

## NEURAL IDENTIFICATION OF THE EMBRYO OF CALF BASED ON ULTRASOUND IMAGES OF THE COW' S WOMB USING COMPUTER SYSTEM „USG RECOGNIZER”

### Summary

The software “USG Recognizer” that was described in this work is equipped with a binarization function with threshold. The application also fulfills some additional functions such as: contrast and closing. With this functionality it is possible to achieve empirical data from digital ultrasound photo of cow's womb. The artificial neural network was generated on the basis of created application. The main purpose of this network is to support an identification or exclusion of the gestation in user's ultrasound picture. “USG Recognizer” was created using Visual Paradigm (UML 8.0) and Microsoft Visual Studio 2010 Professional Edition environments.

**Key words:** cow; womb; pregnancy; ultrasonography, image analysis; artificial intelligence; neural networks; neural modelling, computer systems

## NEURONOWE ROZPOZNANIE CIĄŻY NA PODSTAWIE OBRAZÓW ULTRASONOGRAFICZNYCH MACICY KROWY Z WYKORZYSTANIEM SYSTEMU INFORMATYCZNEGO „USG RECOGNIZER”

### Streszczenie

W pracy zaprezentowano wytworzony, oryginalny system informatyczny „USG Recognizer”, który zaopatrzony został w szereg funkcji wspomagających tworzenie adekwatnych zbiorów uczących, niezbędnych w procesie generowania modeli neuronowych. Dzięki tym funkcjonalnościom możliwa jest identyfikacja oraz ekstrakcja wiedzy zawartej w graficznych danych empirycznych, zakodowanej w postaci cyfrowych zdjęć ultrasonograficznych. W oparciu o zbudowaną aplikację wygenerowana została sztuczna sieć neuronowa, której celem było wspomaganie rozpoznania lub wykluczenia ciąży, dokonanego na podstawie ultrasonogramów macicy krowy. Zaproponowany system informatyczny „USG Recognizer” został zbudowany z wykorzystaniem środowisk: Visual Paradigm (UML 8.0) oraz Microsoft Visual Studio 2010 Professional Edition.

**Słowa kluczowe:** krowa; macica; ciąża; ultrasonografia, analiza obrazu; sztuczna inteligencja; sieci neuronowe; modelowanie neuronowe, systemy informatyczne

### 1. Wprowadzenie

Efektywne monitorowanie rozrodu krów uzależnione jest m.in. od rutynowych badań klinicznych i specjalistycznych. Stan rozrodu jest czułym wskaźnikiem nieprawidłowości występujących w stadzie, który może być kontrolowany i analizowany [1]. W ostatnich latach w intensywnym chowie bydła obserwuje się niepokojące tendencje: znaczące pogorszenie wskaźników rozrodu, skrócenie użytkowności krów, zwiększenie kosztów inseminacji oraz pogorszenie opłacalności produkcji mleka [2, 3]. Wysoka produkcja i jej opłacalność jest efektem regularnego monitoringu weterynaryjnego, który umożliwia m.in.: określenie stanu zdrowia krów, diagnozowanie i leczenie różnego rodzaju zaburzeń, a także wczesne rozpoznanie ciąży. Zauważalny jest wzrost zainteresowania rozwojem specjalistycznego oprogramowania do rozwiązywania problemów związanych m.in. z: diagnozowaniem, wspieraniem diagnozowania oraz analizowaniem danych produkcyjnych i zdrowotnych w stadach bydła. Tendencje w rozwoju współczesnych aparatów ultrasonograficznych wiążą się z doskonaleniem i rozszerzaniem rozwiązań technicznych i programowych [4]. Ultrasonografia (USG) należy do nieinwazyjnych, atraumatycznych technik diagnostycznych. Metoda ta wykorzystuje zjawisko rozchodzenia się, rozpraszania oraz odbicia fal ultradźwiękowych na granicy dwóch ośrodków, przy założeniu stałej prędkości fal propagujących w różnych tkankach. W ultrasonografii medycznej wykorzysty-

