

**SIECI NEURONOWE W PROCESACH AUTOMATYCZNEJ KORELACJI
ZDJĘĆ LOTNICZYCH**

**NEURAL NETWORKS IN AUTOMATIC MATCHING PROCESSES
ON AERIAL IMAGES**

Sławomir Mikrut¹, Zbigniew Mikrut²

¹ Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska, AGH w Krakowie

² Katedra Automatyki, Akademia Górniczo-Hutnicza w Krakowie

SŁOWA KLUCZOWE: fotogrametria cyfrowa, sieci neuronowe, korelacja, spasowanie obrazów

STRESZCZENIE: Koncepcja opisywanych badań opierała się na wyborze kilku reprezentacji, które następnie korelowano przy pomocy metod klasycznych i neuronowych. W trakcie badań przetestowano metody klasyczne spasowania obrazów i porównano je z powstałymi w trakcie badań metodami neuronowymi. Przeprowadzono również eksperymenty polegające na pomiarach manualnych, wykonanych przez niezależnych obserwatorów.

Istota metodyki opartej o sieci neuronowe polegała na przygotowaniu odpowiednich reprezentacji fragmentów obrazów i zastosowaniu do ich klasyfikacji różnych typów sieci neuronowych. Jedną z przyjętych metod bazowała na rozkładzie wartości modułu gradientu obrazu oraz jego kierunku. Sprawdzone przydatność tej reprezentacji do selekcji podobrazów przy pomocy sieci neuronowej SOM Kohonena. Druga metoda polegała na wykorzystaniu transformaty log-polar i log-Hough'a, które są uważane za uproszczone modele przetwarzania wstępnego, realizowanego przez systemy wzrokowe ludzi i zwierząt. Przydatność tej i następnej reprezentacji badano przy pomocy sieci neuronowej typu *backpropagation*. Do utworzenia trzeciej reprezentacji zastosowano sieć ICM (*Intersecting Cortical Model*), która jest jedną z wersji PCNN (*Pulse Coupled Neural Network*). Przy pomocy tej sieci wygenerowano tzw. podpisy obrazów (*signatures*), czyli kilkudziesięcioelementowe wektory, opisujące strukturę obrazu.

1. WSTĘP

Wykorzystanie sieci neuronowych do rozwiązywania problemów fotogrametrycznych jest stosunkowo nowym kierunkiem badań, chociaż sieci stosuje się od dawna w analizie obrazów cyfrowych. Problem wynika nie tylko z braku popularyzacji tej techniki wśród fotogrametrów. Dodatkową trudność stanowi specyfika obrazów fotogrametrycznych, które charakteryzują się stosunkowo dużą różnorodnością i rozdrobieniem informacji. Im mniejsza skala zdjęć tym to rozdrobnienie jest większe. Stwarza to kłopoty z utworzeniem zbioru danych do uczenia i testowania, ponieważ zbiór ten powinien być przede wszystkim *reprezentatywny*. Dodatkową trudność stanowi fakt braku narzędzi neuronowych, przy pomocy których można by zrealizować jeden z najważniejszych etapów analizy, czyli pasowanie (korelowanie). Pozostają zatem zagadnienia związane z klasyfikacją obszarów

i detekcją cech, co pokazują przykłady zastosowań zaczerpnięte z literatury zaprezentowane w rozdziale 2.

W niniejszym artykule autorzy zaproponowali koncepcję wykorzystania sieci neuronowych do wstępnej selekcji podobrazów oraz – pośrednio - do ich dopasowywania. Artykuł jest podsumowaniem kilkuletnich prac. Koncepcja badań opierała się na wyborze kilku reprezentacji, które następnie użyto jako wejścia dla klasyfikujących sieci neuronowych. Szeroko rozumianych sieci neuronowych użyto także do tworzenia reprezentacji, które następnie korelowano. W trakcie badań przetestowano metody klasyczne spasowania obrazów i porównano je z powstałymi w trakcie badań metodami neuronowymi. Przeprowadzono również eksperymenty polegające na pomiarach manualnych, wykonanych przez niezależnych obserwatorów.

