

**SELEKCJA PODOBRAZÓW DLA POTRZEB DOPASOWYWANIA ZDJĘĆ
LOTNICZYCH OPARTA NA HISTOGRAMACH GRADIENTU I SIECI
NEURONOWEJ**

**SELECTION OF SUB-IMAGES FOR AERIAL PHOTOGRAPHS MATCHING
PURPOSES BASED ON GRADIENT DISTRIBUTION AND NEURAL
NETWORKS**

Anna Czechowicz¹, Zbigniew Mikrut²

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

²Katedra Automatyki, Akademia Górniczo-Hutnicza w Krakowie

SŁOWA KLUCZOWE: fotogrametria, wzajemne dopasowanie, algorytm Canny'ego, histogram gradientów, SOM, sieci Kohonena, sieci backpropagation

STRESZCZENIE: Artykuł przedstawia wyniki wykorzystania sieci neuronowych do selekcji podobrazów oraz wyniki wyszukiwania wybranych obszarów na pozostałych zdjęciach z wykorzystaniem rozkładu odpowiedzi dla sieci SOM Kohonena. Zaproponowano reprezentację fragmentu obrazu opartą na rozkładzie wartości modułu gradientu i jego kierunku. Badania przeprowadzono na dziewięciuset podobrazach zdjęć lotniczych okolic Krakowa o różnym pokryciu terenu podzielonych na trzy kategorie: obszarów korzystnych, pośrednich i niekorzystnych pod względem wyszukiwania cech do orientacji wzajemnej. Dla każdego z obrazów, w oparciu o algorytm Canny'ego, wyznaczono krawędzie. Na podstawie wartości gradientu i kierunków wykrytych krawędzi sporządzono histogram, który następnie posłużył wyznaczeniu reprezentacji podobrazu w postaci profilu kierunku. Tak przygotowaną reprezentację wykorzystano do uczenia sieci neuronowych metodą nadzorowaną (*backpropagation*) oraz nienadzorowaną (Kohonena), a następnie do klasyfikacji obszarów nauczonymi sieciami. W przypadku sieci *backpropagation* miarą efektywności klasyfikacji był globalny współczynnik rozpoznania oraz macierz pomyłek. Dla sieci Kohonena wyznaczano współczynnik kompletności i poprawności. Wyniki zestawiono z rezultatami otrzymanymi na drodze uczenia metodą wstecznej propagacji błędów, gdzie generowane na mapie Kohonena odpowiedzi stanowiły sygnał wejściowy dla warstwy *backpropagation*. W dalszym etapie wytypowane obszary korzystne poszukiwano na sąsiednich obrazach. Wzmocniony funkcją preferującą wysokie wartości rozkład odpowiedzi na mapie cech sieci Kohonena, uzyskany dla podobrazów korzystnych, porównywano z rozkładem dla podobrazów o tych samych wymiarach na sąsiednich zdjęciach. Za miarę podobieństwa obszarów przyjęto współczynnik korelacji dla porównywanych odpowiedzi sieci.

1. WPROWADZENIE

Wyznaczenie wzajemnego położenia kolejnych zdjęć lotniczych to jeden z podstawowych etapów przygotowania modelu fotogrametrycznego.

Automatyzacja tego procesu jest jednym z kluczowych problemów fotogrametrii. W typowej procedurze można wymienić osiem etapów: 1) pozyskanie piramidy obrazów dla obu zdjęć, 2) wyznaczenie pokrycia oraz przybliżonych wartości obrotu i różnicy skali między zdjęciami na najwyższym poziomie piramidy, 3) pozyskanie cech, 4) dopasowanie tych cech, 5) wyznaczenie zgrubnych wartości parametrów orientacji wzajemnej, 6) powtórzenie procedur pozyskania i dopasowania cech oraz określenia parametrów na coraz niższych poziomach piramidy obrazów w celu zwiększenia dokładności, 7) określenie położenia punktów homologicznych z podpixselową dokładnością, 8) obliczenie elementów orientacji wzajemnej (Heipke, 1997).

Wśród tych etapów najistotniejsze i najtrudniejsze są: etap pozyskania cech na obrazie oraz poszukiwanie ich odpowiednika na pozostałych obrazach. Pozyskiwanymi cechami są punkty, linie oraz powierzchnie. Wśród stosowanych metod pasowania wyróżnić można najpopularniejszą korelację krzyżową, pasowanie metodą najmniejszych kwadratów (*Least Squares Matching*), *Feature Based Matching* lub *Relational Matching* (Heipke, 1997).

