

NEURONAL IDENTIFICATION OF THE CHOSEN CEREAL PESTS ON THE BASIS OF INFORMATION CONTAINED IN THE FORM OF TWO-DIMENSIONAL PICTURES

Summary

Digital signal processing (DSP) is the science and technology domain dealing with signals in a digital representation and the processing methods of these signals. DSP and analog signal processing are subfields of signal processing. Since the goal of DSP is usually to measure or filter continuous real-world analog signals, the first step is usually to convert the signal from an analog to a digital form, by using an analog to digital converter. Often, the required output signal is another analog input signal for neuronal models. The neuronal pictures analysis is then a new field of digital processing of signals. It is possible to use it to identification of chosen objects given in the form of bitmap.

NEURONOWA IDENTYFIKACJA WYBRANYCH SZKODNIKÓW ZBÓŻ W OPARCIU O INFORMACJĘ ZAWARTĄ W POSTACI DWUWYMIAROWYCH OBRAZÓW

Streszczenie

Cyfrowe przetwarzanie sygnałów (CPS; ang. Digital Signal Processing, DSP) jest dziedziną nauki i techniki zajmującą się sygnałami w postaci cyfrowej i metodami ich przetwarzania. Cyfrowe przetwarzanie sygnałów i analogowe przetwarzanie sygnałów są gałęziami nadrzędnej dyscypliny: przetwarzania sygnałów. Pierwszym etapem cyfrowego przetwarzania sygnałów jest zazwyczaj konwersja sygnału z postaci analogowej na cyfrową za pomocą przetwornika analogowo-cyfrowego. Często sygnał przetworzony cyfrowo jest sygnałem wejściowym dla modelu neuronowego. Neuronowa analiza obrazów to nowa dziedzina cyfrowego przetwarzania sygnałów. Można ją wykorzystać do identyfikacji wybranych obiektów występujących w postaci bitmapy.

Wprowadzenie

Jednym z celów prac prowadzonych w obszarze badawczym określanym mianem sztucznej inteligencji jest doprowadzenie do sytuacji, w której za pomocą komputerów można będzie realizować przetwarzanie informacji w podobny sposób, jak czyni to człowiek. Zakres poszukiwań naukowców obejmuje coraz to większy obszar badawczy, wynikający z pojawiających się pytań związanych z wieloma, często bardzo różnymi dziedzinami nauki. Dynamikę tego procesu generuje postęp techniczny oraz technologiczny, jaki obserwowany jest w ostatnich czasach, a szczególnie w szeroko rozumianej informatyce. Skutkiem tego można zauważyć, że zadania rozwiązywane do niedawna tylko przez ludzi, dzisiaj wykonują automaty wspomagane przez super wydajne komputery. Rosnąca moc obliczeniowa sprzętu oraz nowoczesne metody inżynierii oprogramowania umożliwiają wytwarzanie oraz eksploatację wyrafinowanych systemów informatycznych, występujących m.in. w postaci coraz doskonalszych cyfrowych symulatorów sztucznych sieci neuronowych.

Dziedzina analizy oraz rozpoznawania obrazów z wykorzystaniem modeli neuronowych jest stosunkowo nową gałęzią informatyki i ściśle wiąże się z badaniami nad sztuczną inteligencją. Modele neuronowe stanowią istotne wsparcie oraz uzupełnienie dla klasycznych metod identyfikacyjnych, posiadając przy tym pewne cechy (jak np. szybkość działania) dające istotną przewagę nad technikami tradycyjnymi. Przykładowym aspektem użytecznym może być szerokie wykorzystanie metod neuronowego rozpoznawania obrazów w aplikacjach typu *OCR (Optical Character Recognition)* służących m.in. do przetwarzania mapy bitowej do postaci tekstowej (rozpoznawanie pisma), czy

OMR (Optical Mark Recognition) do odczytywania kodów kreskowych.

Proces optycznej identyfikacji obiektów na podstawie informacji graficznej ma istotne znaczenie również w szeroko rozumianym rolnictwie. Rozpoznawanie obrazów kojarzy się na ogół z identyfikacją obiektów prezentowanych w postaci dwuwymiarowej fotografii lub trójwymiarowej sceny, jednak problem ten obejmuje znacznie szerszy obszar zastosowań. W postaci graficznej można przecież przedstawić również dźwięki, wahania temperatury czy różnego rodzaju czynniki ekonomiczne itd.