wane są częstotliwości z zakresu ok. 2-50 MHz. Fala ultradźwiękowa najczęściej generowana jest, a następnie przetwarzana do postaci impulsów elektrycznych, z wykorzystaniem zjawiska piezoelektrycznego. Pierwsze doświadczenia nad praktycznym zastosowaniem ultrasonografii w szeroko rozumianej diagnostyce medycznej prowadzone były w latach 40. i 50. ubiegłego wieku. Do medycyny ultrasonografy zostały wprowadzone kilka lat później. Warto zauważyć, że jednym z pierwszych klinicznych zastosowań USG była diagnostyka płodu. Pozwala ona m.in. na: wizualizację struktury płodu, określenie jego żywotności, płci, rozpoznanie ciąży bliźniaczej, jak również obserwację dynamiki macicy oraz jajników podczas cyklu rujowego, ciąży i po porodzie [5].

Obecnie ultrasonografia jest łatwo dostępna oraz stosunkowo tania. Obrazy wygenerowane tą techniką są stosunkowo łatwe do pozyskania, zdarza się jednak, że nawet wykwalifikowany operator napotyka na problemy z identyfikacją informacji zawartej na analizowanym ultrasonogramie. Wykorzystanie technik modelowania neuronowego, których zaletą jest odporność na szумы, zawarte w sygnale wejściowym wygenerowanej sieci, pozwala na istotne wsparcie procesu rozpoznawania obrazów USG. Sieci neuronowe mogą być zastosowane z dużym prawdopodobieństwem sukcesu tam, gdzie pojawiają się problemy związane z tworzeniem modeli matematycznych, pozwalających automatycznie (w wyniku tzw. procesu uczenia) odwzorować w komputerze różne złożone zależności pomiędzy wy-

branymi sygnałami wejściowymi a wybranymi sygnałami wyjściowymi [6]. Istotnym aspektem użytecznym podejmowanych zagadnień jest wykorzystanie numerycznych symulatorów sztucznych sieci neuronowych do informatycznego wsparcia procesów związanych z przetwarzaniem oraz rozpoznawaniem obrazów cyfrowych [7, 8, 9, 10, 11].

W pracy podjęto działania zmierzające do wytworzenia klasyfikatora neuronowego, wspomagającego rozpoznanie ciąży na podstawie obrazów, prezentowanych w postaci cyfrowych zdjęć ultrasonograficznych. W związku z tym, celem było zbudowanie narzędziowego systemu informatycznego, dokonującego konwersji danych graficznych do postaci akceptowalnej przez symulator SNN (Sztuczne Sieci Neuronowe). Wytworzono oryginalny system informatyczny „USG Recognizer”, w którym zaimplementowano znane techniki analizy obrazu cyfrowego. System ten wykorzystano następnie w procesie generowania klasyfikacyjnego modelu neuronowego, przeznaczonego do wspomaganie rozpoznania ciąży, na podstawie informacji zakodowanej w postaci cyfrowych zdjęć ultrasonograficznych macicy krowy.

## 2. Metodyka badawcza

System informatyczny „USG Recognizer” wytworzony został w celu wsparcia procesu automatycznej transformacji zdjęć ultrasonograficznych do postaci akceptowalnej przez symulator SNN. Program został wytworzony w „Microsoft Visual Studio 2010 Professional” dla środowiska uruchomieniowego .NET w wersji 4.0. z wykorzystaniem języka programowania C#(3.0/4.0). Niektóre funkcje programu są oparte na darmowych bibliotekach AForge.NET w wersji 2.1.5. Przegląd możliwych działań w systemie charakteryzuje diagram przypadków użycia (rys. 1).

## 3. Opis głównych funkcji programu

Pozyskanie danych dotyczących rozpoznania ciąży na podstawie ultrasonogramów macicy krowy, w celu wytworzenia zbioru uczącego, potrzebnego do prawidłowego wygenerowania sieci neuronowej, składa się z kilku etapów.