Opisywane badania obejmowały dwa etapy. Pierwszy to etap klasyfikacji, w którym sprawdzano możliwości wykorzystania sieci neuronowych (typu *backpropagation* oraz *Self Organizing Map* Kohonena) do selekcji na zdjęciu lotniczym obszarów „korzystnych” pod względem wyszukiwania elementów wiążących. Drugi to etap wyszukiwania wybranego „korzystnego” obszaru na pozostałych zdjęciach z wykorzystaniem odpowiedzi generowanych na mapie SOM.

W ramach badań zaproponowano dwustopniową reprezentację fragmentu obrazu. Za podstawową reprezentację przyjęto informację o rozkładzie wartości gradientu oraz jego kierunku (por. pkt 2). Drugą reprezentację utworzyły wartości odpowiedzi neuronów z warstwy SOM Kohonena (por. pkt 4).

2. PODSTAWOWA REPREZENTACJA OBRAZU

Dla analizowanego fragmentu obrazu cyfrowego wyznaczana jest wartość amplitudy gradientu oraz jego kierunek. Wartości te obliczane są przy pomocy algorytmu Canny’ego (Parker, 1996). Algorytm składa się z dwóch etapów: wstępnego, obejmującego redukcję szumów funkcją Gaussa oraz właściwego, w którym obliczany jest gradient odszumionego obrazu.

Po usunięciu zakłóceń z obrazu wyznaczany jest gradient w dwóch prostopadłych do siebie kierunkach. W wyniku konwolucji odszumionego obrazu z odpowiednią maską filtrującą powstają obrazy gradientu poziomego i pionowego, oznaczone w dalszej części jako S_x oraz S_y .

Wyznaczenie wartości amplitudy gradientu i jego kierunku to proste operacje punktowe obliczane zgodnie z równaniami (1) oraz (2)

$$(1) M(k,l) = \sqrt{S_x(k,l)^2 + S_y(k,l)^2}$$

$$(2) \Theta(k,l) = \arctg S_y(k,l)/S_x(k,l)$$

gdzie:

- M – amplituda gradientu
- Θ – kierunek amplitudy gradientu
- k, l – współrzędne piksela obrazu

2.1. Dwuwymiarowy histogram gradientu

Reprezentacja obrazu w postaci dwuwymiarowego histogramu gradientu w wyznaczana jest dla wszystkich pikseli obrazu, które są pikselami krawędzi. W celu ich wykrycia zastosowano dwie wartości progowe dla gradientu: wysoką (60) oraz niską (30). Przyjmując, że krawędź występuje w miejscach, dla których wartość amplitudy gradientu jest większa od wartości progowych, utworzono dwa obrazy zawierające piksele krawędzi. Oba zostały wykorzystane podczas grupowania pikseli krawędzi metodą śledzenia krawędzi (*edge tracking*), gdzie w pierwszej kolejności algorytm wyznacza przebieg krawędzi na obrazie o progu 60, luki zaś uzupełnia informacją z obrazu o progu 30.

Pojedyncze pole dwuwymiarowego histogramu gradientu odpowiada liczbie pikseli krawędzi, dla których wartości gradientu oraz jego kierunku mieszczą się w zadanych przedziałach:

$$(3) w_{ij} = \sum_{k=1}^{k=K} \sum_{l=1}^{l=L} p_{ij}(k, l) \quad i = 1, 2, \dots, n \quad j = 1, 2, \dots, m$$

przy czym:

$$(4) p_{ij}(k, l) = \begin{cases} 1 & \text{gdy } M(k, l) = i \wedge \Theta(k, l) = j \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

gdzie:

