

# Sławomir Mikrut

---

## Sieci neuronowe a geoinformatyka obrazowa w świetle publikacji międzynarodowych kongresów ISPRS

---

Acta Scientifica Academiae Ostroviensis nr 32, 83-93

---

2009

Artykuł został zdigitalizowany i opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej [bazhum.muzhp.pl](http://bazhum.muzhp.pl), gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.

**Sławomir Mikrut**

## **SIECI NEURONOWE A GEOINFORMATYKA OBRAZOWA W ŚWIETLE PUBLIKACJI MIĘDZYNARODOWYCH KONGRESÓW ISPRS**

### **1. Wstęp**

Wykorzystanie sztucznych sieci neuronowych (SSN) w zagadnieniach związanych z geoinformatyką obrazową jest znane już od ponad 20 lat. Jednym z pierwszych zastosowań było wykorzystanie ich do klasyfikacji obrazów wielospektralnych. Badania rozpoczęto od automatycznej klasyfikacji zobrazowań satelity LANDSAT TM, opisanych w literaturze (Bishop et al., 1992). Kolejnymi obrazami klasyfikowanymi przy pomocy SSN były zdjęcia z satelity SPOT (Dreyer, 1993). SSN wykorzystano również do opracowania danych radarowych (Hara, 1994). Ponieważ badania te potwierdziły możliwość skutecznego działania SSN jako jednej z metod klasyfikacji obrazów, były one kontynuowane i prezentowane na późniejszych kongresach ISPRS.

Oprócz klasyfikacji, SSN próbowano także do innych zastosowań takich jak: wydobywanie cech (ang. feature extraction), kalibracja kamer oraz spasowanie obrazów (ang. matching).

Celem niniejszego artykułu jest dokonanie przeglądu literaturowego publikacji obejmujących tematykę wykorzystania SSN w geoinformatyce obrazowej, prezentowanych na czterech ostatnich kongresach ISPRS tj. Wiedeń 1996, Amsterdam 2000, Istambuł 2004 oraz Pekin 2008.

### **2. Istota działania sieci neuronowych**

Istota działania sieci neuronowych jest stosunkowo prosta. Standardowa metodyka, w przypadku pracy na obrazach cyfrowych, polega na przygotowaniu odpowiednich reprezentacji fragmentów obrazów i zastosowaniu do ich klasyfikacji różnego typu sieci. Najczęściej do klasyfikacji używa się sieci typu backpropagation, którą

uczy się metodą „z nauczycielem” lub sieci SOM Kohonena (Kohonen, 1997), która jest przykładem uczenia bez nadzorowania. W obu przypadkach uczenie sieci polega na zmianie wartości wag połączeń neuronów. Zmiany te zachodzą w wyniku podawania na wejście sieci kolejnych reprezentacji, zgromadzonych w zbiorze uczącym i stosowania odpowiednich reguł. Dla sieci backpropagation zmiany wag zależą od różnic odpowiedzi generowanej przez sieć i odpowiedzi oczekiwanej, określonej przez eksperymentatora. W warstwie Kohonena – po podaniu wektora uczącego - wyznaczany jest neuron, który wygenerował najwyższą wartość. Wagi tego neuronu oraz jego sąsiadów są zmieniane tak, aby zbliżyły się do wartości wektora wejściowego. Teoria opisująca działanie tych sieci została przedstawiona np. w publikacjach (Tadeusiewicz, 1993; Tadeusiewicz et al., 2007).

Historycznie rzecz ujmując, za początek sztucznych sieci neuronowych (SSN) przyjmuje się lata czterdzieste, kiedy rozpoczęto badania nad matematycznym opisem komórki nerwowej oraz powiązaniem go z przetwarzaniem informacji przez komórkę. Za początek przyjmuje się rok 1943 związany z opracowaniem matematycznego modelu sztucznego neuronu przez McCullocha i Pittsa (Korbicz et al, 1994). Jednak intensywne badania nad SSN przypadły na lata osiemdziesiąte z racji rozpowszechniania się komputerów i ułatwienia procesów obliczeniowych, towarzyszących sieciom. Istotnym znaczeniem było opracowanie przez Hopfielda w 1982 r. sieci ze sprzężeniem zwrotnym, którą wykorzystano do rozwiązywania zadań optymalizacyjnych (np. problem komiwojażera) oraz odtwarzania obrazów z ich fragmentów.