Po uruchomieniu okna głównego programu (rys. 2) użytkownik otwiera (za pomocą funkcji *Otwórz*) zdjęcie

w programie, które zostało wykonane podczas badania ultrasonograficznego wczesnej ciąży u krów. Wykorzystywane ultrasonogramy zarejestrowane zostały przy wykorzystaniu aparatu ultrasonograficznego *Animal Scanner*, firmy *Dramiński*, wyposażonego w głowicę sektorową o częstotliwości 5 MHz.

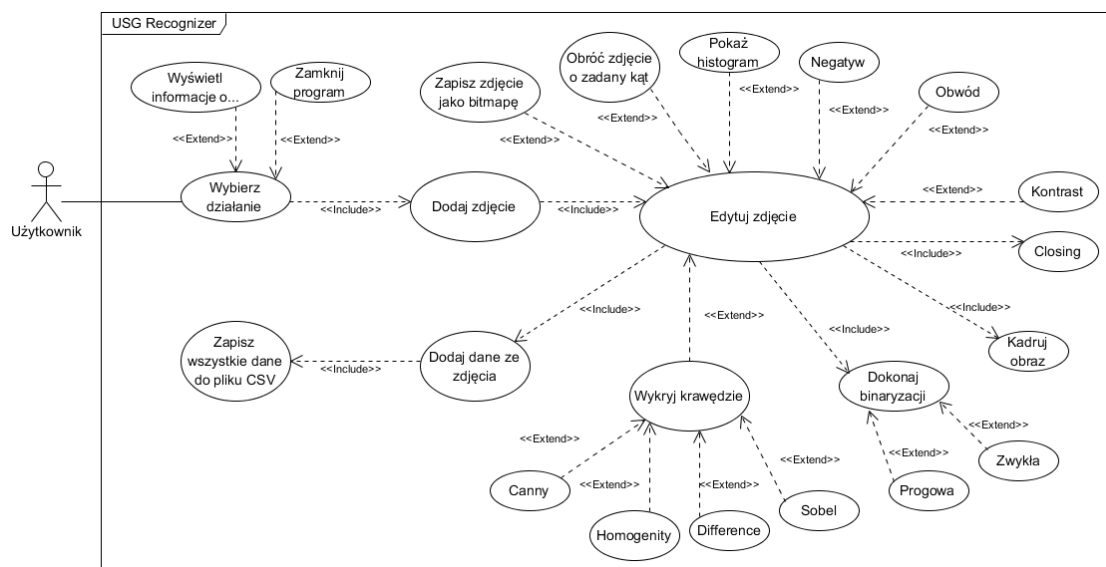


Rys. 2. Okno główne programu „USG Recognizer”  
Fig. 2. Main window of the program „USG Recognizer”

Podstawą do rozpoznania lub wykluczenia ciąży w badaniu ultrasonograficznym jest ocena światła oraz obecność pęcherzyka zarodkowego i płodu w rogach macicznych. W tym celu użytkownik, poprzez wykorzystanie funkcji kadrowania, zawartej w programie (rys. 3) wyznacza fragment badanego rogu macicznego, który to fragment poddany zostanie analizie.