Podstawowymi czynnościami mającymi na celu zidentyfikowanie obiektu występującego w postaci graficznej (na ogół w postaci bitmapy) jest akwizycja obrazów, a następnie ekstrakcja i rozpoznanie cech reprezentatywnych badanych obiektów. Następnie dokonuje się ich analizy, zgodnie ze zdefiniowaną wcześniej funkcją celu [2].

Metodyka badań

Rozwój rolnictwa wiąże się między innymi z wprowadzaniem nowych technologii wspomagających i ułatwiających prace. Dlatego tworzenie oprogramowania z wykorzystaniem sztucznych sieci neuronowych na potrzeby rolnictwa to korzystne połączenie najnowszych dobrodziejstw nauki z dziedziną, która w Polsce zajmuje znaczącą pozycję.

Celem pracy była analiza możliwości wykorzystania sztucznych sieci neuronowych do rozpoznawania wybranych obiektów rolniczych, przedstawionych w postaci dwuwymiarowych obrazów. W związku z tym zostało wytworzone niezbędne oprogramowanie do digitalizacji obrazu (w oparciu o kryterium barwy zgodnie z modelem *RGB*). Dalszym etapem było zaprojektowanie, budowa

oraz testowanie systemu informatycznego „*Szkodniki*” przeznaczonego do rozpoznawania wybranych szkodników zbóż. Pierwsza aplikacja posłużyła do wygenerowania danych treningowych dedykowanych dla proponowanej topologii sztucznej sieci neuronowej. Druga natomiast stanowi praktyczne narzędzie do rozpoznawania szkodników zbóż prezentowanych systemowi informatycznemu w postaci zdjęć cyfrowych. Wytworzony system informatyczny „*Szkodniki*” wykorzystuje w swej strukturze radialną sieć neuronową typu **RBF** (*Radial Basis Function*), która w testach wykazała najlepsze właściwości identyfikacyjne. Rozpoznawane obrazy to dwuwymiarowe zdjęcia wybranych szkodników zbóż, które w sposób istotny różniły się kolorem [6]. W związku z tym za nadrzędną cechę reprezentatywną uznano barwę szkodników prezentowanych w postaci mapy rastrowej (bitmapy) w oparciu o model koloru **RGB**.

Radialny model neuronowy

Sieci o radialnych funkcjach bazowych (**RBF**) należą do klasy sieci jednokierunkowych uczonych metodą hybrydową. Posiadają jedną ukrytą warstwę radialną uczoną jedną z technik bez nauczyciela oraz liniową warstwę wyjściową, uczoną nadzorowaną metodą pseudoinwersji. Sieć radialna **RBF** to sieć, w której każdy neuron na wyjściu określa kwadrat odległości bieżącego wektora wejściowego do swojego wektora wag. Sygnały wejściowe o jednakowych funkcjach wejściowych pod względem wartości przyjmują na płaszczyźnie dwuwymiarowej formę koła, co sprawia, że funkcje sieci o symetrii radialnej nazywa się czasami sieciami posiadającymi „funkcje o symetrii kołowej”. Funkcje te ze względu na swoją ważną pozycję przy tworzeniu sygnału wyjściowego nazywane są również bazowymi funkcjami radialnymi. Odległość określona przez każdy neuron jest modulowana maksymalnym odchyleniem (wartość progowa), po którego przekroczeniu sygnał wyjściowy neuronu przyjmuje wartości zbliżone do zera. Wartość progowa określa maksymalny promień wyznaczanych przez funkcje okręgów [4].

Uczenie sieci neuronowej typu **RBF** z uwzględnieniem wybranego typu radialnej funkcji bazowej sprowadza się do doboru centrów i parametrów kształtu funkcji bazowych oraz doboru wag neuronów warstwy wyjściowej. Wektor wagowy może być wyznaczony przez pseudoinwersję macierzy prostokątnej. Najtrudniejsze w uczeniu sieci radialnych jest odpowiedni dobór parametrów nieliniowych, a szczególnie centrów. Najprostszym sposobem określenia funkcji bazowych jest dobór losowy gdzie centra funkcji bazowych, przy założeniu rozkładu równomiernego, są ustalane losowo. Lepsze rezultaty uzyskuje się korzystając przy doborze centrów z procesu samoorganizacji. Proces ten służy do podziału na klastry danych uczących. Początkowy dobór centrów jest wybierany losowo następnie uruchamiany zostaje proces samoorganizacji. Przedstawiany jest wzorzec następnie wybierane jest centrum najbliższe wzorcowi. Usytuowanie centra modyfikowane jest zgodnie z regułą „zwycięzca bierze wszystko”. Centrum klastra jest jednocześnie centrem funkcji radialnej, więc ilość klastrów odpowiada ilości funkcji radialnych.