SSN nie ominęły również zastosowań w geoinformatyce obrazowej. Koniec lat osiemdziesiątych i początek dziewięćdziesiątych to pierwsze zastosowania sieci neuronowych w tej dziedzinie nauk.

### **3. Wykorzystanie sieci neuronowych w geoinformatyce obrazowej**

#### **3.1 Pojawienie się sieci neuronowych w tematyce kongresów ISPRS**

Analizując historię kongresów Międzynarodowego Towarzystwa Fotogrametrii i Teledetekcji (ISPRS) można zauważyć wzrost liczby publikacji obejmujących tę tematykę. Ilość artykułów, zawierających słowa „neural network” w tytule, wzrastała z kongresu na kongres.

Tematyka ta przedstawiona była już w ośmiu artykułach w 1996, w Wiedniu, tyle samo było prezentowanych w Amsterdamie (2000 r.), jedenaście w Istambule (2004 r.) oraz osiemnaście w Pekinie (2008 r.). Wiele było również artykułów dotyczących problematyki wykorzystania sieci neuronowych, nie zawartych jednak w tytule.

### **3.1.1 SSN w klasyfikacji obrazów wielospektralnych**

Jak wspomniano wcześniej, początki SSN w geoinformatyce obrazowej to zastosowania do klasyfikacji obrazów wielospektralnych. Najczęściej próbowano zastosować SSN jako jedną (obok klasycznych) metod do klasyfikacji obrazów i porównywać do klasycznych. W przykładowym opracowaniu (Vieira, 2000), autor wykorzystał metodę SSN, zwaną ANN (ang. Artificial Neural Network) obok klasycznych: LCA, PTS i MDR, uzyskując porównywalne wyniki automatycznej klasyfikacji.

Metoda SSN została również wykorzystana do klasyfikacji obrazów radarowych typu INSAR, gdzie wykrywano rejony zniszczeń powstałych po trzęsieniach ziemi (Ito et al., 2000). Wykorzystywano je również do produkcji map tematycznych z danych satelitarnych Landsat (Barsi, 2000).

Dalsze przykładowe opracowania, gdzie SSN użyto do klasyfikacji obrazów, można znaleźć w literaturze kongresowej we wspomnianych czterech ostatnich kongresach (Barsi, 1996; Bock, 1996; Chen et al., 1996; Kamiya, 2000; Aria et al., 2004; Cetin et al., 2004; Zhou et al., 2008).

### **3.1.2. SSN do automatycznego uzupełnienia opisów na mapach**

Innym przykładem zastosowania sztucznych sieci neuronowych było użycie ich do automatycznego uzupełniania opisów na mapach cyfrowych (Hong et al., 2000). Autorzy zaprezentowali metodę wstawiania opisów na mapach. Jądrzem algorytmu jest wykorzystana sieć Hopfielda, która służy do znajdowania najlepszego położenia opisu dla wybranego obiektu. Rezultaty eksperymentu potwierdziły dobrą skuteczność oraz szybkość algorytmu.

### 3.1.3. Rektyfikacja obrazów satelitarnych

SSN wykorzystano również do rektyfikacji obrazów satelitarnych SPOT (Sunar et al., 2000). Autorzy dokonali porównania procesu rektyfikacji scen satelitarnych SPOT metodą klasyczną, przy pomocy funkcji wielomianowej (pierwszego i drugiego stopnia) oraz SSN. Wyniki rektyfikacji zostały porównane z danymi referencyjnymi. Przeanalizowano wady i zalety poszczególnych metod.

Dokładności uzyskane wspomnianymi metodami były porównywalne (określono błąd długości przykładowego elementu na obrazie zortorektyfikowanym, który wyniósł poniżej 1 piksela dla wszystkich trzech metod).