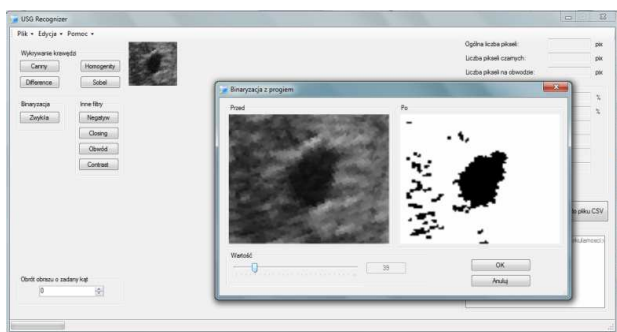


Rys. 3. Funkcja kadrowania  
Fig. 3. Function of framing



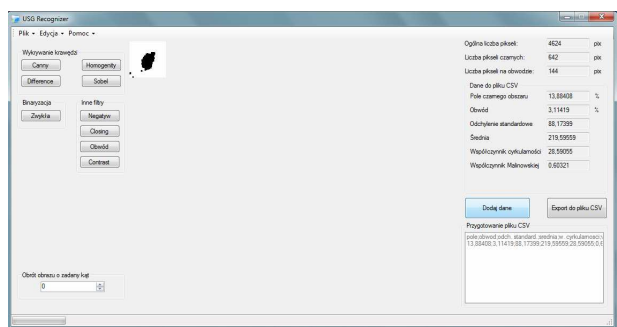
Rys. 1. Diagram przypadków użycia  
Fig. 1. Use case diagram

W kolejnym kroku wyszczególniony fragment zostaje poddany binaryzacji z progiem (rys. 4). Operacja ta powoduje zmianę zdjęcia z kolorów odcieni szarości na plik graficzny składający się wyłącznie z czarnych i białych pikseli.



Rys. 4. Wykorzystanie funkcji *Binaryzacja z progiem*  
Fig. 4. Use of the *Binarization with the threshold function*

Po zakończeniu procesu binaryzacji zdjęcie zostaje odzsumione, przez co zostają usunięte małe, z założenia nieistotne grupki czarnych pikseli. Do tego celu zostaje wykorzystana funkcja *Closing* (rys. 5), która działa w oparciu o darmowe biblioteki AForge.NET.




Rys. 5. Wykorzystanie funkcji *Closing*  
Fig. 5. Use of the *Closing function*

Po naciśnięciu przycisku *Dodaj dane* informacje zakodowane w zdjęciu zostają wyodrębnione i policzone. Elementy wspomnianego wcześniej „framework” zostały wykorzystane do wykonywania obliczeń takich jak:

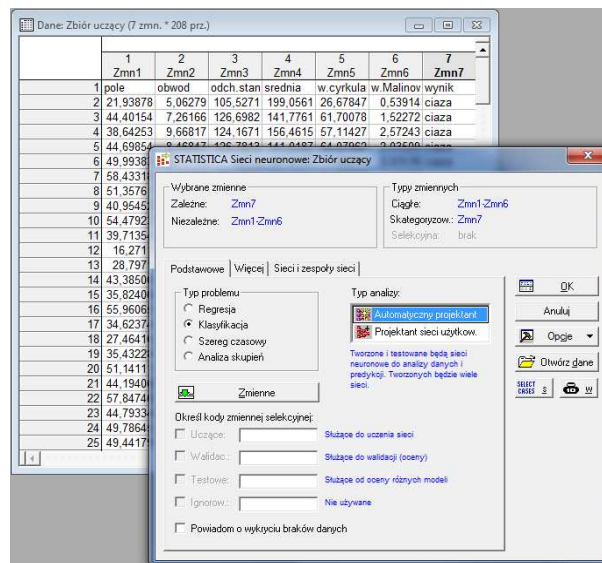
- liczba czarnych pikseli,
- liczba pikseli na wyznaczonym fragmencie,
- liczba pikseli na obwodzie wyznaczonego czarnego pola,
- odchylenie standardowe,
- średnia.

Pozyskane dane można za pomocą przycisku *Eksport do pliku* .csv (*comma separated values*) zapisać na dysku w pliku z rozszerzeniem .csv (rys. 6).