Tworzenie zbioru uczącego

Zbiór uczący został wytworzony w oparciu o cyfrowe zdjęcia w postaci bitmapy trzech wybranych szkodników zbóż. W projekcie zostały uwzględnione następujące owa-
dy:

- m s z y c a (rys. 1) będąca bardzo groźnym szkodnikiem o niewielkim rozmiarze (1,5-3 mm). Pojawia się ona nagle i masowo. Posiada ponadto zdolność do szybkiego uodparniania się na insektycydy. Najgroźniejsze dla zbóż są mszyce zbożowe i czeremchowo-zbożowe, które atakują górne liście i kłos. Mszyce, w zależności od gatunku, mogą mieć barwę czarną, brązową, czerwoną, zieloną lub żółtą. Żerują na młodych, soczystych pędach wierzchołkowych roślin, na liściach, a także na kwiatostanach i pąkach kwiatowych. Największe zagrożenie stanowią w okresie kłoszenia zbóż. Żerowanie mszyc prowadzi do spadku masy 1000 nasion oraz sprzyja rozwojowi chorób, a zwłaszcza rosy miodowej. 5 szt. na 1 źdźbło obniża plon od 10 do 15%.

- p r y s z c z a r e k z b o ż o w i e c (rys. 2) to szkodnik podobny do komara, żółtopomarańczowy o długości 3-6mm. Stadium szkodliwym jest larwa ceglastoczerwona z prześwitującym zielonkawym jelitem. Jaja złożone na liściach uszkadzają międzywęzła, powodują łamanie się roślin, ograniczają kłoszenie, bardzo drobne ziarno. Atakują pszenice, jęczmień, żyto oraz różne rodzaje traw. W zwalczaniu występowania szkodnika ważną czynnością jest zabieg głębokiej orki jesiennej, gdyż duża część larw przed zniwami schodzi pod ziemię, oraz zmianowanie.

- s k r z y p i o n k i (rys. 1); Rozpoznaje się ok. 800 gatunków skrzypionek, najczęściej występujące to: skrzypionka zbożowa (*Lema melanopa*), osiągająca 3-5 mm długości, o zielonym lub niebieskim ubarwieniu pokryw skrzydłowych, z metalicznym połyskiem, oraz czerwonym przedpleczem, występująca masowo w całej Europie na uprawach owsa, jęczmienia i pszenicy, a także skrzypionek błękitek (*Lema cyanella*), żerująca na owsie, oraz skrzypionek (*Lema bilineata*) występująca pierwotnie w Afryce Południowej, przeniesiona do Ameryki Południowej, gdzie stała się szkodnikiem upraw tytoniu i krzewów owocowych. Skrzypionki atakują liście i powodują zahamowanie wzrostu źdźbła i ograniczenie powierzchni asymilacyjnej. Destrukcja liści przebiega w czasie od momentu strzelania w źdźbło do fazy dojrzałości młecznego ziarna. Najbardziej narażone na żerowanie skrzypionek są: pszenica ozima i jęczmień ozimy oraz owies i jęczmień jary.

W celu wygenerowania zbioru uczącego w postaci akceptowalnej przez symulator sztucznych sieci neuronowych zaimplementowany w komercyjnym pakiecie *Statistica v. 7.1* wytworzono aplikację „**Form1**”. Służyła ona do fragmentacji obrazu a następnie konwersji segmentu bitmapy do pliku tekstowego jako wektora uczącego. Występował on w postaci ciągu liczb reprezentujących piksele wskazanego fragmentu (czarny prostokąt na rys. 4.) z uwzględnieniem 3 składowych modelu koloru **RGB**.

Dla fragmentu obrazu o wymiarze 8• 8 ciąg (jeden przypadek uczący) składał się z 8• 8• 3=192. Dla fragmentu obrazu 16• 16 ilość zmiennych wynosiła 16• 16• 3=768 natomiast dla 32• 32 odpowiednio 32• 32• 3=3072. W tym ostatnim przypadku, w celu odciążenia symulatora od tak dużej liczby zmiennych wejściowych, wskazana była kompresja danych, które ze względu na swą naturę (ciągłość barw w obrazie) wykazywały dużą korelację wzajemną. W tym celu zastosowano

nieliniową kompresję z wykorzystaniem neuronowej sieci *autoasocjacyjnej* [1]. Powyższa procedura stanowiła zatem element *preprocessingu* („obróbki” danych empirycznych do postaci właściwej dla symulatora sieci) poprzedzającego proces generowania topologii sztucznej sieci neuronowej z wykorzystaniem modułu *Statistica v. 7.1*. Omówiona technika użyta została do wygenerowania zbioru 90 przypadków uczących (po 30 dla każdego szkodnika).



