

**LOKALIZACJA PUNKTÓW POMIAROWYCH W SYSTEMIE
DO TRÓJWYMIAROWEGO POZYCJONOWANIA CIAŁA
WYBRANYMI METODAMI SZTUCZNEJ INTELIGENCJI**

**DETECTION OF MEASUREMENT POINTS IN A 3D BODY POSITIONING
SYSTEM BY MEANS OF ARTIFICIAL INTELLIGENCE**

Anna Czechowicz, Regina Tokarczyk

Katedra Geoinformacji, Fotogrametrii i Teledetekcji Środowiska,
Akademia Górniczo-Hutnicza

SŁOWA KLUCZOWE: fotogrametria, pozycjonowanie ciała, sieci neuronowe, perceptron wielowarstwowy, wsteczna propagacja błędów, sieci z radialnymi funkcjami bazowymi

STRESZCZENIE: Fotogrametryczny system cyfrowy do pomiaru ciała ludzkiego dla celów badania wad postawy służy do wyznaczania przestrzennego położenia wybranych jego punktów. Wymaga on pomierzenia na zdjęciach cyfrowych trzech grup punktów, zwanych w tytule referatu punktami pomiarowymi: fotopunktów, markerów sygnalizowanych na pacjencie oraz źrenic oczu. Fotopunkty to czarno-białe sygnały pozwalające na orientację w przestrzeni modelu utworzonego ze zdjęć. Markery to styropianowe kulki o średnicy 4÷5 mm sygnalizujące wybrane elementy kośćca umieszczone na powierzchni ciała. Artykuł dotyczy wykorzystania sieci neuronowych do lokalizacji fotopunktów i styropianowych markerów. Zadaniem sieci jest klasyfikacja kolejnych fragmentów obrazu na zawierające obraz fotopunktu, markera lub niezawierające obrazu żadnego z nich. W ramach badań sprawdzono możliwość przeprowadzenia zdefiniowanej powyżej klasyfikacji sieciami o architekturze wielowarstwowego perceptronu (ang. *Multi Layer Perceptron –MLP*) ze wsteczną propagacją błędu oraz sieciami z radialnymi funkcjami bazowymi RBF (ang. *Radial Basis Function Networks*). Zweryfikowano przydatność reprezentacji opartej na informacji o rozkładzie wartości gradientu oraz jego kierunku dla celów wykrycia punktów pomiarowych. Wspomniana reprezentacja wywodzi się z badań nad selekcją podobrazów dla potrzeb dopasowania zdjęć lotniczych.

1. WPROWADZENIE

Celem pracy jest sprawdzenie przydatności wykorzystania sieci neuronowych do lokalizacji fotopunktów i styropianowych markerów w systemie do badania wad

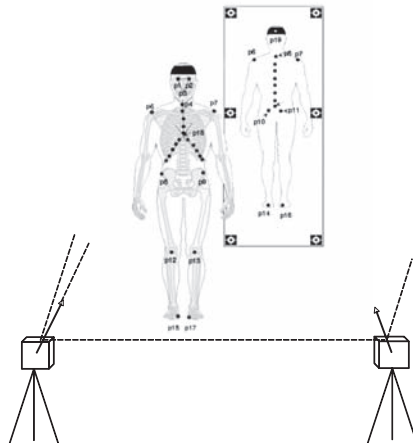
postawy. Zadaniem sieci jest klasyfikacja kolejnych fragmentów obrazu na zawierające obraz fotopunktu, markera lub go niezawierające. Wybór tej metodyki jest podyktowany pewnym doświadczeniem w zastosowaniu jej do innych zagadnień fotogrametrycznych (Czechowicz, Mikrut, 2007a; 2007b) jak również możliwością oparcia badań na bardzo bogatym materiale doświadczalnym, pochodzącym z rejestracji pacjentów z użyciem systemu w gabinecie rehabilitacyjnym. Do przebadania zastosowania metod sztucznej inteligencji zachęcają też pozytywne wyniki użycia sieci neuronowych w detekcji źrenic oczu dla potrzeb systemu (Tokarczyk *et al.*, 2007).

W niniejszych badaniach do klasyfikacji obiektów wykorzystano sieci o architekturze wielowarstwowego perceptronu (ang. *Multi Layer Perceptron - MLP*) ze wsteczną propagacją błędów oraz sieci z radialnymi funkcjami bazowymi RBF (ang. *Radial Basis Function Networks*).