Rys. 6. Eksport do pliku .csv  
Fig. 6. Export into the .csv file

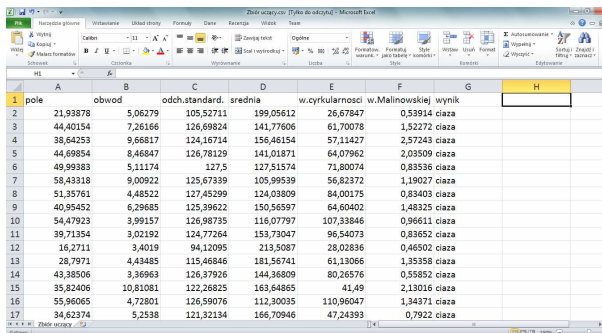
Na podstawie danych empirycznych zapisanych w pliku .csv w systemie informatycznym zostaje wytworzony zbiór uczący. Zbiór ten zostaje zaimportowany do symulatora SNN (Sztuczne Sieci Neuronowe) (rys. 7) i wykorzystany do wygenerowania sieci neuronowej, niezbędnej do neurologicznego wspomaganie rozpoznania ciąży na podstawie cyfrowych zdjęć ultrasonograficznych macicy krowy.



Rys. 7. Okno symulatora SNN (*Statistica v.8.0*)  
Fig. 7. Window of the simulator ANN (*Statistica v.8.0*)

#### 4. Wyniki

Do opracowania modelu neuronowego wykorzystano technikę uczenia SNN „z nauczycielem”. W związku z tym niezbędne było wytworzenie zbioru uczącego (rys. 8), zawierającego w swojej strukturze parametry (cechy reprezentatywne) istotne w procesie wspomaganie rozpoznania ciąży na podstawie informacji zakodowanych w postaci ultrasonogramów macicy krowy. Wielkości te zidentyfikowano w oparciu o przeprowadzony cykl badań empirycznych. Zbudowany zbiór uczący zawierał 207 przypadków uczących. Jego struktura to: 6 charakterystycznych parametrów wejściowych oraz 1 nominalna zmienna wyjściowa. Na wejściu sieci znajdowały się takie dane jak: pole, obwód, odchylenie standardowe, średnia, współczynnik cyrkularności oraz współczynnik Malinowskiej. Sygnał wyjściowy reprezentowała 3-stanowa zmienna nominalna, która przyjmowała 3 wartości: ciąża, niepewność rozpoznania ciąży oraz jej brak.



Rys. 8. Zbiór uczący (plik .csv)  
Fig. 8. Learning file (.csv file)

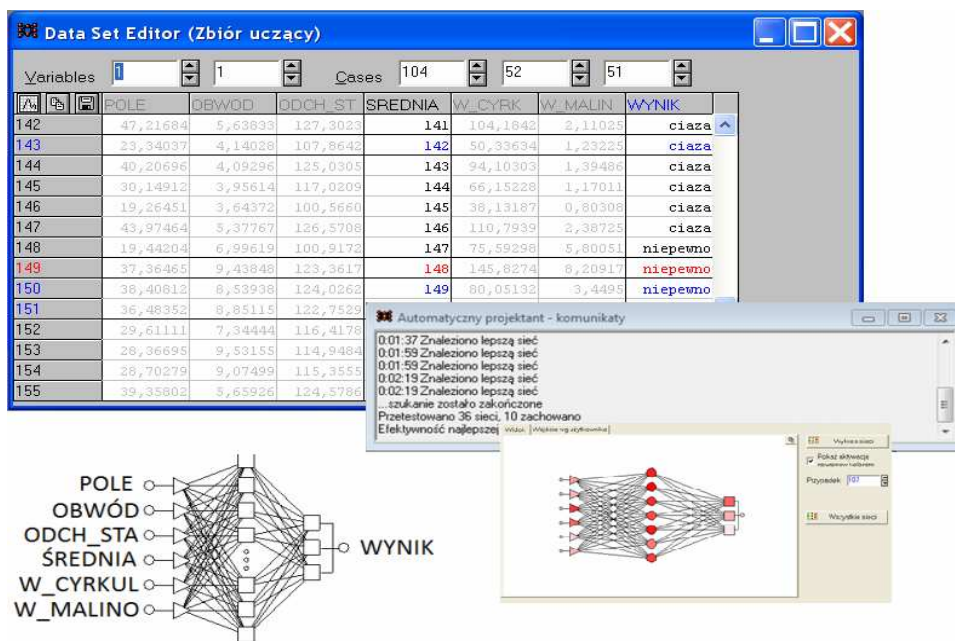
Optymalnym modelem neuronowym, najlepiej odwziewierającym badane zagadnienie, okazała się sieć typu **RBF** (ang. *Radial Basis Function*). Proces uczenia jest równoważny dostrajaniu parametrów modelu reprezentowanego przez sieć (określenie optymalnych wartości wag) do dostępnych danych uczących. W istocie uczenie z nauczycielem sieci neuronowej można uznać za eksploracyjne badanie powierzchni błędów w celu znalezienia minimum (12). Wygenerowana sieć uczona była metodą hybrydową z wykorzystaniem algorytmów optymalizacyjnych **SS** (Sub-Sample), **EX** (Explicit) oraz **PI** (Pseudoinwersji) i posiadała strukturę: 6:6-7-3:1 (rys. 9, 10).