SSN zaczęto również stosować do rozwiązywania typowych problemów fotogrametrycznych. Poniżej dokonano próby tematycznego ich usystematyzowania. Badania literaturowe podkreśliły potrzebę dokonania takiej analizy, z racji coraz powszechniejszego ich wykorzystania, a także skuteczności działania.

#### 3.1.4 SSN a wydobywanie cech z obrazu (*feature extraction*)

SSN zaczęto również wykorzystywać do wydobywania cech (*feature extraction*). Jednym z pierwszych eksperymentów wykorzystujących sieci do ekstrakcji cech, był opisany w literaturze przykład, opublikowany w roku kongresu w Washingtonie (Zheng, 1992). Jeśli chodzi natomiast o materiały kongresowe można znaleźć przykłady już na kongresie w Wiedniu. W przykładowych badaniach dokonano porównania metod wydobywania cech pomiędzy transformacją Karhunen-Löwe (K-L) a SOM (Self Organizing Maps) Kohonena (Törma, 96). Uzyskane w trakcie badań różnice pomiędzy metodami były bardzo małe. W niektórych przypadkach błędy metody K-L były mniejsze, jednak proces działający przy użyciu SOM był szybszy. Różnice pomiędzy metodami powstawały wówczas, gdy liczba próbek na klasę była mała, co jest typowe dla sieci, tzn. przy zbyt małej liczbie próbek sieci wykazują małą skuteczność.

Kolejny przykład to wykrywanie dróg na obrazach zdjęć lotniczych z wykorzystaniem sieci Hopfielda do optymalizacji algorytmu matchingu przedstawił Hu na kongresie ISPRS w Amsterdamie (Hu et al., 2000). Również przy pomocy SSN opracowano ekstrakcję węzłów drogowych

z obrazów cyfrowych (Barsi et al., 2002). Neuronowy operator, oparty o sieć typu feed-forward, przeszukuje oknem czarno-białe obrazy w średniej rozdzielczości decydując czy skrzyżowanie zawiera 3 czy 4 odnogi. Najlepsze rezultaty otrzymano dla sieci trójwarstwowej. Do uczenia wykorzystano warstwę wektorową dróg. Kilka innych przykładów użycia SSN do wydobywania cech z obrazu zaprezentowano na kongresie ISPRS w Pekinie (Ahadzadeh et al., 2008; Mokhtarzade et al., 2008).

### 3.1.5 Spasowanie obrazów (*matching*)

Wykorzystanie sieci neuronowych oraz zależności fotogrametrycznych (komplanarność, współczynnik korelacji) do spasowania wieloobrazowego (multi-image matching) zostało zaprezentowane podczas kongresu ISPRS w Pekinie 2008 (Elaksher, 2008). Autor zaprezentował metodykę użycia sieci w odniesieniu do zdjęć naziemnych przedstawiających ratusz w Zurichu, udostępnianych przez ISPRS jako materiał testowy. Wykorzystując dowolną liczbę zdjęć, proces startuje z obliczeniem warunku komplanarności pomiędzy wszystkim parami zdjęć. Dla każdej pary punktów liczony jest współczynnik korelacji dla lokalnych jasności obrazu. Do określania prawidłowego dopasowania użyto sieć typu feed-forward. Uzyskano bardzo zadowalające rezultaty. Współczynnik detekcji (ang. detection rate) na poziomie 95% - 98% oraz współczynnik niedopasowania (ang. false alarm rate) od 4% do 7%.

Przedstawione pozycje literaturowe odnoszące się do spasowania obrazów obejmują badania prowadzone na obrazach zdjęć naziemnych. Jest to zagadnienie o tyle nieskomplikowane, że obrazy z kamer naziemnych charakteryzują się stosunkowo dużym podobieństwem (z reguły robione są z krótkiej bazy). Problem staje się bardziej złożony w sytuacji, gdy mamy do czynienia ze zdjęciami lotniczymi. Rozdrobnienie informacji oraz duża paralaksa na przykład w przypadku wysokich budynków znacznie komplikuje zagadnienie.

