

**AUTOMATYCZNA ORIENTACJA OBRAZÓW CYFROWYCH
NA PRZYKŁADZIE WYBRANEJ GEOMETRII SIECI ZDJĘĆ**

**AUTOMATIC ORIENTATION OF DIGITAL IMAGES USING THE EXAMPLE
OF SELECTED GEOMETRY OF A NETWORK OF IMAGES**

Dorota Zawieska

Zakład Fotogrametrii, Teledetekcji i SIP, Wydział Geodezji i Kartografii
Politechnika Warszawska

SŁOWA KLUCZOWE: operatory detekcji narożników, dopasowanie zdjęć, modelowanie 3D

STRESZCZENIE: Celem niniejszego referatu jest przeanalizowanie działania wybranych algorytmów, które automatycznie obliczą elementy orientacji zewnętrznej sieci zdjęć a następnie wyznaczą współrzędne chmury punktów 3D, opisujących model badanego obiektu. Do obliczeń wykorzystano autorski program, realizujący kolejne etapy tworzenia modelu 3D. Pierwsza faza obejmowała wyróżnienie na poszczególnych zdjęciach elementów charakterystycznych, gdzie wykorzystane zostały operatory detekcji narożników SIFT i SUSAN. Następnym krokiem było połączenie punktów homologicznych na sąsiednich zdjęciach. Sposób realizacji tego kroku jest determinowany przez wybór typu operatora. Operator SIFT posiada dedykowany mechanizm tworzenia par, podczas gdy operator SUSAN wymaga utworzenia odrębnych metod. Do dopasowania punktów wykorzystano metodę Area Base Matching, zmodyfikowaną na potrzeby modelowania 3D. Na podstawie tak zebranych danych, kolejnym etapem jest wyznaczenie współrzędnych 3D chmury punktów mierzonego obiektu. W niniejszym referacie przedstawiono dwa rozwiązania. Jedno z nich realizuje dopasowywanie zdjęć parami, korzystając z macierzy podstawowej a drugie trójkami, wykorzystując rachunek tensorowy. W praktyce, pierwsze rozwiązanie wyznaczające punkty modelu okazało się mniej stabilne numerycznie, co może prowadzić do znacznych błędów w modelu końcowym. Drugie rozwiązanie jest trudniejsze do wykorzystania, gdyż wymaga odnalezienia odpowiadających sobie punktów na co najmniej trzech zdjęciach. Eksperymenty przeprowadzono na wybranych obiektach bliskiego zasięgu, z odpowiednio wykonaną geometrią zdjęć, tworzących pierścieni (okrąg) wokół mierzonego obiektu.

1. WPROWADZENIE

Automatyczna rekonstrukcja modeli trójwymiarowych (3D) opracowanych na podstawie obrazów cyfrowych jest od długiego czasu przedmiotem prac badawczych w dziedzinie fotogrametrii bliskiego zasięgu i widzeniu komputerowym. W zależności od zapotrzebowania generowane są modele o różnym stopniu dokładności. W fotogrametrii bliskiego zasięgu, wymagane jest generowanie modeli o wysokiej dokładności. W literaturze prezentowanych jest wiele metod i systemów, o różnym stopniu automatyzacji, które są wykorzystywane do rekonstrukcji modeli 3D lub w widzeniu komputerowym (Luhman, et

al., 2006., Hartley, Zisserman, 2004). Inne podejście do tego zagadnienia prezentują fotogrametry a nieco inne specjaliści z dziedziny robotyki czy widzenia komputerowego. Niejednokrotnie są to te same zagadnienia, ale wykorzystywana jest inna terminologia. Integracja obu dziedzin, wykorzystanie wspólnych algorytmów i metod może korzystnie wpłynąć na rozwój i tworzenie nowych rozwiązań z zakresu automatyzacji pomiarów.

Celem niniejszego referatu jest przedstawienie teoretycznych podstaw i weryfikacja opracowanej aplikacji do automatycznego tworzenia modeli 3D wybranych obiektów bliskiego zasięgu w oparciu o rachunek tensorowy.

2. WYKRYWANIE NAROŻNIKÓW

W literaturze opublikowanych jest wiele algorytmów, które mogą być wykorzystywane do wykrywania punktów charakterystycznych tzw. narożników na zdjęciach cyfrowych. Weryfikując ich działanie dla wybranych operatorów (Zawieska, 2010) wybrano te, które wydają się najbardziej optymalne dla przyjętych w artykule rozwiązań rekonstrukcji kształtu modelowanych powierzchni. Przy modelowaniu rozpatrywano dwa detektory narożników SUSAN (Smith, Brady 1997) i SIFT (Lowe 2004). Oprócz różnic w technologii znajdowania potencjalnych narożników wymuszają one zróżnicowane podejście do zadania dopasowywania par punktów na zdjęciach. Algorytm SIFT (*Scale Invariant Feature Transform. ang*) dokonuje opisu punktów cechami, które są niezmiennikami obrotu, i dokonuje porównania porównując te cechy. Algorytm SUSAN (*Smallest Univalued Segment Assimilating Nucleus. ang*) nie posiada wbudowanego mechanizmu i z tego powodu należy zastosować metodę uniwersalną. W opisywanym przypadku zastosowano algorytm ABM (*Area Base Matching. ang*), (Lang, Förstner, 1998). Szczegóły algorytmu są podane w opisie detektora SUSAN.