Rys. 1. Mszyca czeremchowo-zbożowa
Fig. 1. *Rhopalosiphum padi* L.



Rys. 2. Pryszczarek zbożowiec (dorosły owad)
Fig. 2. *Haplodiplosis equestris* Wagner (grown-up insect)



Rys. 3. Skrzypionki
Fig. 3. *Oulema* spp.

Przykładowy fragment zbioru uczącego (dla wariantu 16•16 generującego 768 zmiennych) w postaci zrzutu formularza edytora danych symulatora SNN, przedstawiono na rys. 5.

Wykorzystując efektywną opcję „Automatycznego projektanta”, zaimplementowaną w symulatorze SNN, wygenerowano, przetestowano i zweryfikowano zbiór sieci neuronowych, z których wybrano 10 najlepszych. Siecią, która wykazała najmniejszy błąd *RMS* okazała się sieć neuronowa typu *RBF* o strukturze 768-192-1 przedstawiona na rys. 6.


Jakość wytworzonej sieci można wizualnie przedstawić za pomocą tzw. macierzy pomyłek (rys. 7.)

Jak przedstawia okno „macierzy pomyłek”, wygenerowana sieć została nauczona poprawnie. Kolumny tabeli odpowiadają klasom rzeczywistym, zaś wiersze klasom prognozowanym. Tylko jeden przypadek należący do klasy pierwszej został błędnie przypisany klasie drugiej.

Opis systemu informatycznego „Szkodniki”

Wstępną fazą budowy systemu informatycznego było określenie wymagań stawianych projektowanej aplikacji. Postawione zostały określone cele, zaproponowany został zakres oraz zaprezentowano ramowy opis systemu informatycznego „Szkodniki”. W fazie projektowania, wykonane zostały podstawowe diagramy mające na celu wizualizację implementacji systemu. Diagram przypadków użycia przedstawiono na rys. 8. Diagram klas systemu „Szkodniki” przedstawiono na rys. 9. Diagram czynności systemu „Szkodniki” przedstawiono na rys. 10.


Spośród dostępnych narzędzi programistycznych wybrany został *Borland C++ Builder v.6.0*. Kod symulujący działanie sieci neuronowych został wygenerowany z wykorzystaniem modułu „Generator kodu” zaimplementowanego w komercyjnym pakiecie *Statistica v.7.1*. Otrzymany kod w języku *C* został poddany drobnym zmianom adaptacyjnym, w celu lepszego dostosowania go do środowiska programistycznego *Borland C++ Builder v.6*. Wytworzony następnie system informatyczny „Rozpoznawanie cyfr” opiera się na tym kodzie i stanowi jądro wytworzonej aplikacji. Wygląd okna głównego programu „Szkodnik” przedstawia rys. 11.



Rys. 4. Główny interfejs użytkownika programu
Fig. 4. Main user interface of program

	757 Zmn758	758 Zmn759	759 Zmn760	760 Zmn761	761 Zmn762	762 Zmn763	763 Zmn764	764 Zmn765	765 Zmn766	766 Zmn767	767 Zmn768	768 Zmn769	769 Robak
73	90	102	52	61	64	25	33	25	2	19	5	0	3
74	10	2	3	7	0	0	12	3	0	68	60	53	3
75	9	12	16	9	10	14	29	30	34	15	14	16	3
76	43	25	14	102	86	70	83	67	51	18	2	0	3
77	68	30	6	65	34	11	55	40	14	97	93	69	3
78	52	51	41	95	99	88	102	107	98	28	32	26	3
79	14	0	3	16	1	5	16	1	5	14	0	3	3
80	11	4	1	9	1	0	19	13	2	88	85	70	3
81	5	0	1	11	1	1	15	3	0	34	18	5	3
82	5	0	0	5	0	0	4	0	1	5	0	2	3
83	65	29	13	72	32	14	80	40	21	61	25	7	3
84	18	2	3	14	0	2	13	0	2	10	0	0	3
85	28	12	5	36	19	10	42	24	13	70	54	38	3
86	42	42	54	42	43	53	58	54	65	48	41	54	3
87	19	13	18	4	1	3	7	2	1	11	0	0	3
88	18	2	0	18	3	0	15	0	0	12	0	0	3
89	18	4	6	15	1	2	15	3	3	12	0	0	3