Parametrami, które informują o jakości sieci, są m.in. błędy dla zbiorów uczących, testowych i walidacyjnych. Zasadniczo im błędy są mniejsze tym sieć jest lepsza. W dobrze dopasowanych sieciach błąd uczący jest mniejszy niż dwie pozostałe kategorie błędów. Ważne jest by błędy walidacyjne i testowe nie były znacząco większe od błędów uczących, ponieważ taki objaw uwydatnia słabą zdolność sieci do generalizowania. Oznacza to, że sieć nauczyła się wszystkich przypadków uczących na pamięć i nie radzi sobie z nowymi problemami. Istotny jest także stosunek błędów testowego do błędów walidacyjnego. Jeśli błędy te różnią się znacznie od siebie to oznacza to, że przypadki zostały dobrane w sposób niereprezentatywny [13]. Efektywność wygenerowanej sieci neuronowej można uznać za dobrą: współczynnik poprawnych klasyfikacji wyniósł 0.800000

dla zbioru uczącego (rys. 10). Zbliżona wartość jakości walidacyjnej (0.784314) oraz testowej (0.725490) wskazuje na dobre własności aproksymacyjne wygenerowanego modelu neuronowego.

## 5. Dyskusja

Rozwój komputerowych systemów, opartych na technikach neuronowych, wspomagających podejmowanie decyzji, umożliwia zautomatyzowanie wybranych procesów decyzyjnych. Wdrożenie tej technologii zmniejsza uzależnienie procesów diagnostycznych od subiektywnych, psychofizjologicznych właściwości organu wzroku człowieka. Poprawnie klasyfikujący model neuronowy może być wykorzystane zarówno jako pomoc w diagnozowaniu, jak również jako wsparcie w instruktażu dla lekarzy w ramach diagnostyki obrazowej. System informatyczny „USG Recognizer” jest efektywnym narzędziem umożliwiającym szybkie generowanie zbiorów uczących, tworzonych w oparciu o informacje zawarte w postaci cyfrowych zdjęć ultrasonograficznych. Jego zaletą jest możliwość rozbudowy wytworzonego systemu, poprzez zaimplementowanie kolejnych modułów, wzbogacając tym samym funkcjonalność programu. Możliwa jest również modernizacja wytworzonego systemu poprzez uwzględnienie kolejnych, deterministycznych zmiennych, charakterystycznych dla badanego zagadnienia oraz powiększenie liczby przypadków uczących.



Rys. 9. Generowanie modelu neuronowego typu **RBF**  
Fig. 9. Generating neural model, type **RBF**