W ramach badań zweryfikowano przydatność reprezentacji opartej na informacji o rozkładzie wartości gradientu oraz jego kierunku dla celów wykrycia punktów pomiarowych.

2. OPIS SYSTEMU DO TRÓJWYMIAROWEGO POZYCJONOWANIA CIAŁA

Rejestracja obrazów w systemie pomiarowym dokonywana jest dwoma cyfrowymi aparatami fotograficznymi, którymi wykonuje się równocześnie zdjęcia o osiach zbieżnych i w przybliżeniu poziomych w taki sposób, aby oprócz przedniej części ciała pacjenta uwidocznione było również odbicie tylnej jego części w lustrze (Rys. 1).



Rys. 1. Schemat fotogrametrycznego systemu do pomiaru geometrii ciała ludzkiego dla celów badania wad postawy.

Fotopunkty to sześć czarno-białych sygnałów, pozwalających na orientację w przestrzeni 3D modelu utworzonego ze zdjęć. Znajdują się one na powierzchni lustra, równomiernie po trzy wzdłuż dłuższych jego krawędzi. Takie ich umieszczenie pozwala na proste obliczenie położenia punktów z tyłu pacjenta, znajdujących się w odbiciu zwierciadlanym.


Markery to styropianowe kulki o średnicy 4÷5 mm sygnalizujące przeniesione na powierzchnię ciała wybrane elementy kośćca. Pomiarowi podlega osiemnaście markerów standardowych oraz kilkanaście na kręgosłupie i mostku.

Dotychczasowe rozwiązania automatyzacji detekcji i pomiaru fotopunktów to wykorzystanie korelacji krzyżowej z zastosowaniem wzorca „wyciętego” ze zdjęcia. Podniesienie dokładności do podpikselowej odbywa się z wykorzystaniem metody wagowego środka ciężkości. Detekcja markerów opiera się na metodzie korelacji krzyżowej wzbogaconej o elementy analizy morfologicznej. Wykrycie i pomiar źrenic oczu to zastosowanie sieci neuronowych ze wsteczną propagacją błędów.

Oprogramowanie systemu pozwala na wczytanie i wyświetlenie obrazów obok siebie, pomiar na zdjęciach, wykonanie obliczeń oraz przedstawienie wyników w postaci graficznej i tabelarycznej. Zawiera również bazę danych o pacjentach.

3. WYBÓR DANYCH DO EKSPERYMENTÓW

Przeprowadzone eksperymenty dotyczą klasyfikacji kolejnych fragmentów zdjęcia cyfrowego na fragmenty zawierające obraz fotopunktu (Rys. 2), obraz markera (Rys. 2) lub niezawierające obrazu żadnego z nich. W związku z poszukiwaniem dwóch różnych obiektów przygotowano dwie bazy danych. Pierwsza z nich została wykorzystana do uczenia sieci w celu rozpoznania fotopunktów, druga zaś do uczenia sieci w celu rozpoznania markerów.



Rys. 2. Zdjęcie cyfrowe pacjenta z przykładowymi fragmentami obrazu: a) fotopunktu, b) markera, c) nie-fotopunktu, nie-markera.

Baza danych dla celów rozpoznania fotopunktów składa się z 4040 kolorowych obrazów fotopunktów oraz 2280 kolorowych obrazów nie-fotopunktów. Dla celów rozpoznania markerów przygotowano bazę składającą się z 2470 kolorowych obrazów markerów oraz 2280 kolorowych obrazów nie-markerów. Wymiar obrazów podyktowany jest wielkością znaczka sygnalizującego fotopunkt i wynosi 30x30 pikseli (fotopunkt poszerzony o pas kilku pikseli). W niniejszym artykule mianem nie-fotopunktu, nie-markera określane będzie fragment zdjęcia cyfrowego nie zawierający ani fotopunktu ani markera (Rys. 2).

4. REPREZENTACJA OBRAZU

W ramach badań zweryfikowano przydatność reprezentacji opartej na informacji o rozkładzie wartości gradientu oraz jego kierunku w celu wykrycia punktów pomiarowych. Wspomniana reprezentacja wywodzi się z badań nad selekcją podobrazów dla potrzeb dopasowania zdjęć lotniczych (Czechowicz, Mikrut, 2007a; 2007b).