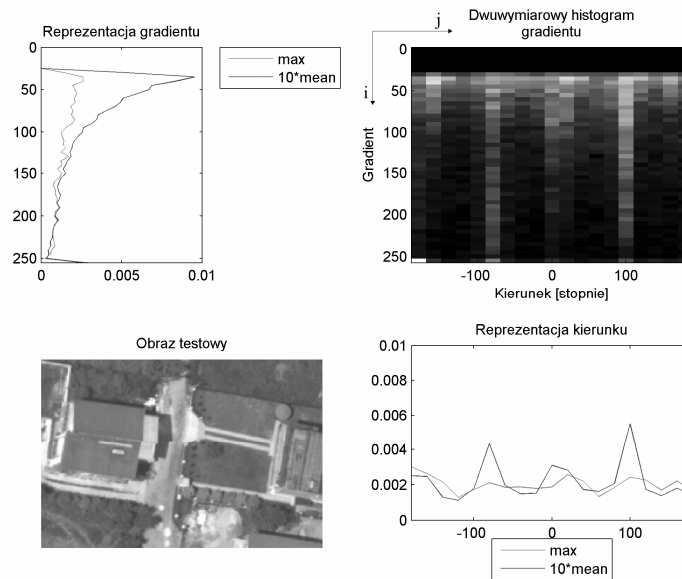
- w_{ij} – wartość dwuwymiarowego histogramu gradientu
- n, m – liczba przedziałów, na które został podzielony odpowiednio zakres wartości kąta i wartości gradientu
- k, l oraz K, L – odpowiednio współrzędne i rozmiar obrazu wejściowego

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 (utworzonych w analogiczny sposób).

Przykładowy histogram wraz z wizualizacją wektorów cech przedstawiono na rysunku 1.

W celu wykrycia ewentualnych różnic w przebiegu reprezentacji dla obszarów różniących się pokryciem terenu pozyskano wektory cech dla kilku fragmentów zdjęć lotniczych. Obrazy podzielono na dwie grupy: reprezentujące obszary korzystne oraz niekorzystne pod względem wyszukiwania cech do orientacji wzajemnej zdjęć. Obszary

korzystne to takie, które charakteryzują się dużą ilością przebiegających pod różnymi kątami elementów liniowych oraz elementów kontrastowych. Są to np. tereny zabudowane, miejsca skrzyżowań dróg (Rys. 1). Obszary niekorzystne zaś to te, na których znajdują się równoległe linie lub nie występują kontrastowe elementy. Są to np. obrazy pól uprawnych, łąk, lasów, zbiorników wodnych.



Rys. 1. Dwuwymiarowy histogram gradientu i wektory cech (profile) dla obszaru „korzystnego”

Charakter reprezentacji kierunku różni się w większości przypadków dla obu typów obszarów. Zaobserwowano co najwyżej dwa maksima dla obszarów niekorzystnych oraz co najmniej trzy maksima dla obszarów korzystnych (Rys. 1). W przypadku wykresów profilu modułu nie stwierdzono wyraźnych różnic w przebiegu reprezentacji. Na tym etapie badań przyjęto więc jedynie kątowe zależności, jako wystarczające do próby podziału obszarów obrazu na korzystne i niekorzystne pod względem wyszukiwania punktów do orientacji wzajemnej.

3. KLASYFIKACJA PODOBRAZÓW ZDJĘĆ LOTNICZYCH

Źródłem danych są zdjęcia lotnicze obszaru Krakowa w skali szarości (składowa G z obrazu kolorowego RGB) o rozdzielczości 600 dpi, z których wybrano 900 podobrazów o wymiarze 240x160 pikseli. Dla podobrazów wyznaczono profil maksymalnych i średnich wartości kierunku gradientu z agregacją kąta 5° oraz 20° (por. rys. 2).

Każdy podobraz został zaklasyfikowany niezależnie przez pięciu ekspertów fotogrametrów do jednej z trzech grup: obszarów korzystnych, niekorzystnych oraz pośrednich pod względem wyszukiwania elementów do wzajemnego dopasowania zdjęć. Przynależność do danej klasy wyznaczała wartość medianowa klasyfikacji. Próbkę

podzielono na dwa zbiory: uczący oraz testowy. Wektory danych znormalizowano do przedziału 0÷1.

Sieci neuronowe uczone dwiema metodami: nadzorowaną - wykorzystując sieć typu *backpropagation* i nienadzorowaną – stosując sieć SOM Kohonena, oraz na dwa sposoby – zbiorami uczącymi składającymi się z trzech lub dwóch klas. W pierwszym przypadku zbiór uczący składał się z próbek wszystkich trzech klas, w drugim zaś z próbek klasy korzystnej i niekorzystnej. Klasyfikacja próbek pośrednich wykonana przez ekspertów charakteryzowała się największą ilością skrajnych ocen, stąd do badań przyjęto również wariant z dwiema klasami.

