaci sztucznej sieci neuronowej.

Klasyfikator neuronowy

Jako klasyfikator wybrano sztuczną sieć neuronową. Ze względu na to że sieć z pojedynczą warstwą ukrytą może aproksymować dowolną funkcję, zdecydowano się na

sieć o takiej strukturze. Funkcje przejścia w neuronach znajdujących się w warstwie ukrytej były w postaci tangensa hiperbolicznego. W warstwie wyjściowej znajdował się pojedynczy neuron z liniową funkcją przejścia. Działanie sieci neuronowej o strukturze przedstawionej powyżej zależy od doboru optymalnego zbioru danych wejściowych, liczby neuronów w warstwie ukrytej oraz doboru wag wzmacniających lub osłabiających sygnały przenoszone pomiędzy neuronami. Optymalny wektor cech oraz liczba neuronów w warstwie ukrytej była dobrana przy zastosowaniu metody używanej do celu redukcji rozmiarów sieci neuronowej o nazwie Optimal Brain Surgeon (OBS) [Zawada 2004]. Metoda ta polega na analizie wrażliwości zmian funkcji celu na zastąpienie wartości wagi obliczonej podczas procesu uczenia na wagę o wartości zero, co jest jednoznaczne z usunięciem danego połączenia. Wartość wpływu funkcji kosztów na zmianę i -tej wartości wagi jest opisana poprzez równanie (1):

$$\delta E_i = \frac{1}{2} H_{ii} u_i^2 \quad (1)$$

gdzie:

- δE_i – wartość wpływu funkcji kosztów na zmianę i -tej wartości wagi,
- u_i – wartość i -tej wagi,
- H_{ii} – i -ty element na przekątnej głównej macierzy drugich pochodnych funkcji celu.

Metoda OBS została zastosowana do wyboru optymalnego wektora cech wprowadzanych na wejście sieci neuronowej. Procedura optymalnego wyboru wektora cech polegała na przygotowaniu zbiorów uczącego i testującego z informacjami uzyskanymi od eksperta które obiekty wyodrębnione na obrazie cyfrowym są nicieniami i z jakiej liczby nicieni się składają. Jeżeli obiekt nie był nicieniem przypisywano mu wartość zero, jeżeli składał się z jednego nicienia przypisywano mu wartość jeden, z dwóch dwa itd.. Na wejście sieci neuronowej początkowo podano wektor składający się z osiemdziesięciu dwóch wartości opisujących poszczególne obiekty. Tak przygotowany wektor cech został wprowadzony do sieci neuronowej. Procedura optymalizacyjna Levenberga–Marquardta wyszukiwała optymalne wartości wektora wag sieci neuronowych, następnie wektor wag oraz macierz drugich pochodnych funkcji celu były podstawiane do równania (1). W wyniku obliczeń otrzymywano wektor δE_i opisujący wpływ i -tej wagi na zmianę wartości wyjściowej. Jeżeli dla wag w warstwie wyjściowej wartość δE_i była mniejsza niż przyjęta wartość progowa uznawano, że dana cecha nie ma istotnego znaczenia dla poprawności klasyfikacji i była odrzucana. Procedurę powtarzano czterokrotnie jej przebieg został przedstawiony w tabeli 1.

Ostatecznie wybrano cechy oznaczone w tabeli 1 numerami: 22 – maksymalna średnica Fereta obiektu, 28 – ekwiwalentna przekątna prostokąta obiektu, 34 – pole powierzchni obiektu, 36 - pole powierzchni obiektu i otworów wewnątrz obiektu, 37 - pole powierzchni łuski wypukłej obiektu, 53 - suma wartości wzdłuż osi y dla obiektu, 56 - suma wartości wzdłuż osi xy dla obiektu, 59 - suma wartości wzdłuż osi xyy dla obiektu. Dodatkowo w każdym etapie uczenia był wprowadzony wektor o własnościach białego szumu - 82.

Zastosowanie sieci neuronowych...