Artykuł zorganizowany jest następująco. W rozdziale 2 przedstawiono przykłady zastosowań sieci neuronowych w fotogrametrii i zagadnieniach pokrewnych, zaczerpnięte z literatury. W rozdziale 3 krótko przypomniano zasady działania najczęściej używanych sieci neuronowych oraz nieco dokładniej omówiono mniej znaną sieć impulsującą ICM (*Intersecting Cortical Model*). Główną część pracy stanowi rozdział 4, w którym zaprezentowano zrealizowane eksperymenty dotyczące zastosowań sieci neuronowych na różnych etapach analizy obrazów fotogrametrycznych. Rozdział 5 zawiera zestawienie wyników i wnioski.

2. PRZYKŁADY ZASTOSOWAŃ SIECI NEURONOWYCH W FOTOGRA-METRII I TELEDETEKCJI

Próby wykorzystania sieci neuronowych podejmowane były do rozwiązywania różnych problemów w dziedzinie fotogrametrii i teledetekcji praktycznie od samego początku ich rozwoju. Możliwości wykorzystania sztucznej inteligencji w fotogrametrii, w ogólnym zarysie, przedstawił już w 1988 r. T. Sarjakoski (Sarjakoski, 1988).

Jednym z pierwszych zastosowań było użycie sieci do ekstrakcji cech (ang. *feature extraction*) (Zheng, 1992). Następnie metodę wykrywania dróg na obrazach zdjęć lotniczych z wykorzystaniem sieci Hopfielda do optymalizacji algorytmu *matchingu* przedstawił Hu na kongresie ISPRS w Amsterdamie (Hu *et al.*, 2000).

Jednak najpopularniejsze zastosowanie to użycie neuronów do klasyfikacji treści obrazów wielospektralnych. W jednym z przykładów autor (Vieira, 2000) wykorzystał sieci jako jedną z metod do klasyfikacji. Metoda ANN (*Artificial Neural Network*) była wykorzystana obok metod LCA, PTS i MDR. Sieci zostały również wykorzystane przy 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). Kolejne przykłady wykorzystania sieci do klasyfikacji obrazów teledetekcyjnych można znaleźć w pracy (Kamiya, 2000).

Innym przykładem zastosowania sztucznych sieci neuronowych było użycie ich do automatycznego uzupełniania opisów na mapach cyfrowych (Hong, 2000) czy rektyfikacji obrazów satelitarnych (Sunar *et al.*, 2000).

Próbowano również wykorzystać sieci do korelowania obrazów. Jednak zagadnienie to jak do tej pory testowano głównie w dziedzinie robotyki. Autorzy (Pajares *et al.*, 1998)

próbowali rozwiązać problem przez wykorzystanie strategii uczenia sieci bazującej na Self-Organizing Feature Mapping (SOFM), która jest jednym z wariantów sieci Kohonena.

3. ZARYS TECHNIKI SIECI NEURONOWYCH

Większość zastosowań sieci neuronowych związana jest z szeroko rozumianą klasyfikacją. Stosowana standardowo metodyka polega na przygotowaniu odpowiednich reprezentacji fragmentów obrazów i zastosowaniu do ich klasyfikacji różnych typów 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). Powstały także komputerowe programy ułatwiające stosowanie sieci neuronowych nawet osobom o niezbyt dużym doświadczeniu (Duin, 2000; Matlab, 2006). Z tego powodu szersze przedstawianie zasad działania i metod postępowania z tymi sieciami wydaje się zbędne.