W dalszej części artykułu przedstawione będą jedynie wyniki uczenia i testowania dwiema klasami, gdyż dla nich uzyskano wyższą efektywność klasyfikacji.

3.1. Klasyfikacja obszarów metodą nadzorowaną z wykorzystaniem sieci typu *backpropagation*

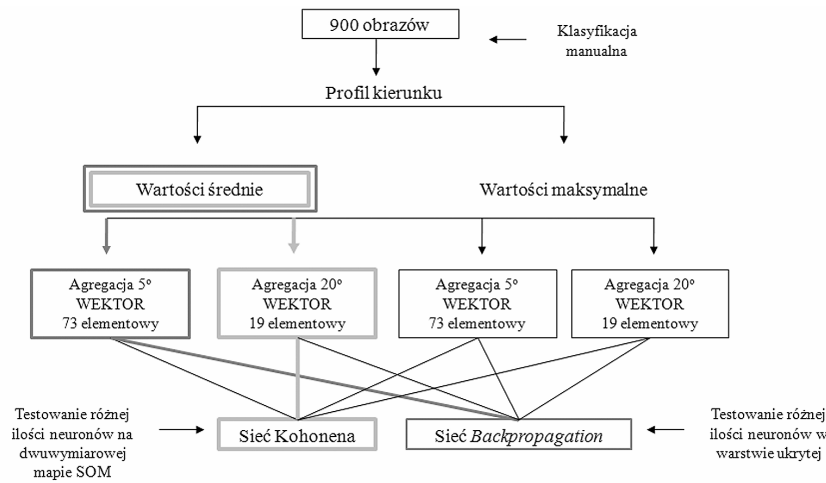
Jedną z podstawowych cech mających wpływ na efektywność sieci typu *backpropagation* jest liczba warstw ukrytych oraz ich wielkość (ilość neuronów). Badania przeprowadzono dla sieci z jedną warstwą ukrytą o zmiennej liczbie neuronów. Aktualizacja wag następowała każdorazowo po prezentacji całego zbioru uczącego tj. po jednej epoce. Sieć uczona była przy użyciu algorytmu Levenberga-Marquardta z logarytmiczną funkcją transferu w 2000 epok. Do eksperymentów wykorzystano Neural Network Toolbox środowiska programistycznego Matlab (Beal, 1998).

Rezultaty uczenia osiągnęły wartość 100%, natomiast wyniki rozpoznania wyniosły średnio 85.1%, maksymalnie 86.8% dla reprezentacji średniej wartości kierunku gradientu z agregacją kąta 20°. Dla wszystkich czterech reprezentacji i wybranych wielkości warstwy ukrytej, dla których globalny współczynnik rozpoznania osiągnął lokalne maksimum, przeprowadzono kilkukrotne uczenie sieci przy tych samych parametrach, przyjmując różne wartościami wag początkowych. W tabeli 1 zestawiono globalne rozpoznania oraz macierz pomyłek dla najlepszego wyniku. Podczas jego wyboru kierowano się nie tyle najwyższą wartością globalnego rozpoznania, ale zasadą, że bardziej niepożądanym przypadkiem jest taki, gdy sieć zaklasyfikuje obszary niekorzystne (n) jako korzystne (k), niż gdy obszary korzystne zostaną pominięte (por. podświetlone pole w tabeli 1).

Tab 1. Wyniki uczenia i rozpoznania dla profilu średnich wartości kierunku gradientu i 10 neuronów w warstwie ukrytej (struktura sieci: 73 – 10 – 2)

		Profil średnich wartości kierunku 73 – 10 – 2*				
		Zbiór uczący		Zbiór testowy		
Rozpoznanie		99.1%		84.9%		
Macierz pomyłek		k	n	k	n	
		k	168	3	151	16
		n	0	159	25	80

* notacja: liczebność warstwy wejściowej – ukrytej – wyjściowej



Rys. 2. Schemat badań dla celów klasyfikacji podobrazów zdjęć lotniczych (szarym obramowaniem wyróżniono najlepsze wyniki)