#### 4. Eksperymenty z wykorzystaniem SSN w odniesieniu do spasowania zdjęć lotniczych

Na ostatnim kongresie ISPRS w Pekinie (2008 r.) zaprezentowano również możliwości wykorzystania SSN do spasowania obrazów zdjęć lotniczych. Autorzy (S. Mikrut, Z. Mikrut) zaprezentowali wyniki badań nad pasowaniem obrazów zdjęć lotniczych przy pomocy różnych reprezentacji (Mikrut *et al.*, 2008). Prace polegały na przeprowadzeniu kilku eksperymentów mających na celu zdefiniowanie odpowiednich klasyfikacji, na wejście do sieci neuronowych. W tabeli 1 zestawiono zrealizowane eksperymenty. Pamiętając o podziale technik przetwarzania obrazów na „obiektywne” i „obszarowe” w omawianych badaniach skoncentrowano się na tych ostatnich. W poszczególnych kolumnach oznaczonych kolejnymi cyframi pokazano cele, które postawił sobie zespół badawczy. Pierwszym z nich było utworzenie reprezentacji podobrazów zdjęcia lotniczego, które następnie zostały użyte do selekcji (cel drugi) i równolegle do pasowania (cel trzeci).

**Tab 1.** Zrealizowane eksperymenty (kursywą oznaczono techniki neuronowe)

1. Schemat konstruowania reprezentacji	2. Selekcja obrazów przy pomocy:	3. Dopasowywanie reprezentacji
gradient → histogram kątów	→ <i>SOM</i> → <i>BP</i>	Tak
gradient → histogram kątów → <i>SOM</i>	→ <i>BP</i>	Tak
<i>Log-polar</i> → gradient → <i>log-Hough</i>	→ <i>BP</i>	Nie
<i>ICM</i> → sygnatura	→ <i>BP</i>	Tak

W kolumnie pierwszej tabeli 1 zestawiono wykorzystane reprezentacje. Zaimplementowano i sprawdzono metody: algorytm oparty na dwuwymiarowym histogramie gradientów, transformaty log-polar i log-Hough'a oraz sygnatury generowane przez sieć impulsującą PCNN (ICM). Kolumna druga tabeli 1 zawiera informacje o sposobie selekcji obrazów. Zadanie polegało na zastosowaniu sieci neuronowych do klasyfikacji podobrazów na „korzystne” i „niekorzystne” z punktu widzenia późniejszego dopasowywania. Podstawową bazę danych utworzono na podstawie zdjęć lotniczych obszaru Krakowa w skali szarości (składowa G z obrazu barwnego RGB) o rozdzielczości 600 dpi

(we wstępnym etapie badań przyjęto obniżoną rozdzielczość ze względu na problemy z czasem przetwarzania dużych obrazów), z których wybrano 900 podobrazów o wymiarze 240x160 pikseli. Każdy podobraz został zaklasyfikowany niezależnie przez pięciu ekspertów fotogrametrów do jednej z trzech grup: obszarów korzystnych, niekorzystnych oraz pośrednich pod względem możliwości wyszukiwania elementów do wzajemnego dopasowania zdjęć. Próbkę podzielono na dwa zbiory: uczący oraz testowy. Do realizacji zadania selekcji wykorzystano dwa typy sieci neuronowych: SOM Kohonena oraz backpropagation. W trzeciej kolumnie tabeli 1, pokazano dla których reprezentacji dokonano spasowania obrazów. Pasowano trzy rodzaje reprezentacji: Reprezentacje uzyskane po zastosowaniu sieci SOM Kohonena, sygnatury wygenerowane przez impulsującą sieć ICM oraz – dla porównania – wektory histogramu gradientów, uzyskane bez stosowania sieci neuronowych.

Wyniki przedstawionych eksperymentów dowiodły, że wykorzystanie sieci neuronowych do wstępnej selekcji obrazów jest celowe, pod warunkiem zastosowania odpowiednich reprezentacji obrazów.