3.1. Sieci neuronowe impulsujące

Impulsująca sieć neuronowa (PCNN – *Pulse Coupled Neural Network*) to model sieci biologicznej, a konkretnie model fragmentu sieci wzrokowej kota (Eckhorn *et al.*, 1990). Sieci te służą do przetwarzania cyfrowych obrazów. Przy ich pomocy można realizować takie operacje jak segmentacja obrazu czy też detekcja konturów. Teoria i możliwości zastosowań tych sieci zostały najpełniej opisane w (Lindblad *et al.*, 2005).

Impulsująca sieć neuronowa jest siecią jednowarstwową. Składa się z neuronów, z których każdy jest połączony z jednym pikselem obrazu wejściowego. Schemat blokowy pojedynczego neuronu przedstawiono na rysunku 1. Jest to uproszczony model sieci PCNN, wprowadzony w pracy (Kinser, 1996) i nazwany ICM (*Intersecting Cortical Model*).

Pojedynczy neuron generuje impuls w momencie, gdy sumaryczny poziom pobudzenia F przekracza wartość progową. Po wygenerowaniu impulsu próg gwałtownie rośnie a następnie stopniowo opada do wartości spoczynkowej. Na pobudzenie F neuronu ma wpływ – oprócz wartości piksela obrazu S – także sygnał sprzężenia zwrotnego od neuronów sąsiednich. W kolejnych krokach obliczeniowych sieć generuje binarne obrazy, przy czym piksele o wartości 1 odpowiadają sytuacji pojawienia się impulsu, a sygnały o wartości 0 – brakowi impulsu.



Rys. 1. Pojedynczy neuron sieci impulsującej ICM

W omówionych w rozdziale 4 badaniach sieć ta została użyta jako generator reprezentacji fragmentu obrazu lotniczego. Reprezentacja ta to tzw. sygnatura (*signature*). Jest to jednowymiarowa funkcja, powstała w wyniku sumowania wszystkich pikseli obrazu wyjściowego (binarnego) w kolejnych krokach obliczeniowych.

3.2. Model biologicznej sieci neuronowej

Inny rodzaj reprezentacji obrazu można otrzymać po przetworzeniu go transformacjami log-polar i log-Hough'a. Transformacje te można zaliczyć do szeroko pojętej klasy sieci neuronowych ponieważ są one uproszczonymi modelami przetwarzania informacji wizyjnej w systemie wzrokowym zwierząt wyższych (Schwartz, 1977; Weiman, 1989).

Zasadę działania transformaty log-polar oraz transformaty log-Hough'a dokładnie przedstawiono w pracy (Piekarski *et al.*, 2007), znajdującej się w tym tomie. Tu wystarczy nadmienić, że odwzorowanie log-polar jest najdokładniejsze w pobliżu środka obrazu, a mniej dokładne dla pól receptorowych położonych daleko od środka. Głównymi zaletami transformacji log-polar są: duża redukcja danych oraz przekształcanie rotacji i powiększania obiektu w przestrzeni kartezjańskiej na równoległe przesunięcia wzdłuż odpowiednich osi w przestrzeni log-polar

Przy pomocy transformaty log-Hough'a wykrywane są odcinki linii prostych i łagodne łuki na krawędziowym obrazie log-polar (Weiman, 1989). W przestrzeni log-Hough'a powstają maksima w miejscach odpowiadających parametrom wykrytych linii. Maksima te są tym wyższe im więcej współliniowych punktów znajdowało się na obrazie w przestrzeni log-polar po wydzieleniu krawędzi. Operacja realizowana przez transformatę log-Hough'a jest podobna do przekształcania obserwowanego w jednym z obszarów kory wzrokowej: wykrywania fragmentów linii o różnych nachyleniach.

Obie te transformaty zostały wybrane do skonstruowania reprezentacji obrazu ponieważ dokonują one redukcji informacji oraz dostarczają w formie skondensowanej informacji o wzajemnym położeniu krawędzi.

4. ZAKRES BADAŃ

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 równoległe do pasowania (cel trzeci). Z tych trzech zagadnień osobnego omówienia wymaga cel drugi.