3.2. Klasyfikacja obszarów metodą nadzorowaną z wykorzystaniem warstwy SOM oraz sieci *backpropagation*

Sieć *Self Organizing Map* Kohonena, jest jedną z najpopularniejszych sieci uczących się bez nadzoru. Zazwyczaj ma postać regularnej siatki dwuwymiarowej (mapy), w której węzłach przechowywane są modele bardzo podobnych do siebie reprezentacji (Kohonen, 1997). Zdolność do grupowania reprezentacji z zachowaniem topologii powoduje bliskie umiejscowienie na mapie cech elementów podobnych – w tym przypadku obszarów o podobnych reprezentacjach (Tadeusiewicz, 1993). Powinno pozwolić to na wybranie neuronu (neuronów) odpowiadających za obszary korzystne, a tym samym na dokonanie selekcji podobrazów na zdjęciu lotniczym.

Podstawowy wpływ na proces grupowania sygnałów w przypadku sieci Kohonena ma jej wielkość, czyli ilość neuronów składających się na dwuwymiarową mapę cech. Badania przeprowadzono dla sieci dwuwymiarowych przyjmując różne rozmiary warstwy. Aktualizacja wag następowała każdorazowo po prezentacji całego zbioru uczącego. Testowane sieci powstały w środowisku MATLAB z wykorzystaniem funkcji biblioteki SOM Toolbox udostępnionej przez Laboratory of Computer and Information Science Uniwersytetu w Helsinkach (Alhoniemi, 2005).

Proces uczenia analizowano śledząc dwa parametry świadczące o efektywności uczenia tj. współczynnik kwantyzacji q_e oraz topologii t_e . Współczynnik kwantyzacji to średnia odległość pomiędzy zbiorem próbek i jego wektorem zwycięzcą, współczynnik topografii zaś jest stosunkiem wszystkich wektorów, dla których pierwszy i drugi neuron zwycięzca nie są sąsiadami (Vesanto, 2000).

Koncepcję klasyfikacji obszarów metodą nienadzorowaną z wykorzystaniem sieci SOM Kohonena i techniki odrzuceń (wyboru kilku najlepiej rozpoznających neuronów) przedstawiono w (Czechowicz, Mikrut, 2007). Do eksperymentów wybrano sieć Kohonena

19-28[7x4] (ilość wejść – ilość neuronów [wymiar sieci]) uczoną reprezentacją profilu średnich wartości kierunku z agregacją 20°, którą uznano za najefektywniej klasyfikującą podobrazy zdjęć lotniczych. Generowane przez nią odpowiedzi stanowiły sygnał wejściowy dla warstwy *backpropagation*, która dokonywała ostatecznej klasyfikacji, ucząc się metodą nadzorowaną.

Rezultaty uczenia dla najefektywniej klasyfikującej sieci typu *backpropagation* z pięcioma neuronami w warstwie ukrytej zestawiono w tabeli 2. Wyniki rozpoznania osiągnęły wartość 84.5% (por. tab 2) i są porównywalne z otrzymanymi na drodze klasyfikacji nadzorowanej z wykorzystaniem podstawowej reprezentacji podobrazu (por. tab 1).

Tab 2. Wyniki selekcji podobrazów zbioru uczącego i testowego

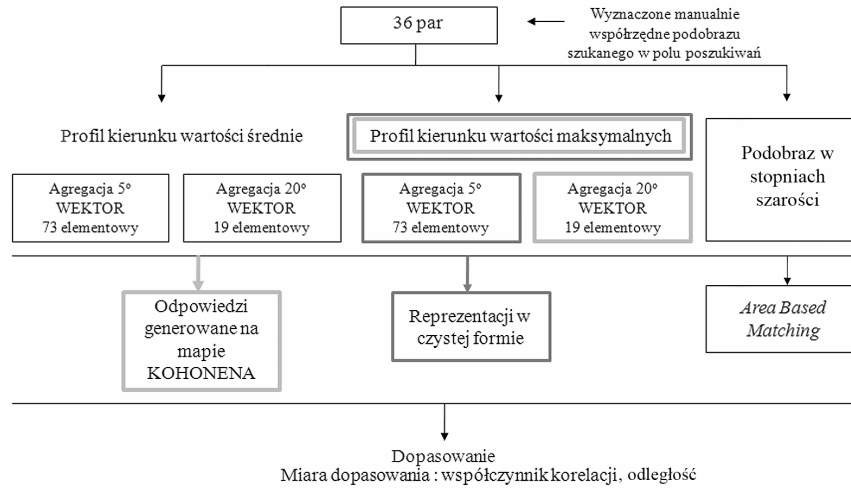
Rozpoznanie		Profil średnich wartości kierunku 73 – 10 – 2*			
		Zbiór uczący		Zbiór testowy	
		98.2%		84.5%	
Macierz pomyłek	k	160	13	139	5
	n	8	149	37	91