Dla obrazu cyfrowego wyznaczana jest wartość amplitudy gradientu oraz jej kierunek. Wartości te obliczane są przy pomocy algorytmu Canny'ego (Parker, 1996). Reprezentacja obrazu w postaci dwuwymiarowego histogramu gradientu w (1), (2) wyznaczana jest dla wszystkich pikseli obrazu, które przynależą do krawędzi. W celu ich wykrycia zastosowano dwie wartości progowe dla gradientu: wysoką (równą 60) oraz niską (równą 30). Przyjmując, że krawędź obiektu 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 (ang. *edge tracking*), gdzie w pierwszej kolejności algorytm wyznacza przebieg krawędzi na obrazie o progu gradientu równym 60, luki zaś uzupełnia informacją z obrazu o progu gradientu równym 30. Pojedyncze pole dwuwymiarowego histogramu gradientu w_{ij} (1) odpowiada liczbie pikseli na obrazie, dla których wartości gradientu oraz jego kierunku mieszczą się w zadanym przedziałach (2). Dla zastosowanej reprezentacji przyjęto przedziały 20 jednostek dla gradientu oraz 20° dla kierunku, gdzie:

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

przy czym:

$$(2) \quad p_{ij}(k, l) = \begin{cases} 1 & \text{gdy } M(k, l) = i \wedge \Theta(k, l) = j \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

w_{ij} – wartość dwuwymiarowego histogramu gradientu,

n, m – liczba przedziałów, na które został podzielony odpowiednio zakres wartości kąta i wartości gradientu,

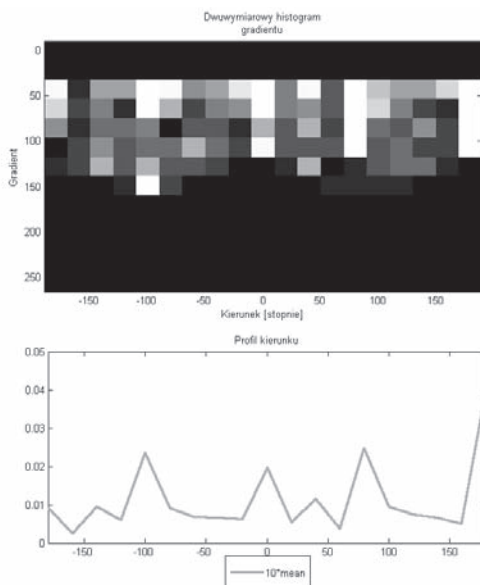
k, l, K, L – odpowiednio współrzędne i rozmiary obrazu wejściowego,

M – amplituda gradientu,

Θ – kierunek amplitudy gradientu,

Na podstawie tak przygotowanego histogramu wyznaczany jest wektor cech w postaci profilu średnich wartości kierunku (3), które powstają poprzez rzutowanie wartości średnich na oś kierunku (Rys. 3):

gdzie:



Rys. 3. Przykładowy histogram gradientu wraz z profilem średnich wartości kierunku dla fotopunktu z agregacją kąta 20°.

$$d_{sr}(j) = \frac{\sum_{i=1}^n (w_{ij})}{n}, \quad j = 1, 2, \dots, m \quad (3)$$

d_{sr} – wartość średnia kierunku.

Przykładowy histogram gradientu wraz z profilem średnich wartości kierunku dla fotopunktu przedstawiono na rysunku 3.

5. KLASYFIKACJA FRAGMENTÓW ZDJĘCIA CYFROWEGO

Klasyfikację fragmentów zdjęcia cyfrowego przeprowadzono metodami nadzorowanymi z wykorzystaniem sieci o architekturze wielowarstwowego perceptronu MLP ze wsteczną propagacją błędów oraz sieci z radialnymi funkcjami bazowymi RBF.

Baza danych została poddana wstępnemu przetwarzaniu, na który składała się standaryzacja oraz analiza składowych głównych (ang. *Principal Component Analysis*) dla uczenia sieci MLP oraz normalizacja do wartości 0÷1 dla sieci RBF.