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

Podczas procesu analizy fotogrametrycznej człowiek wskazuje *informatywne* punkty na jednym ze zdjęć a następnie na drugim zdjęciu odszukuje najpierw większy obszar a potem odpowiedniki punktów, wskazanych na zdjęciu pierwszym. Cel drugi (selekcja) obejmował dokonanie próby automatyzacji pierwszego etapu analizy, czyli zbadanie, czy jest możliwe stwierdzenie, że wybrany fragment obrazu jest wystarczająco informatywny i nadaje się do dalszego przetwarzania.

4.1 Reprezentacje podobrazów

Utworzone reprezentacje podobrazu zostały zestawione w pierwszej kolumnie tabeli 1. Zaimplementowano i sprawdzono trzy metody: algorytm oparty na dwuwymiarowym histogramie gradientów, transformaty *log-polar* i *log-Hough*'a oraz sygnatury generowane przez sieć impulsującą PCNN (*ICM*).

Metoda opisana w tabeli 1 jako „histogram kątów” polega na utworzeniu z obrazu gradientowego dwuwymiarowego histogramu. Pojedyncze pole tego histogramu odpowiada liczbie pikseli na obrazie, dla których wartości gradientu oraz kierunku mieszczą się w zadanym przedziale. Dwuwymiarowy histogram gradientu sporządzany jest dla wszystkich pikseli obrazu, które są pikselami krawędzi. Na podstawie tak przygotowanego histogramu wyznaczany jest wektor cech w postaci: profilu maksymalnych i średnich wartości modułu gradientu, które powstają poprzez rzutowanie odpowiednio wartości

maksymalnych i średnich na oś modułu gradientu oraz profilu maksymalnych i średnich wartości kierunku. Szczegóły metody zawiera praca (Czechowicz *et al.*, 2007). Tak utworzone reprezentacje stanowiły wejście dla samoorganizującej się sieci neuronowej Kohonena. Sieć ta została użyta do selekcji podobrazów (por. drugą kolumnę tabeli 1), a wyselekcjonowane neurony tej sieci (a właściwie sygnały na ich wyjściach) utworzyły drugi rodzaj reprezentacji, opartej na histogramie 2D (por. trzeci wiersz tabeli 1).

Transformaty log-polar i log-Hough'a, opisane w rozdziale 3, operowały na obrazie nie przetworzonym. Wektor cech został utworzony poprzez rzutowanie wartości maksymalnych z odpowiednich linii i kolumn przestrzeni log-Hough'a na osie układu współrzędnych. Powstały w ten sposób profile, określające pozycje oraz długości odcinków prostych i łagodnych łuków krawędzi. Informacje o kolejności przekształceń obrazu oraz o wyborze i agregacji wektorów cech zamieszczono w pracy (Piekarski *et al.*, 2007).

Ostatni rodzaj reprezentacji to sygnatury podobrazów, wygenerowane przez impulsującą sieć neuronową ICM. W eksperymentach używano sygnatur 25., 50. i 100. elementowych (Mikrut, 2007).

4.2 Selekcja obrazów

Zadanie *selekcji* polegało na zastosowaniu sieci neuronowych do klasyfikacji podobrazów na „korzystne” i „niekorzystne” z punktu widzenia późniejszego dopasowywania. Podstawową bazę danych utworzono na podstawie są zdjęć lotniczych obszaru Krakowa w skali szarości (składowa G z obrazu kolorowego 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. Przynależność do danej klasy wyznaczała wartość medianowa klasyfikacji. Próbkę podzielono na dwa zbiory: uczący oraz testowy.

Do realizacji zadania selekcji wykorzystano dwa typy sieci neuronowych: SOM Kohonena oraz *backpropagation* (por. tab. 1). Zarówno analiza bazy danych jak i wstępne eksperymenty wykazały, że wyniki uzyskiwane dla trzech klas nie są satysfakcjonujące. Dlatego w dalszych testach uczono sieci neuronowe dokonywania podziału na 2 klasy: podobrazów „korzystnych” i „niekorzystnych”.