- notacja: liczebność warstwy wejściowej – SOM[wymiar] – ukrytej – wyjściowej

4. WZAJEMNE DOPASOWYWANIE PODOBRAZÓW ZDJĘĆ LOTNICZYCH

Proponowana metoda dopasowania składa się z kilku etapów. Dla podobrazu sporządzana jest reprezentacja podstawowa np. w postaci profilu średnich wartości kierunku z agregacją 5°. Reprezentacja ta podawana jest następnie na wejście nauczonej sieci SOM Kohonena, która generuje odpowiedzi. Neurony sieci reagują na podaną próbkę w ten sposób, że przechowujące podobny model reprezentacji uzyskują wysokie wartości, przechowujące zaś odmienny model niskie. Dla procesu dopasowania istotne są odpowiedzi wysokie, dlatego też podlegają one wzmocnieniu (wzmocnienie polega na podniesieniu wszystkich wartości odpowiedzi do potęgi trzeciej). Tak przetworzona informacja o podobrazie jest porównywana z podobną uzyskaną dla podobrazów w polu poszukiwań. Miarą dopasowania jest maksymalny współczynnik korelacji.

Eksperymenty przeprowadzono na zbiorze 36 par obrazów, na które składały się wyselekcjonowane uprzednio podobrazy „korzystne” oraz ich odpowiedniki (obramowane pasem o szerokości 150 pikseli). Zaproponowaną metodę dopasowania porównano z metodą opartą na korelacji reprezentacji w postaci profilu kierunku oraz z metodą *area based matching* wykorzystującą korelację krzyżową opartą na kowariancji (Stefano, 2004). Dla każdej pary podobrazów manualnie wyznaczono współrzędne lewego górnego narożnika podobrazu w polu poszukiwań. Jako miarę prawidłowości dopasowania przyjęto maksymalny współczynnik korelacji oraz odległość pomiędzy współrzędnymi lewego górnego narożnika wyznaczonymi w wyniku dopasowania, a współrzędnymi wyznaczonymi manualnie. Schemat postępowania przedstawia rysunek 3.




Rys. 3. Schemat badań dla celów wzajemnego dopasowania wybranych uprzednio jako „korzystne” fragmentów zdjęć lotniczych (szarym obramowaniem wyróżniono najlepsze wyniki)

Wyniki zestawiono w formie trójwymiarowych histogramów. Histogram dla metody dopasowania wykorzystującej odpowiedzi generowane na mapie Kohonena o wymiarach 7x4 neuronów uczonej reprezentacją w postaci średnich wartości kierunku z agregacją kąta 20° przedstawia rysunek 4. Przyjmując, że wyszukane poprawnie obszary charakteryzują się odległością nie większą niż 30 pikseli uzyskano następujące wyniki poprawnej lokalizacji podobrazów na sąsiednich zdjęciach:

- dla wyżej opisanej metody dopasowania 10/36
- dla metody porównującej reprezentacje w postaci profilu kierunku 2/36
- dla metody *area based matching* 36/36 (por tab 3).

Tab 3. Wyniki dopasowania fragmentów zdjęć lotniczych

Odpowiedzi generowane na SOM			Reprezentacja obrazu			<i>Area Based Matching</i>		
< 30	30-50	> 50	< 30	30-50	> 50	< 30	30-50	> 50
10	10	16	2	5	29	36	0	0



Rys. 4. Trójwymiarowy histogram rozkładu dopasowania obrazów dla metody wykorzystującej odpowiedzi na mapie SOM

5. WNIOSKI

Zaproponowana reprezentacja obrazu w postaci profilu kierunku może być wykorzystywana do selekcji podobrazów na zdjęciach lotniczych. Uzyskana efektywność klasyfikacji z wykorzystaniem sieci neuronowych jest zadowalająca i osiąga wartości: dla sieci *backpropagation* uczonej reprezentacją podstawową 84.9%, uczonej zaś odpowiedziami SOM 84.5%. W przypadku sieci typu *backpropagation* efektywność klasyfikacji może zostać jeszcze poprawiona poprzez zastosowanie techniki odrzuceń z wykorzystaniem pewności rozpoznania.