Dla celów uczenia i testowania sieci MLP bazę danych podzielono na trzy podzbiory: uczący, walidacyjny oraz testowy. Na podstawie zbioru uczącego obliczany jest gradient oraz wyliczane są wagi i wartości obciążenia (*bias*) dla sieci. Na podzbiórce walidacyjnym kontrolowany jest błąd uczenia sieci w trakcie procesu uczenia. Jeżeli błąd dla tego zbioru zaczyna rosnąć przez kolejne 6 epok, proces uczenia zostaje zatrzymany, a dla neuronów przywrócone zostają wartości wag oraz obciążenie uzyskane dla najniższego błędu otrzymanego na zbiorze walidacyjnym. Zastosowanie zbioru walidacyjnego minimalizuje zjawisko przeuczenia sieci. Podzbiór testowy nie bierze udziału w procesie uczenia, służy ocenie jakości nauczonej sieci.

Dla celów uczenia sieci RBF baza danych została podzielona na dwa podzbiory: uczący oraz testowy.

Do wyznaczenia optymalnych współczynników wag, sieci uczono z wykorzystaniem walidacji skośnej (ang. *crossvalidation*). Zbiór danych podzielono na 10 części. Każda struktura sieci uczona była dziesięciokrotnie. W przypadku sieci MLP każdorazowo 9 części zbioru stanowiło zbiór uczący, zaś 1 część stanowiła zbiór testowy. Ze względów systemowych dla sieci RBF jedna część stanowiła zbiór uczący, dziewięć zaś zbiór testowy. Końcowe wagi uzyskano uśredniając wartości wag z wszystkich 10 uczeń.

Dokładność klasyfikacji opisano współczynnikiem globalnego rozpoznania obliczanym na podstawie wzoru (4).

gdzie:

r – globalny współczynnik rozpoznania,

$$(4) \quad r = \frac{TP + TN}{a}$$

a – liczba wszystkich próbek,

TP – (ang. *True Positive*) odpowiedź pozytywna, którą stanowią próbki klasy korzystnej rozpoznane przez sieć prawidłowo,

TN – (ang. *True Negative*) odpowiedź negatywna dodatnio, którą stanowią próbki klasy niekorzystnej rozpoznane przez sieć jako niekorzystne.

5.1. Klasyfikacja fragmentów zdjęcia cyfrowego z wykorzystaniem sieci MLP ze wsteczną propagacją błędów

Jednym z najlepiej znanych algorytmów uczenia sieci neuronowej jest metoda wstecznej propagacji błędów. Sieci uczy się na zbiorze składającym się z wektora wejściowego i odpowiadającego mu wektora wyjściowego. Uczenie odbywa się metodą nadzorowaną i polega na takim doborze wag neuronów, by w efekcie końcowym błąd popełniany przez sieć był mniejszy od zadanego. Błędy w poszczególnych warstwach sieci obliczane są począwszy od warstwy ostatniej w kierunku warstwy wejściowej. Liczba warstw może być dowolna. W prezentowanych badaniach wykorzystano sieć o jednej oraz dwóch warstwach ukrytych.

Ważną składową wpływającą na proces uczenia jest funkcja transferu. Funkcja transferu to funkcja określająca zazwyczaj nieliniową zależność między pobudzeniem neuronu, a jego wyjściem. W badaniach zastosowano dwa typy funkcji transferu: logistyczną oraz liniową.

Przetestowano dziewięć różnych algorytmów obliczania gradientu podczas procesu uczenia. Są to:

- algorytm ze zmiennym współczynnikiem uczenia (ang. *Variable Learning Rate Backpropagation*) (oznaczenie GDX),
- przyspieszony algorytm uczenia (oznaczenie RP),
- metoda gradientów sprzężonych z algorytmem Polak – Ribiera (oznaczenie CGP),
- metoda gradientów sprzężonych z algorytmem Powell – Beale’a (oznaczenie CGB),
- metoda gradientów sprzężonych (ang. *Conjugate Gradient*) z algorytmem Fletcher – Powell’a (oznaczenie CGF),
- metoda skalowanego gradientu sprzężonego (ang. *Scaled Conjugate Gradient*) (oznaczenie SCG),
- metody Quasi-Newtona:
 - *One Step Secant* (oznaczenia OSS),
 - *BFGS Quasi – Newton* (oznaczenia BFG)
 - *Levenberg – Marquardt* (oznaczenia LM).