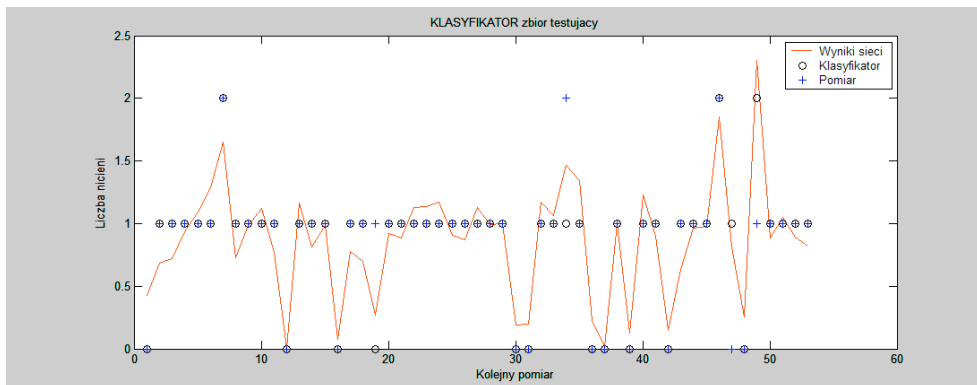
Tabela 1. Przebieg procesu wyboru optymalnego wektora cech dla klasyfikatora neuronowego, cechy wytypowane w poszczególnych etapach zaznaczono ciemnym kolorem

Table 1. The progress of the process involving selection of optimal characteristics vector for neural classifier; characteristics marked out at individual stages are highlighted with dark colour

Nr	Cecha	I etap	II etap	III etap	IV etap	Nr	Cecha	I etap	II etap	III etap	IV etap
1	Center of Mass X					42	Orientation				
2	Center of Mass Y					43	Max Feret Diameter Orientation				
3	First Pixel X					44	% Area/Image Area				
4	First Pixel Y					45	% Area/(Particle & Holes' Area)				
5	Bounding Rect Left					46	Ratio of Equivalent Ellipse Axes				
6	Bounding Rect Top					47	Ratio of Equivalent Rect Sides				
7	Bounding Rect Right					48	Elongation Factor				
8	Bounding Rect Bottom					49	Compactness Factor				
9	Max Feret Diameter Start X					50	Heywood Circularity Factor				
10	Max Feret Diameter Start Y					51	Type Factor				
11	Max Feret Diameter End X					52	Sum X				
12	Max Feret Diameter End Y					53	Sum Y				
13	Max Horiz. Segment Length Left					54	Sum XX				
14	Max Horiz. Segment Length Right					55	Sum XY				
15	Max Horiz. Segment Length Row					56	Sum YY				
16	Bounding Rect Width					57	Sum XXX				
17	Bounding Rect Height					58	Sum XXY				
18	Bounding Rect Diagonal					59	Sum XYY				
19	Perimeter					60	Sum YYY				
20	Convex Hull Perimeter					61	Moment of Inertia XX				
21	Holes' Perimeter					62	Moment of Inertia XY				
22	Max Feret Diameter					63	Moment of Inertia YY				
23	Equivalent Ellipse Major Axis					64	Moment of Inertia XXX				
24	Equivalent Ellipse Minor Axis					65	Moment of Inertia XXY				
25	Equivalent Ellipse Minor Axis (Feret)					66	Moment of Inertia XYY				
26	Equivalent Rect Long Side					67	Moment of Inertia YYY				
27	Equivalent Rect Short Side					68	Norm. Moment of Inertia XX				
28	Equivalent Rect Diagonal					69	Norm. Moment of Inertia XY				
29	Equivalent Rect Short Side (Feret)					70	Norm. Moment of Inertia YY				
30	Average Horiz. Segment Length					71	Norm. Moment of Inertia XXX				
31	Average Vert. Segment Length					72	Norm. Moment of Inertia XXY				
32	Hydraulic Radius					73	Norm. Moment of Inertia XYY				
33	Waddel Disk Diameter					74	Norm. Moment of Inertia YYY				
34	Area					75	Hu Moment 1				
35	Holes' Area					76	Hu Moment 2				
36	Particle & Holes' Area					77	Hu Moment 3				
37	Convex Hull Area					78	Hu Moment 4				
38	Image Area					79	Hu Moment 5				
39	Number of Holes					80	Hu Moment 6				
40	Number of Horiz. Segments					81	Hu Moment 7				
41	Number of Vert. Segments					82	White Noise				