Ostatecznie wejściami dla sieci Kohonena były 19. elementowe reprezentacje utworzone z profilu średnich wartości kierunku gradientu z agregacją 20°. Najlepsze wyniki osiągnięto dla sieci o rozmiarach 7x4 neurony.

W trzech pozostałych przypadkach (por. tab. 1) zastosowano sieci typu *backpropagation*. Metodyka eksperymentów była za każdym razem podobna. Najpierw zgrubnie wyznaczano pary „reprezentacja – struktura sieci” a następnie wybraną reprezentacją uczono sieć, która uzyskała najlepsze wyniki rozpoznawania w fazie wstępnej. Skuteczność rozpoznawania zwiększano stosując technikę odrzuceń. Zestawienie najbardziej efektywnych struktur sieci oraz procentowych wyników klasyfikacji zawiera rozdział 5.

4.3 Dopasowywanie reprezentacji podobrazów

Z bazy danych opisanej w punkcie 4.2 wybrano dwa podzbiory: 36 obrazów, reprezentujących składową G oraz 44 obrazy w stopniach szarości (składowe R, G i B zostały scalone). Na kolejnym zdjęciu lotniczym manualnie zlokalizowano te obszary i po odpowiednim obramowaniu zapisano je w celu przeprowadzenia testów pasowania.

Należy podkreślić, że w omawianych badaniach sprawdzano możliwości dopasowywania *reprezentacji* podobrazów, czyli obliczano wektory reprezentacji podobrazu ze zdjęcia chronologicznie pierwszego, następnie obliczano reprezentacje wszystkich podobrazów wchodzących w skład fragmentu drugiego (kolejnego) zdjęcia lotniczego i te wektory porównywano. Samo porównywanie wektorów realizowano przy użyciu klasycznej korelacji.

Jak pokazano w trzeciej kolumnie tabeli 1 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.

Do badania dopasowania wybrano 19. elementową reprezentację profilu średnich wartości kierunku gradientu z agregacją 20° . Reprezentację neuronową stanowiły odpowiedzi generowane na najlepiej klasyfikującej sieci typu SOM o strukturze 19-28[7x4]. Szczegóły można znaleźć w pracy (Czechowicz *et al.*, 2007a), a najważniejsze wyniki zestawiono w rozdziale 5.

Drugą reprezentacją, którą wykorzystano do pasowania, były 100. elementowe sygnatury wytworzone przez sieć ICM. Badano wyniki dopasowywania dla sygnatur generowanych na obrazach dwukrotnie i czterokrotnie zmniejszonych. Obliczano sygnatury dla całego obrazu oraz dla obrazu podzielonego równomierną siatką na 4. i 6. elementowe fragmenty. Opis eksperymentów zostanie opublikowany w pracy (Mikrut *et al.*, 2008), a najlepsze wyniki zaprezentowano w rozdziale 5.

5. WYNIKI I PODSUMOWANIE

W tabelach 2 i 3 zestawiono odpowiednio wyniki klasyfikacji podobrazów na fragmenty „korzystne” i „niekorzystne” z punktu widzenia późniejszego pasowania oraz wyniki wzajemnego dopasowywania reprezentacji podobrazów na dwóch kolejnych zdjęciach lotniczych.

Wyniki przedstawione w tabeli 2 dowodzą, 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. Rezultaty przedstawione w tabeli 3 (trzecia kolumna) zostały uzyskane po przyjęciu granicznej wartości przesunięcia, poniżej której dopasowanie jest uznawane za dopuszczalne. Wartość ta, równa 30 pikseli, została przyjęta w oparciu o wyniki dopasowania całych (nie przetworzonych) podobrazów metodą *area based matching* (por. ostatni wiersz tabeli 3). Tyle właśnie wyniósł maksymalny błąd dopasowania tą metodą. Z kolei przedostatni wiersz tabeli 3 pokazuje niskie możliwości bezpośredniego wykorzystania reprezentacji, opartej na dwuwymiarowym histogramie gradientów.