5.1.1. Wyniki uczenia sieci MLP ze wsteczną propagacją błędów dla celów rozpoznania fotopunktów oraz markerów


Sieci uczono zmieniając liczbę neuronów w warstwie ukrytej od 2÷20. Optymalną ich liczbę wytypowano na podstawie maksymalnej wartości globalnego współczynnika rozpoznania (4), minimalnej różnicy między maksymalną a minimalną wartością globalnego współczynnika rozpoznania w jednym cyklu walidacji krzyżowej oraz średniej wartości zdefiniowanej uprzednio różnicy dla neuronów od 2÷20. Dodatkowo uwzględniono liczbę neuronów, która powinna być jak najmniejsza ze względu na fakt, że sieć o mniejszej liczbie neuronów w warstwie ukrytej ma potencjalnie większą możliwość generalizacji.

Ze względu na znaczną liczbę wyników, poniżej zaprezentowane zostaną jedynie wybrane, reprezentatywne dla każdej ze zdefiniowanych klasyfikacji.

Dla celów rozpoznania fotopunktów, w przypadku uczenia sieci z jedną warstwą ukrytą dla 2÷20 neuronów, najwyższe współczynniki globalnego rozpoznania oraz minimalne jego różnice w jednym cyklu walidacji uzyskano dla algorytmu *Levenberg – Marquardt* i funkcji logistycznej na wejściu oraz liniowej na wyjściu. Na rysunku 4 przedstawiono wartość globalnego współczynnika rozpoznania dla zbiorów: uczącego, walidacyjnego i testowego w zależności od liczby neuronów w warstwie ukrytej.

Z wykresu wynika, że uzyskana efektywność klasyfikacji waha się w przedziale 0.984÷0.997, maksymalną wartość dla zbioru testowego uzyskuje się dla 20 neuronów. Jednak ze względu na wspomnianą generalizację, wybrano sieć LM_19_11_2 jako najlepszą wśród badanych sieci z jedną warstwą ukrytą rozpoznającą fotopunkty (wynik

Wartość globalnego współczynnika rozpoznania dla sieci LMw zależności od ilości neuronów



Rys. 4. Wartość globalnego współczynnika rozpoznania dla sieci LM w zależności od ilości neuronów. Strzałką zaznaczono strukturę dla której prezentowane są szczegółowe wyniki w Tab. 1.

wskazany na wykresie strzałką). Globalny współczynnik rozpoznania dla zbioru uczącego wynosi 0.995, walidacyjnego 0.997, testowego zaś 0.996.

Jeżeli chodzi o uczenie sieci z dwoma warstwami ukrytymi najefektywniejsza okazała się sieć uczona metodą *Resilient Backpropagation* o 20 i 2 neuronach w warstwie ukrytej oraz funkcji logistycznej w warstwach ukrytych i liniowej w warstwie wyjściowej. Globalny współczynnik rozpoznania dla zbioru uczącego wynosi 1.00, walidacyjnego 1.00, testowego zaś 0.997.

W tabeli 1 zestawione są macierze pomyłek dla sieci z dwoma warstwami ukrytymi. Wartości powinny być odczytywane następująco (patrz. Tab. 1, zbiór testowy): 1 próbka fotopunktu (f) została zaklasyfikowana jako nie-fotopunkt (n-f), 200 uzyskało prawidłową klasyfikację. Wśród próbek nie-fotopunkt wszystkie, tj. 118 zostały zaklasyfikowane prawidłowo (0 próbek nie-fotopunkt zostało przyporządkowanych do klasy fotopunkt). Przekątna macierzy pomyłek zawiera poprawną klasyfikację. Wartości na niej umieszczone służą obliczeniu globalnego współczynnika rozpoznania.

Procedurę uczenia powtórzono dla celów rozpoznania markerów. W tym przypadku zastosowana reprezentacja okazała się opisem mało charakterystycznym i głównie ona wpłynęła na niskie wyniki uczenia. Dla wszystkich badanych metod globalny współczynnik rozpoznania dla zbiorów uczącego, walidacyjnego oraz testowego lokował się w okolicy wartości odpowiednio 0.520, 0.517 oraz 0.515 (Tab. 2).

Tab. 1. Macierz pomyłek rozpoznania fotopunktów dla sieci MLP ze wsteczną propagacją błędu.

		RP_19_20_2_2					
		Zbiór uczący		Zbiór walidacyjny		Zbiór testowy	
		f	n-f	f	n-f	f	n-f
Macierz pomyłek	f	3631	0	198	0	200	0
	n-f	2	2055	0	115	1	118

f– fotopunkt

n-f – nie-fotopunkt

Tab. 2. Globalny współczynnik rozpoznania dla sieci MLP dla celów rozpoznania markerów.