Wyniki uzyskiwane na wyjściu sieci neuronowej przedstawiono na rysunku 3. Wartość wyjściowa z sieci neuronowej była liczbą rzeczywistą. W związku z tym w następnym kroku była zaokrąglana do najbliższej wartości całkowitej i porównywana z wartościami określonymi przez eksperta. Dla zbiorów testujących maksymalny błąd wynosił cztery błędne klasyfikacje dla obrazów na których znajdowało się około pięćdziesiąt obiektów. Dla maksymalnego błędu oszacowania niedokładność wynosiła 8%.

Analizując kształt obiektów sklasyfikowanych poprawnie oraz błędnie można zauważyć, że sieć neuronowa miała problemy z klasyfikacją tylko w przypadku obiektów o niejednoznacznym kształcie (tab. 2).



Rys. 2. Wyniki działania klasyfikatora dla przykładowego obrazu, linia ciągła – wartość wyjściowa z sieci neuronowej, + – liczba nicieni określona przez eksperta, O – liczba nicieni określona przez sieć neuronową

Fig. 2. Classifier operation results for an example image, solid line – output value from neural network, + – the number of nematoda determined by an expert, O – the number of nematoda determined by neural network

Tabela 2. Obiekty błędnie sklasyfikowane dla przykładowego obrazu
Table 2. Objects incorrectly classified for an example image

Nr obiektu	Obiekt	Klasyfikator	Ekspert
19		0	1
34		1	2
47		1	0
49		2	1

Wnioski

Zastosowanie metody zliczającej liczbę nicieni umożliwiło przyspieszenie badań związanych z określeniem przeżywalności nicieni. Sieć neuronowa wraz z algorytmem OBS umożliwia wybór optymalnego wektora cech opisujących znajdujące się na obrazie cyfrowym obiekty a tym samym redukcję rozmiaru sieci i poprawę zdolności generalizowania sieci. Maksymalny błąd działania klasyfikatora wynosi osiem procent.

Praca naukowa finansowana ze środków na naukę w latach 2007–2010 jako projekt badawczy nr N 310 049 32/2537.

Bibliografia

- Poinar Jr., G.O.** 1990. Biology and taxonomy of Steinernematidae and Heterorhabditidae. In: Gaugler, R., Kaya, H.K. (Eds.), *Entomopathogenic Nematodes in Biological Control*. CRC Press, Boca Raton, FL, s. 23-62.
- Grewal P.S., Ehlers R.U., Shapiro-Ilan D.I.** 2005. *Nematodes as biocontrol agents*. CAB International. ISBN 0851990177.
- Zawada-Tomkiewicz A., Tomkiewicz D.** 2004. The Application of Optimal Brain Surgeon Method for Optimisation of Tool Wear Estimator Structure, *Poliptymalizacja i Komputerowe Wspomaganie Projektowania t. III*, WNT.

USING NEURAL NETWORKS TO COUNT INSECTICIDAL NEMATODA

Abstract. The scope of the research involved studies on applying neural networks in computer image analysis for the purposes of counting insecticidal nematoda. The researchers developed a classifier consisting of a neural network, and classifying objects shown on a photo according to the vector of characteristics obtained from the image. Thus, the classifier was determining whether the objects were nematoda and how many nematoda they contained. The Optimal Brain Surgeon method was employed in order to ensure optimal selection of characteristics vector.

Key words: biological plant pesticide, nematoda, computer image analysis, neural networks

Adres do korespondencji:

Jerzy Chojnacki; jerzy.chojnacki@poczta.onet.pl
Katedra Agrotechnologii
Politechnika Koszalińska
ul. Raławicka 15-17
75-620 Koszalin