Dopasowanie podobrazów metodą porównywania rozkładów odpowiedzi na mapie Kohonena nie powiodło się. Ilość prawidłowo zlokalizowanych podobrazów na sąsiednich zdjęciach (przy założeniu granicznej odległości 30) pikseli wynosi 10/36, podczas gdy w przypadku metody wykorzystującej korelację krzyżową wynosi 36/36. Powodem słabego wyniku może być fakt, iż reprezentacje porównywanych podobrazów opisują nie cały podobraz, a tylko jego fragmenty zawierające elementy charakterystyczne. Poprawa efektywności dopasowania w dalszej kolejności powinna więc uwzględnić zmniejszenie podobrazu tak aby charakter reprezentacji nie uległ zmianie oraz aby na zmniejszonym podobrazie występowały tylko elementy charakterystyczne.

6. LITERATURA

Alhoniemi E., Himberg J., Parhankangas J., Vesanto J., 2005 SOM Toolbox
www.cis.hut.fi/projects/somtoolbox/

Beal M., Demuth H., 1998 *Neural Network Toolbox for use in Matlab*, The MathWorks Inc.
Czechowicz A., Mikrut Z., 2007 Wykorzystanie sieci Kohonena do selekcji podobrazów dla potrzeb dopasowania zdjęć lotniczych, *Automatyka AGH*, t.11, z.3, w druku

- Heipke C., 1997 Automation of interior, relative and absolute orientation. *ISPRS Journal of Photogrammetry & Remote Sensing*, 52, s. 1-19
- Kohonen T., 1997 *Self-Organizing Maps*, New York , Springer-Verlag
- Parker J.R., 1996 *Algorithms for Image Processing and Computer Vision*, Wiley
- Stefano L., Marchionni M., Mattocchia S, 2004 A fast area-based stereo matching algorithm, *Image and Vision Computing*,22, s. 983-1005
- Tadeusiewicz R., 1993 *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, W-wa
- Vesanto J., Alhoniemi E., Himberg J., Parhankangas J., 2000 SOM Toolboxfor Matlab 5, <http://www.cis.hut.fi/projects/somtoolbox/documentation>

Praca finansowana jest z grantu Komitetu Badań Naukowych nr 4T12E 001 27

SELECTION OF SUB-IMAGES FOR AERIAL PHOTOGRAPHS MATCHING PURPOSES BASED ON GRADIENT DISTRIBUTION AND NEURAL NETWORKS

KEY WORDS: photogrammetry, mutual matching, Canny edge detector, gradient histogram, SOM, Kohonen networks, backpropagation networks

SUMMARY: This paper describes the application of neural networks for selection of sub-images and the result of the search for the selected areas on the remaining photographs with the utilisation of Kohonen's SOM network responses distribution. Image fragment representation based on the gradient magnitude values distribution and its direction was proposed. The research was conducted on nine hundred sub-images, taken from aerial photographs of the Cracow's environs with different terrain cover, divided into three categories: advantageous, intermediate and disadvantageous areas in respect of searching for the features for mutual matching. The edges were detected with Canny algorithm. Based on the gradient values and the directions of the edges, the histogram was created and used to determine the representation of the sub-image in the direction's profile form. The prepared representation served for teaching the neural network using supervised (*backpropagation*) and unsupervised (Kohonen) method and later for the classification. For the *backpropagation* network, the classification effectiveness was measured using the global recognition coefficient and the co-occurrence matrix. For the Kohonen network, the completeness and correctness coefficients were determined. Afterwards, the two networks were put together: the responses generated on the Kohonen map constituted the input signal for the *backpropagation* layer. In the next step, the adjacent images were sought for the chosen areas. Response distribution on the Kohonen network feature map, amplified with the function preferring the high values, was compared with the distribution for the same size sub-images of the adjacent photographs. To measure the similarity of the subimages, the correlation coefficient to compare network's responses was used.

mgr inż. Anna Czechowicz
e-mail: eire02@op.pl
telefon: (012) 617 23 02
fax: (012) 633 17 91

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