Globalny współczynnik rozpoznania		
Zbiór uczący	Zbiór walidacyjny	Zbiór testowy
0.520	0.517	0.515

Ze względu na reprezentację zaniechano badań nad wykorzystaniem sieci RBF dla celów rozpoznania markerów.

5.1.2. Wstępne badania nad wykorzystaniem sieci RBF do rozpoznania fotopunktów

Sieci RBF są przykładem sieci iteracyjnych. Sieci te mają zawsze tylko trzy warstwy: warstwę wejściową, warstwę ukrytą mającą neurony radialne oraz liniową warstwę wyjściową. Neuron w warstwie ukrytej realizuje funkcję zmieniającą się radialnie wokół wybranego centrum i przyjmuje wartości niezerowe tylko w jego otoczeniu. Każdy neuron wyznacza odległość (będącą miarą dystansu między aktualnym wektorem wejściowym i centrum reprezentowanym przez zestaw wag neuronu), która jest modulowana przez wartość progową. Wartość progowa jest maksymalnym odchyleniem, powyżej którego odległość uważana jest za tak dużą, że sygnał wyjściowy neuronu przyjmuje wartości bardzo bliskie zera. Zastosowanie funkcji radialnych i wartości progowej powoduje, że sieć RBF tworzy lokalne obszary wokół klastrów danych, dzięki czemu możliwe jest uzyskanie odpowiedzi stwierdzającej brak przynależności próbki do zdefiniowanych klas.

Dobór liczby neuronów warstwy ukrytej w sieciach radialnych zależy od przyjętego błędu. Neurony są dodawane iteracyjnie, 1 neuron w jednej iteracji, aż do osiągnięcia błędu średniokwadratowego podanego przez użytkownika lub osiągnięcia maksymalnej liczby neuronów. Maksymalna liczba neuronów równa jest liczbie wektorów wejściowych.

W badaniach zastosowano następujące wartości: maksymalna ilość neuronów 1000, maksymalny błąd 0.0001, wartości progowe 0.5, 1.0. W tabeli 3 zestawiono wartości globalnego współczynnika rozpoznania. W tabeli 4 zestawiono macierze pomyłek. Wartości powinny być odczytywane następująco (patrz. Tab. 4, RBF_0.5 zbiór testowy): 46 próbek fotopunktów (f) zostało zaklasyfikowanych błędnie i uzyskało klasę nie-fotopunkt (n-f),

Tab. 3. Globalny współczynnik rozpoznania dla sieci RBF i dwóch wartości progowych.

Wartość progowa	Globalny współczynnik rozpoznania	
	Zbiór uczący	Zbiór testowy
0.5	1.000	0.964
1.0	1.000	0.956

Tab. 4. Macierz pomyłek rozpoznania fotopunktów dla sieci RBF.

		RBF_0.5			
		Zbiór uczący		Zbiór testowy	
		f	n-f	f	n-f
Macierz pomyłek	f	409	0	3473	158
	n-f	0	223	46	2011
		RBF_1.0			
		f	n-f	f	n-f
		f	n-f	f	n-f
Macierz pomyłek	f	409	0	3587	44
	n-f	0	223	204	1853

f – fotopunkt

n-f – nie-fotopunkt

3473 zaś zostało zaklasyfikowanych prawidłowo jako fotopunkt (f). Wśród próbek nie-fotopunkt 158 zostało przyporządkowane do klasy fotopunkt, 2011 zaś uzyskało prawidłową klasyfikację.

5.2. Wyniki rozpoznania

Na rysunku 5 przedstawiono przykładowe rozpoznanie fotopunktów siecią RP_19_20_2_2.

Jak widać, wśród obszarów rozpoznanych jest kilka, które nie zawierają obrazu fotopunktu (otoczone białym prostokątem). Obszary te zostaną wyeliminowane w następnym etapie przy dokładnym pomiarze fotopunktu na przykład metodą wagowanego środka ciężkości lub LSM.



Rys. 5. Przykład rozpoznania fotopunktów na stereogramie zdjęć zbieżnych siecią RP_19_20_2_2.