Tab 2. Wyniki rozpoznawania 2 klas obrazów

Opis reprezentacji	Rodzaj i struktura sieci neuronowej	Rozpoznanie zbioru testowego	Publikacje i uwagi
2D histogram gradientów: profil średnich wartości kierunku gradientu z agregacją 20°	SOM Kohonena 19-28[7x4]	89,5%	(Czechowicz <i>et al.</i> , 2007) stosowano odrzucenia - uwzględniono odpowiedzi 6 neuronów
jak wyżej	SOM + BP 19-[7x4]-5-2	84,5%	(Czechowicz <i>et al.</i> , 2007a)
jak wyżej, ale z agregacją 5°	BP 73-10-2	84,8%	(Czechowicz <i>et al.</i> , 2007a)
przestrzeń log-Hough'a – wektor rzutów na oś promienia, agregowany co 2	BP 25-2-2 25-28-2	72,5% 69,2%	(Piekarski <i>et al.</i> , 2007)
50. elementowe sygnatury generowane przez sieć ICM	BP 50-6-2	73%	(Mikrut, 2007) - przy ~20% odrzuceń rozpoznanie wzrosło do ~80%

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%.

Tab 3. Wyniki eksperymentów z dopasowywaniem obrazów

Opis reprezentacji	Opis zbioru danych	Wynik	Publikacje i uwagi
wyjścia neuronów warstwy SOM Kohonena	36 par obrazów (składowa G)	10/36	(Czechowicz <i>et al.</i> , 2007a)
100. elementowe sygnatury, 6 sygnatur na 1 podobraz	44 pary obrazów (w stopniach szarości)	40/44	(Mikrut S. <i>et al.</i> , 2008)
19. elementowy profil kierunków gradientów	36 par obrazów (składowa G)	2/36	(Czechowicz <i>et al.</i> , 2007a)
cały podobraz – <i>area based matching</i>	jak wyżej	36/36	(Czechowicz <i>et al.</i> , 2007a)

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.

Podsumowując należy stwierdzić, że zastosowanie sieci neuronowych powiodło się 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.

6. LITERATURA

- Barsi A., 2000. The impact of data compression and neighborhood information on the classification accuracy of artificial neural networks, *International Archives of Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B3
- Czechowicz A., Mikrut Z., 2007. Wykorzystanie sieci Kohonena do selekcji podobrazów dla potrzeb dopasowania zdjęć lotniczych. *Uczelniane Wydawnictwo Naukowo-Dydaktyczne Kraków – Półrocznik Automatyka*, Tom 11; str. 329 – 343;
- Czechowicz A., Mikrut Z., 2007a. Selekcja podobrazów dla potrzeb dopasowywania zdjęć lotniczych oparta na histogramach gradientu i sieci neuronowej. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 17, Dobczyce (w tym tomie)
- Duin R.P.W., 2000. *PRTools Version 3.0 - a Matlab Toolbox for Pattern Recognition*. Delft University of Technology, <http://www.ph.tn.tudelft.nl/prtools>
- Eckhorn R., Reitboeck H.J., Arndt M., Dicke P., 1990. Feature linking via synchronization among distributed assemblies: Simulations of results from Cat Visual Cortex. *Neural Comp.* vol. 2, pp. 293-307.
- 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
- 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
- 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,
- Kamiya I., 2000. Image classification by spatial shift invariant neural network, *International Archives of Photogrammetry and Remote Sensing*. Amsterdam., Holland, Vol. XXXIII, Part B3
- Kinser J.M., 1996. A Simplified Pulse-Coupled Neural Network. *Proc. SPIE*, Vol. 2760, No. 3.
- Kohonen T., 1997. *Self-Organizing Maps*. New York , Springer-Verlag.
- Lindblad T., Kinser J.M., 2005. *Image Processing Using Pulse-Coupled Neural Networks*. Springer, Berlin Heidelberg New York.
- Matlab, 2006. *Image Processing Toolbox For Use with Matlab. User's Guide*. The MathWorks, Inc., Natick.