Procentowe rozpoznania mogą być dodatkowo zwiększane przez zastosowanie techniki odrzuceń, polegającej na badaniu pewności rozpoznawania i odpowiedni dobór wartości granicznej dla tej pewności. Najlepsze wyniki osiągnięto dla reprezentacji w postaci sygnatur, generowanych przez sieć ICM (około 91% dopasowań). Dla mniejszych dopuszczalnych odległości odchyłek równych 10 i 5 pikseli procentowe wartości prawidłowych dopasowań wyniosły odpowiednio około 63% i 38%.

Uzyskane w trakcie badań wyniki potwierdzają wstępnie przyjęte założenia, aczkolwiek należy podkreślić, że zagadnienie to jest skomplikowane a temat badań o wiele bardziej rozległy niż zakładano początkowo. Dopasowywane obrazy zdjęć lotniczych cechuje zmienność obiektów, tekstury i oświetlenia. Głównie te cechy – powiązane ze zbyt ubogim przetwarzaniem wstępnym obrazów - spowodowały otrzymanie nie w pełni zadowalających rezultatów.

W podsumowaniu autorzy stwierdzili, że zastosowanie sieci neuronowych ma sens w przypadku przeprowadzania wstępnej selekcji podobrazów. Natomiast problem dopasowania prawdopodobnie wymaga zastosowania innego podejścia – być może opartego o detekcję i opis



obiektów. Autorzy widzą sens kontynuowania badań, przy zmodyfikowanych w powyższy sposób algorytmach, lecz podobnej metodyce. Szczegóły można znaleźć we wspomnianej publikacji (Mikrut *et al.*, 2008).

## 5. Podsumowanie i wnioski

W niniejszym artykule dokonano przeglądu literatury dotyczącej wykorzystania sztucznych sieci neuronowych (SSN) w geoinformatyce obrazowej, na bazie literatury kongresów ISPRS. Przedstawiono wyniki badań z wybranych, ciekawszych publikacji. Wynika z nich jednoznacznie, że następuje zwiększenie zainteresowania sztucznymi sieciami neuronowymi (SSN) w dziedzinie geoinformatyki obrazowej. O ile na początku (Wiedeń 1996) dominowały zastosowania SSN do automatycznej klasyfikacji oraz wydobywania cech z obrazu, tak z kongresu na kongres, przedstawiano inne, nowe zastosowania takie jak: spasowanie obrazów (stereo-matching), uzupełnianie opisów na mapach, kalibracja kamer, rektyfikacja scen satelitarnych i inne. Prowadzone są również badania nad nowymi zastosowaniami (np. spasowanie zdjęć lotniczych), które mimo złożoności problemu daje pierwsze, ciekawe wyniki, pozwalające sądzić, że prowadzenie badań w tym kierunku może przynieść w przyszłości zadowalające rezultaty.

## Literatura:

1. Ahadzadeh S., Valadanzouj M., Sadeghian S., Ahmadi S., 2008. Detection of Damaged Buildings after an Earthquake Using Artificial Neural Network Algorithm. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, Vol. XXI, Part B8, s. 369-372.
2. Aria E.H., Saradjian M.R., Amini J., Lucas C., 2004. Generalized cooccurrence matrix to classify IRS-1D images using neural network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Istambul, Turkey, Vol. XX, Part B7., s. 114-116.
3. Barsi A., 1996. Thematic classification of Landsat image using neural network. *The International Archives of the Photogrammetry,*