Rys. 5. Fragment zbioru uczącego
Fig. 5. Fragment of teaching file

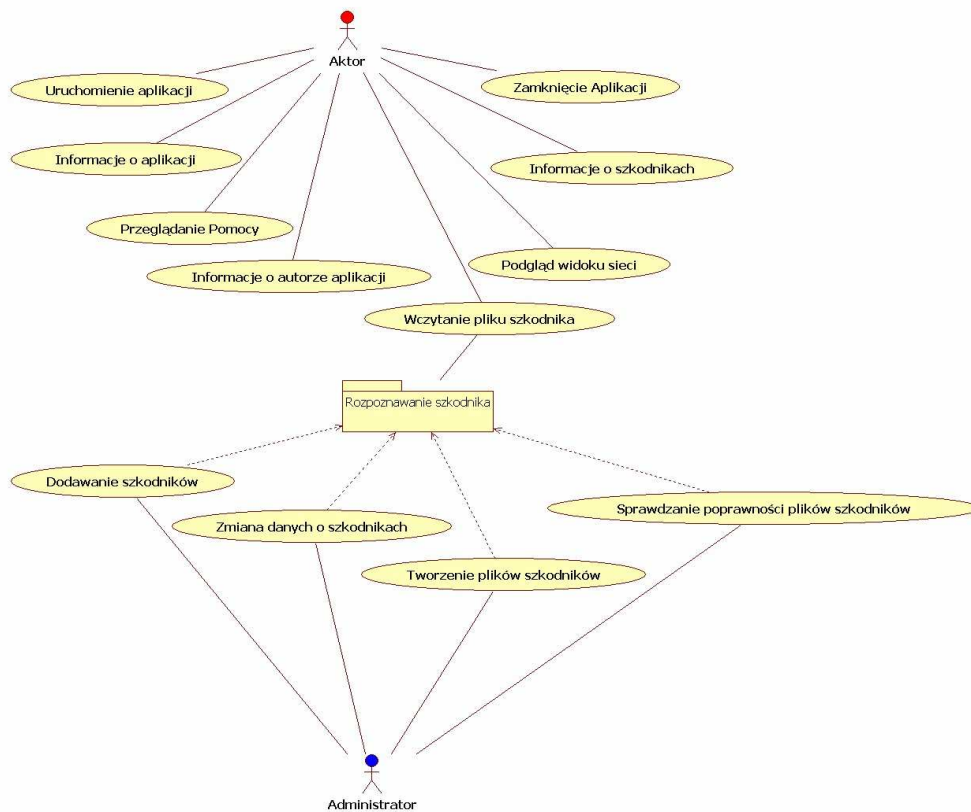


Rys. 6. Topologia sieci neuronowej typu **RBF**
Fig. 6. Topology of neural network type **RBF**