Sieci, podsumowanie (Arkusz1)															
	Ind.	Zab.	Sam	Zesp.	Typ	Jakość ucz.	Jakość walid.	Jakość test.	Błąd ucz.	Błąd walid.	Błąd test.	Uczenie	Wejścia	Ukryte(1)	Ukryte(2)
1	1,000000	Nie	Tak	0,00	RBF 6:6-3-3:1	0,780952	0,647059	0,745098	0,322300	0,404666	0,374679	KM,KN,PI	6,000000	3,000000	0,00
2	2,000000	Nie	Tak	0,00	RBF 6:6-5-3:1	0,800000	0,666667	0,764706	0,313447	0,391173	0,369710	KM,KN,PI	6,000000	5,000000	0,00
3	3,000000	Nie	Tak	0,00	RBF 6:6-6-3:1	0,800000	0,686275	0,764706	0,307073	0,386984	0,363515	KM,KN,PI	6,000000	6,000000	0,00
4	4,000000	Nie	Tak	0,00	RBF 6:6-7-3:1	0,809524	0,666667	0,784314	0,305486	0,384560	0,353879	KM,KN,PI	6,000000	7,000000	0,00
5	5,000000	Nie	Tak	0,00	RBF 6:6-7-3:1	0,800000	0,784314	0,725490	0,334352	0,307503	0,367675	SS,EX,PI	6,000000	7,000000	0,00

Rys. 10. Optymalny model neuronowy typu **RBF**  
Fig. 10. Optimum neural model, type **RBF**

## 6. Bibliografia

- [1] Mordak R.: Podstawy monitorowania rozrodu w stadach bydła. *Życie Weterynaryjne*, 2008, 83(9): 736-741.
- [2] Nowak W., Jaśkowski J. M., Wylegała S.: Wpływ żywienia w okresie przejściowym na rozród krów mlecznych. *Medycyna Wet.*, 2006, 62: 632-636.
- [3] Jaśkowski J. M., Olechnowicz J., Nowak W.: Niektóre przyczyny obniżającej się płodności u krów mlecznych. *Medycyna Wet.*, 2006, 62: 385-389.
- [4] Nałęcz M., Chmielowski L., Kulikowski J.L., Nowakowski A.: *Biocybernetyka i inżynieria biomedyczna 2000. Tom 8. Obrazowanie biomedyczne*. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2003.
- [5] Lamb C.: Reproductive ultrasound for management of beef cattle. *Reproductive Management Course. Appendix*: 1-18.
- [6] Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: *Biocybernetyka i inżynieria biomedyczna 2000. Tom 6. Sieci neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2000.
- [7] Boniecki P., Mueller W., Nowakowski K.: Klasyfikacja chronionych w Polsce motyli z rodziny Papilionidae z wykorzystaniem wybranych topologii neuronowych. *Technika Rolnicza Ogrodnicza Leśna*, 2009, 3: 23-26.
- [8] Świerczyński K., Boniecki P., Nawrocka A.: Neuronowa identyfikacja uszkodzeń ziarna pszenicy spowodowanych przez wołka zbożowego (*sitophilus granarius* L.). *Journal of Research and Applications in Agricultural Engineering*, 2011, Vol. 56(2): 165-174.
- [9] Jakubowska T., Wiecek B., Wysocki M., Drews-Peszynski C., Strzelecki M.: Classification of Breast thermal images Using artificial neural networks. *Journal of Medical Informatics & Technologies*, 2004, 7: 41-50.
- [10] Wróblewska A., Przelaskowski A., Bargiel P., Boniński P.: MammoViewer -CAD Application Based on Effective Multiscale Image Analysis, *Pol. J. Med. Phys. Eng.*, 2005, 11: 17-28.
- [11] Duda D., Krętowski M., Bézy-Wendling J.: Klasyfikacja tekstur w rozpoznawaniu nowotworów wątroby na podstawie serii obrazów tomograficznych XIV KBIB'05 – Tom I – *Obrazowanie Medyczne*, 2005.
- [12] Boniecki P.: *Elementy modelowania neuronowego w rolnictwie*. Poznań: Wydawnictwo Uniwersytetu Przyrodniczego w Poznaniu, 2008.
- [13] Szaleniec M.: *Sieci neuronowe i regresja wieloraka - czyli jak określić złożoność w badaniach naukowych?*. Instytut Katalizy i Fizykochemii Powierzchni PAN, Kraków, 2008.