- Remote Sensing and Spatial Information Sciences*, Vienna, Austria, Vol. XVIII, Part B3, s.48-52.
4. Barsi A., 2000. The impact of data compression and neighborhood information on the classification accuracy of artificial neural networks. *Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Amsterdam, Holland, Vol. XIX, Part B7, s. 140-147.
  5. Barsi A., Heipke C., Willrich F., 2002. Junction extraction by artificial neural network system – JEANS, *IntArchPhRS XXXIV/3b*, Graz , s.18-21
  6. Bischof H., Schneider W., Pinz A., 1992. Multispectral classification of Landsat images using neural network, *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 30, No 3, s. 482-490.
  7. Bock S., 1996. A region-based approach to land-use classification of remotely –sensed image data using artificial neural network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vienna, Austria, Vol. XVIII, Part B7, s.71-76.
  8. Cetin M., Kavzoglu T., Musaoglu N., 2004. Classification of multi-spectral, multi-temporal and multi-sensor images using principal components analysis and artificial neural networks: beykoz case. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Istanbul, Turkey, Vol. XX, Part B4, s. 951-956.
  9. Chen C., Chen S., Shyn S., 1996. Classification of remote sensing imagery using an unsupervised neural network. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vienna, Austria, Vol. XVIII, Part B7, s. 112-117.
  10. Dreyer P., 1993. Classification of land cover using optimized neural nets on SPOT data, *Photogrammetric Engineering and Remote Sensing*, Vol. 59, No. 5, s. 617-621.
  11. Elaksher A., 2008. Multi-image matching using neural networks and photogrammetric conditions. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, Vol. XXI, Part B3, s. 39-44.

12. Hara Y., Atkins R., Yueh S., Shin R., Kong J., 1994. Application of neural networks to radar image classification, *IEEE Trans. on Geoscience and Remote Sensing*, Vol. 32, No. 1, s. 100-109.
13. Hong F., Zhang Z., Daosheng D., 2000. A Hopfield neural network algorithm for automated name placement for point feature, *International Archives of Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B3.
14. Hu X., Zhang Z., Zhang J., 2000. An approach of semiautomated road extraction from aerial image based on template matching and neural network. *International Archives of Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B3, s. 994-999.
15. Ito Y., Hosokawa M., Lee H., Liu J.G., 2000. Extraction of damaged regions using sar data and neural networks, *International Archives of Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B1, s. 156-163.
16. Kamiya I., 2000. Image classification by spatial shift invariant neural network. *Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Amsterdam, Holland, Vol. XIX, Part B7, s. 636-639.
17. Kohonen T., 1997. *Self-Organizing Maps*. New York , Springer-Verlag.
18. Korbicz J., Obuchowicz A., Uciński D., 1994. *Sztuczne sieci neuronowe. Podstawy i zastosowania*. Akademicka Oficyna Wydawnicza PLJ, Warszawa.
19. Mikrut S., Mikrut Z., 2008. Neural networks in the automation of photogrammetric processes. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, Vol. XXI, Part B4, s. 331-336.
20. Mokhtarzade M., Valadan Zoj M., Ebadi H., 2008. Automatic Road Extraction from High Resolution Satellite Images Using Neural Networks, Texture Analysis, Fuzzy Clustering and Genetic Algorithms. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, Vol. XXI, Part B3b, s. 549-556.
21. Sunar F., Özkan C., 2000. Rectification of remotely sensed images with artificial neural network, *International Archives of*

- Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B3
22. Tadeusiewicz R., 1993. *Sieci neuronowe*. AOW Warszawa.
  23. Tadeusiewicz R., Gąciarz T., Borowik B., Leper B., 2007. *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C\#*. Polska Akademia Umiejętności. Międzywydziałowa Komisja Nauk Technicznych, Kraków.
  24. Törma M., 1996, Self-organizing Neural Network in Feature Extraction. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vienna, Austria, Vol. XVIII, Part B2, s.374-379.
  25. Vieira C., Mather P., McCullagh M., 2000. The spectral-temporal response surface and its use in the multi-sensor, multitemporal classification of agricultural crops. *International Archives of Photogrammetry and Remote Sensing*. Amsterdam, Holland, Vol. XXXIII, Part B2.
  26. Zheng Y-J, 1992. Feature extraction: a neural network oriented approach. *Int. Archives of Photogrammetry and Remote Sensing*, vol. 29.
  27. Zhou L., Yang X., 2008. Use of Neural Networks for Land Cover Classification from Remotely Sensed Imagery. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Beijing, China, Vol. XXI, Part B7, s. 575-578.