6. WNIOSKI

Podsumowując zaprezentowane badania można wyciągnąć następujące wnioski:

- 1) Weryfikacja reprezentacji w postaci profilu średniej wartości kierunku gradientu z agregacją kąta 20° zakończyła się pozytywnym rezultatem dla rozpoznania fotopunktów oraz negatywnym dla rozpoznania markerów. W przypadku markerów jest ona mało charakterystyczna i nie pozwala odróżnić klasy „marker” od klasy „nie-marker”.
- 2) Sieć MLP z wsteczną propagacją błędów daje pozytywne wyniki dla rozpoznania fotopunktów i może być z powodzeniem wykorzystywana do takich celów. Sieć BP z dwoma warstwami ukrytymi uczona metodą *Resilient Backpropagation* o strukturze 19-20-2-2 rozpoznaje fotopunkty w zbiorze testowym na poziomie 99.7%.
- 3) Sieć typu RBF wymaga dalszych testów. Wstępne badania dla rozpoznania fotopunktów dają pozytywne rezultaty na poziomie 96.4% dla zbioru testowego przy współczynniku progowym 0.5. Przy wzroście współczynnika obserwuje się spadek wartości globalnego współczynnika rozpoznania oraz negatywne zjawisko jakim jest przyporządkowanie większej liczby próbek fotopunkt do klasy nie-fotopunkt

(patrz. Tab. 4, wartość 204). Zdecydowanie bardziej korzystna jest sytuacja odwrotna, gdy sieć zaklasyfikuje większą ilość próbek nie-fotopunkt do klasy fotopunkt, gdyż próbki te w dalszym etapie, zostaną wyeliminowane metodą np. wagowanego środka ciężkości lub LSM. Badania powinny być prowadzone przy współczynniku mniejszym niż 0.5.

- 4) Testy dotyczące wykorzystania sieci RBF do celów klasyfikacji markerów powinny zostać podjęte po uprzednim dobraniu charakterystycznej dla markerów reprezentacji.

7. LITERATURA

Czechowicz A., Mikrut Z., 2007a. Wykorzystanie sieci Kohonena do selekcji podobrazów na potrzeby dopasowania zdjęć lotniczych. *Automatyka: półrocznik Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie*, Kraków.

Czechowicz A., Mikrut Z., 2007b. Selekcja podobrazów dla potrzeb dopasowywania zdjęć lotniczych oparta na histogramach gradientu i sieci neuronowej. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol.17a, Kraków.

Parker J.R., 1996. *Algorithms for Image Processing and Computer Vision*, Wiley

Tokarczyk R., Huppert M., Koprowski R., Mazur T., Mierzwa W., Mikrut S., Wróbel Z., 2007. *Automatyzacja pomiaru na obrazach cyfrowych w systemie fotogrametrycznym do badania wad postawy*. Praca zbiorowa pod redakcją Reginy Tokarczyk, Uczelniane Wydawnictwa Naukowo-Techniczne AGH, Kraków.

DETECTION OF MEASUREMENT POINTS IN A 3D BODY POSITIONING SYSTEM BY MEANS OF ARTIFICIAL INTELLIGENCE

KEY WORDS: Photogrammetry, Body Positioning, Neural Networks, Multi Layer Perceptron, Error Back-Propagation, Radial Basis Function Networks

SUMMARY: A digital photogrammetric system for making measurements of the human body for the purpose of studying faulty posture is designed to determine the three-dimensional location of selected points in the human body. It requires the measurement of three groups of points on digital images, points referred to in this paper's title as measurement points, i.e. control points, markers indicated on the patient's body and pupils of the eyes. Control points are black and white signals permitting the correct orientation in space of a model created from the images. The markers are balls of polystyrene foam of 4-5 mm diameter, placed on the body, which indicate selected elements of the human skeleton. This paper describes the utilisation of neural networks to locate control points and markers. The aim of the networks is to classify consecutive fragments of an image as containing control points, containing markers or not containing any of these features. The research covered evaluation of the possibility of conducting this classification using Multi Layer Perceptron Networks with back propagation of errors as well as with Radial Basis Function Networks. The usefulness

of a representation based on information about the distribution of gradient value and direction for the purpose of the detection of measurement points has been verified. This representation comes from earlier research on the selection of subimages for the purpose of matching the aerial pictures

mgr inż. Anna Czechowicz
an.czechowicz@gmail.com
telefon: +48 12 6173993
fax: +48 12 6173993

dr hab. inż. Regina Tokarczyk
tokarcz@agh.edu.pl
telefon: +48 12 6172288
fax: +48 12 6173993