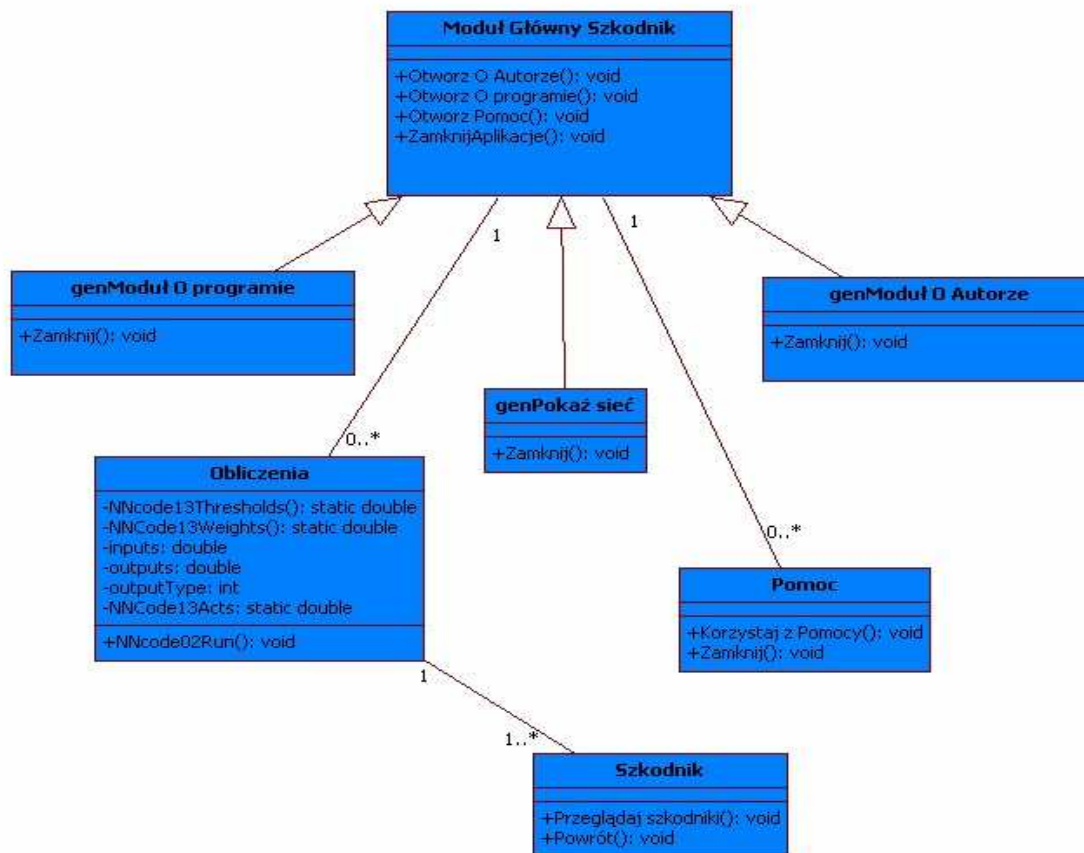
Dane: wszystkie szkodniki.sta (770 zmn. * 185 prz.)														
	1 rozd	2 Zmn2	3 Zmn3	4 Zmn4	5 Zmn5	6 Zmn6	7 Zmn7	8 Zmn8	9 Zmn9	10 Zmn10	11 Zmn11	12 Zmn12	13 Zmn13	14 Zm
1	16	197	245	249	188	245	247	174	248	248	147	250	247	
2											99	137	119	
3											41	192	176	
4											78	163	141	
5											74	199	184	
6											38	206	189	
7											83	198	181	
8											210	240	241	
9											36	193	173	
10											77	189	177	
11											168	229	233	
12											51	219	207	
13											109	232	236	
14											155	255	254	
15											90	218	207	
16											86	214	202	
17											15	139	123	
18											36	190	162	

Macierz pomyłek - Robak(3) (wszystkie szkodniki.sta)			
	1	2	3
1.3	29,00000	0,00000	0,00000
2.3	1,00000	30,00000	0,00000
3.3	0,00000	0,00000	29,00000