- Mikrut S. (red.), 2008. *Ocena efektywności wykorzystania sieci neuronowych w procesach automatycznej korelacji obrazów zdjęć lotniczych*. Monografia, Uczelniane Wydawnictwa Naukowo-Dydaktyczne AGH (praca w redakcji)
- Mikrut Z., 2007. Tworzenie reprezentacji obszarów zdjęć lotniczych za pomocą sieci neuronowych klasy PCNN. *Uczelniane Wydawnictwo Naukowo-Dydaktyczne Kraków – Półrocznik Automatyka*, Tom 11, str. 355 – 364.
- Pajares G., Cruz J.M., Aranda J., 1998. Stereo matching based on the self-organizing feature-mapping algorithm, *Pattern Recognition Letters* 19, s. 319-330.
- Piekarski P., Mikrut Z., 2007. Wykorzystanie transformacji log-Hougha do tworzenia reprezentacji obrazu dla klasyfikatora neuronowego. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 17, Dobczyce (w tym tomie)
- Sarjakoski T., 1988. Artificial intelligence in Photogrammetry. *Photogrammetria (PRS)* 42, s. 245-270.
- Schwartz E.L., 1977. Spatial mapping in the primate sensory projection: analytic structure and relevance to perception. *Biological Cybernetics*, nr 25, s. 181-194.
- 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
- Tadeusiewicz R., 1993. *Sieci neuronowe*. AOW Warszawa.
- 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.
- 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
- Weiman C.F.R., 1989. Polar exponential sensor arrays unify iconic and Hough space representation. *Proc. SPIE* vol.1192: *Intelligent robots and computer vision VIII*.
- Zheng Y-J, 1992. Feature extraction: a neural network oriented approach. *Int. Archives of Photogrammetry and Remote Sensing*, vol. 29.

Opisane badania zostały wykonane w ramach grantu KBN nr 4T12E 001 27.

NEURAL NETWORKS IN AUTOMATIC MATCHING PROCESSES ON AERIAL IMAGES

KEY WORDS: digital photogrammetry, neural networks, correlation, images matching

SUMMARY: The concept of the research was based on the selection of several representations, which were later correlated by means of conventional, and neural methods. In the course of research, conventional methods of image matching were tested and compared with neural methods that originating from the research process. Additionally, experiments consisting in manual measurements, performed by independent observers, were conducted.

The essence of methodology that was based on neural networks consisted in the preparation of suitable representations of image fragments and using them for the classification of various types of neural networks. One of the assumed methods was based on the distribution of image gradient module value and of its direction. The usability of that representation for the selection of sub-images was tested by means of SOM Kohonen neural network. Another method consisted in the utilisation of the log-polar and log-Hough transforms, which are considered to be simplified models of preliminary image processing, performed by visual systems of people and animals. The usability of that representation was tested by means of the *backpropagation* type of neural network. As regards the generation of the third representation, the ICM (Intersecting Cortical Model) network was applied, which is one of the versions of the PCNN (Pulse Coupled Neural Network). Using that network, the so-called image *signatures*, or vectors composed of tens of elements which describe the image structure, were generated.

dr inż. Sławomir Mikrut
e-mail: smikrut@agh.edu.pl
telefon: (012) 617 23 02
fax: (012) 617 39 93

dr inż. Zbigniew Mikrut
e-mail: zibi@agh.edu.pl
telefon: (012) 617 38 53