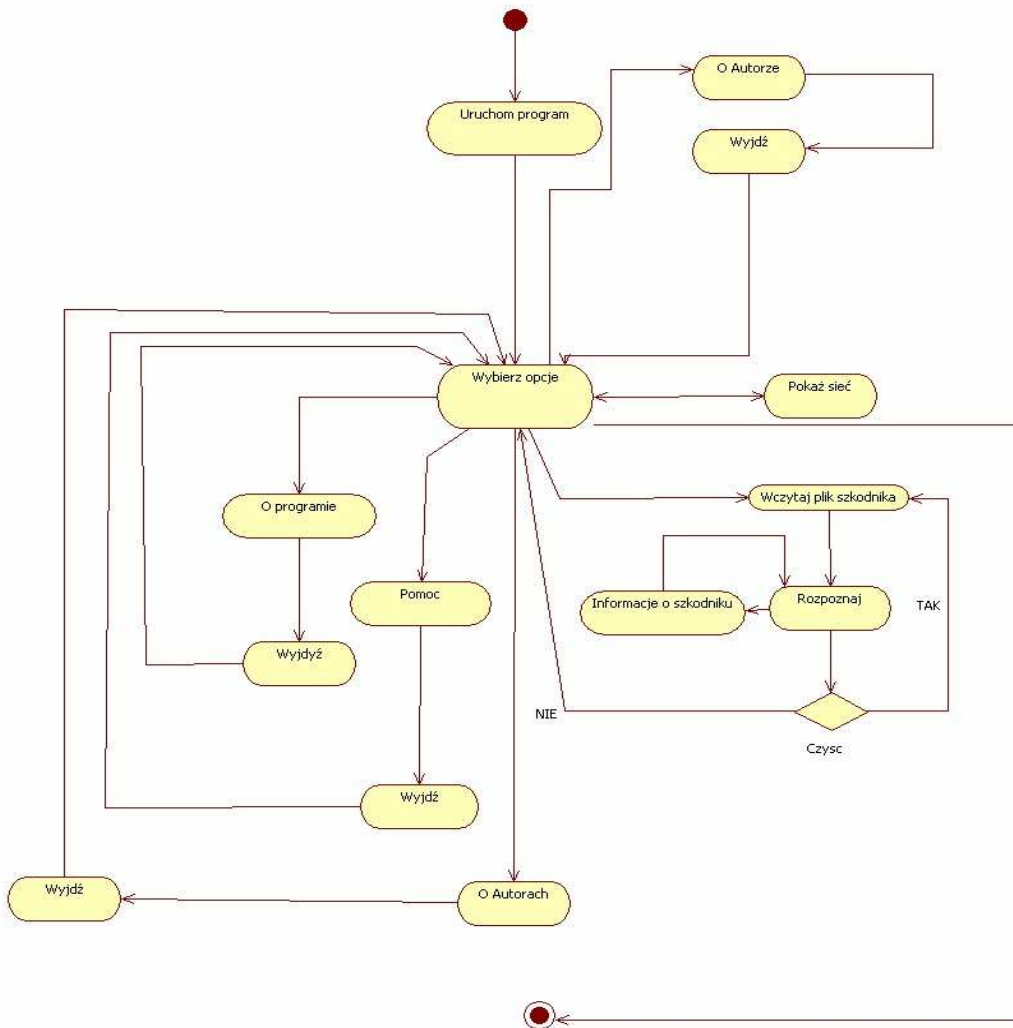
Rys. 7. Macierz pomyłek
Fig. 7. Matrix of mistakes



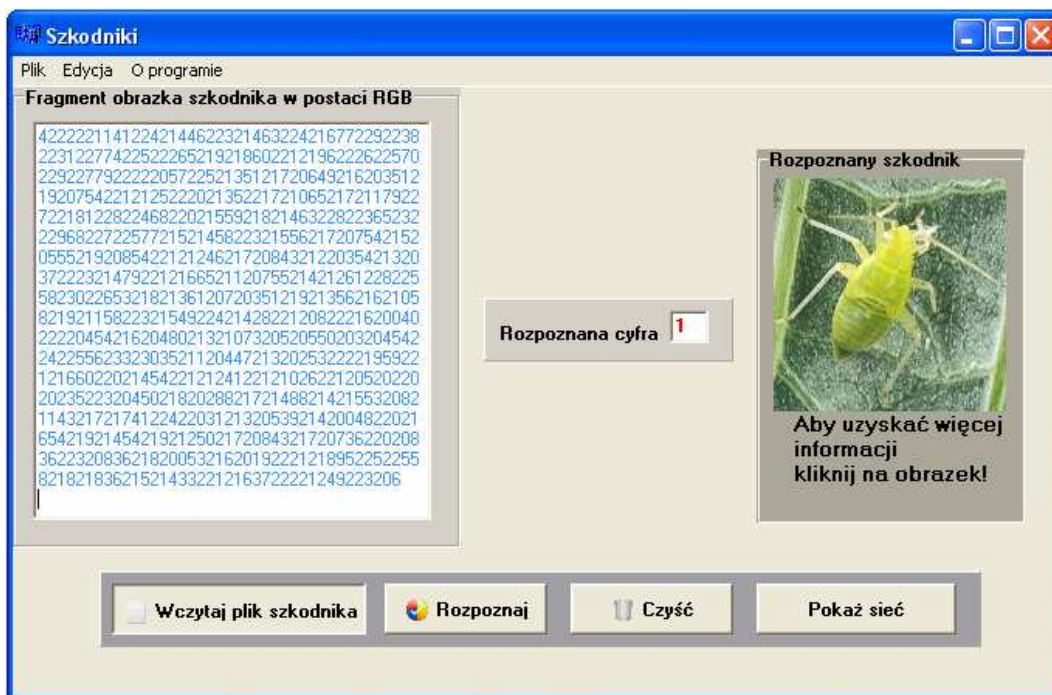
Rys. 8. Diagram przypadków użycia dla systemu „Szkodniki”
 Fig. 8. Diagram of cases of use for system „Szkodniki”



Rys. 9. Diagram klas systemu informatycznego „Szkodniki”
 Fig. 9. The class diagram of computer system „Szkodniki”



Rys. 10. Diagram czynności systemu informatycznego „Szkodniki”
 Fig. 10. The activity diagram of computer system „Szkodniki”



Rys. 11. Wygląd okna głównego programu „Szkodniki”
 Fig. 11. Main window of computer system „Szkodniki”

Aplikacja została przetestowana zarówno dla wygenerowanego kodu jak również po utworzeniu poszczególnych jej modułów.

Wymagania niefunkcjonalne

- Aby system działał bezproblemowo, potrzebne są:
- komputer klasy PC z systemem operacyjnym Windows®,
 - pamięć operacyjna: co najmniej 64MB,
 - rozdzielczość ekranu: co najmniej 800• 600 pikseli.

Wytworzone oprogramowanie przetestowano na następujących komputerach:

- AMD Duron Procesor 801 MHz, 256 MB RAM,
- AMD Athlon Procesor 1900+XP 1,65 GHz, 1 GB RAM,
- Intel Pentium Procesor 2,8 GHz, 512 MB RAM,
- AMD Sempron™ 2800+ 2 GHz, 448 RAM.

Wnioski

W toku realizacji pracy wytworzono dwie aplikacje, jedną do digitalizacji obrazu oraz drugą do rozpoznawania obrazów wybranych szkodników zbóż. Zaprojektowano oraz wytworzono sieć typu **RBF**, którą zaimplementowano w aplikacji „*Szkodniki*”. Rezultaty pracy pozwalają wprowadzić następujące wnioski:

1. Wytworzona aplikacja do digitalizacji obrazu prawidłowo zamienia kolory na postać liczbową odpowiadającą skali **RGB**. Z powodzeniem może być wykorzystywana do dyskretyzacji innych obrazów lub zdjęć dwuwymiarowych, dla których podstawą klasyfikacji jest kolor.
2. Zbudowany program „*Szkodniki*” prawidłowo rozpoznaje zadane obrazy i potwierdza skuteczność wykorzystanej sieci **RBF** przy rozpoznawaniu wzorców. Istotne znaczenie podczas uczenia sieci, wpływające na jego jakość, ma liczba przypadków uczących. Większa baza danych wejściowych wpływa na lepszą jakość nauczanej sieci.

3. W celu zwiększenia zakresu użyteczności aplikacji niezbędne jest rozbudowanie bazy danych wejściowych, co umożliwi rozpoznawanie większej liczby szkodników.
4. Aplikacje spełniają wymagania funkcjonalne a przedstawiony diagram przypadków użycia prawidłowo określa zależności istniejące między użytkownikiem a systemem informatycznym. Diagram klas prezentuje statyczną strukturę klas oraz relacje, jakie zachodzą między nimi w programie.
5. Zaprojektowane aplikacje mogą być wykorzystywane w celach edukacyjnych związanych ze sztucznymi sieciami neuronowymi i ich zastosowaniem w procesie rozpoznawania obrazów w rolnictwie. Programy posiadają czytelny interfejs zaprojektowany z myślą o wygodnym użyciu przez przyszłych użytkowników.

Literatura

- [1] Boniecki P., Przybył J., (2006)., Autoasocjacyjna sieć neuronowa jako narzędzie do nieliniowej kompresji danych: Journal of Research and Applications in Agricultural Engineering (1'2006), str.37-41
- [2] Tadeusiewicz R., Flasiński M., (1991). Rozpoznawanie obrazów: Wydawnictwo Naukowe PWN, Warszawa
- [3] Mirkut Z., Tadeusiewicz R., (2000). Sieci neuronowe tom 6: Akademicka Witryna Wydawnicza EXIT, Warszawa
- [4] Boniecki P., (2004). Sieci neuronowe typu MLP oraz RGB jako komplementarne modele aproksymacyjne w procesie predykcji plonu pszenżyta: Journal of Research and Applications in Agricultural Engineering, POZNAN, (1'2004), Vol. 49(1), str. 28-33
- [5] Kohorda P., Tadeusiewicz R., (1999). Komputerowa analiza i przetwarzanie obrazów: Drukarnia Narodowa, Kraków
- [6] Boniecki P., Piekarska-Boniecka H., (2004). The *SOFM* Neural Network in the Process of Identification of Selected Orchard Pests: Journal of Research and Applications in Agricultural Engineering, Vol 49(4), p. 5-10, Poznań.