2.1. Algorytm SUSAN

Algorytm działa na obrazach w skali szarości i jest parametryzowany przy pomocy dwóch progów t i g . Dla każdego piksela $r_0=(x,y)$ wyznaczana jest okrągła maska, o promieniu t , a następnie stosowane jest równanie (1)

$$c(r, r_0) = e^{\left(\frac{-I(r)-I(r_0)}{t}\right)^6} \quad (1)$$

które po wstawieniu do formuły

$$n(r_0) = \sum_r c(r, r_0) \quad (2)$$


pozwalające na określenie liczby punktów w otoczeniu o promieniu t o nasyceniu $I(r)$ zbliżonym do nasycenia w punkcie środkowym $I(r_0)$.

Jeżeli w otoczeniu punktu r_0 istnieje mało punktów o zbliżonym natężeniu, to można uznać go za narożnik. Funkcję decyzyjną, określającą, czy punkt jest narożnikiem można zdefiniować jako

$$C(r_0) = \begin{cases} g - n(r_0), & n(r_0) < g \\ 0, & n(r_0) \geq g \end{cases} \quad (3)$$

Próg g można szacować na podstawie maksymalnej wielkości funkcji $n(r_0)$, w dziedzinie obrazu wejściowego. Ponieważ wyliczone wartości $C(r_0)$ mogą generować wiele

niezerowych wystąpień, odpowiadających w rzeczywistości temu samemu narożnikowi, można wyzerować te, które nie będąc zerowe przy wyznaczaniu $n(r_0)$ znajdują się dalej od środka ciężkości tworzonego przez nie kształtu (Rys. 1).



Rys. 1. Lokalizacja narożników przy pomocy algorytmu SUSAN

Do dopasowania punktów wykorzystano metodę ABM (Campbell N. A., Wu X. 2008, Gang Hong, Yun Zhang 2004). Metoda bada otoczenie porównywanych punktów i wybiera do dopasowania te punkty, których otoczenie jest do siebie najbardziej zbliżone. Badanie otoczenia jest ograniczone do obszaru wyznaczonego ramką o środku zdefiniowanym przez położenie punktu. Dopasowanie jest określone na podstawie korelacji krzyżowej. Współczynnik korelacji między ramką referencyjną na pierwszym ze zdjęć i ramką wyznaczaną przez badany punkt na drugim obrazie, obliczany jest na podstawie następującego równania:

$$\rho = \frac{\sum_{\xi=1}^m \sum_{\eta=1}^n (f(\xi, \eta) - \mu_1) * (g(\xi, \eta) - \mu_2)}{\sqrt{\sum_{\xi=1}^m \sum_{\eta=1}^n (f(\xi, \eta) - \mu_1)^2 * \sum_{\xi=1}^m \sum_{\eta=1}^n (g(\xi, \eta) - \mu_2)^2}} \quad (4)$$

Gdzie $f(\xi, \eta)$ jest wartością intensywności punktu w oknie referencyjnym, μ_1 średni poziom intensywności w oknie referencyjnym, $g(\xi, \eta)$ to wartość intensywności punktu w przeszukiwanym oknie, μ_2 średni poziom intensywności w przeszukiwanym oknie m, n wymiary okna referencyjnego. Współczynnik korelacji przyjmuje wartości z przedziału $[-1, 1]$.

2.2. Algorytm SIFT

Algorytm składa się z czterech etapów, wyszukania potencjalnie interesujących punktów, poprzez przeszukanie obrazów w różnych skalach w poszukiwaniu niezmienników; wyznaczenia punktów kluczowych, obieranych na podstawie pomiaru ich stabilności; Do lokalizacji kluczowego punktu przypisywana jest jedna lub więcej orientacji określana na podstawie skierowania lokalnego gradientu obrazu. Na tej podstawie tworzony jest opis punktu kluczowego. Algorytm rozpatruje obraz w kilku skalach poprzez wprowadzenie do oryginalnego obrazu $I(x, y)$ modyfikacji w postaci rozkładu Gaussa.

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (5)$$

co daje obraz postaci:

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y) \quad (6)$$

Analizując obrazy sąsiadujące między sobą względem skali można wyliczyć różnicę między obrazami

$$D(x, y, \sigma) = (G(x, y, k\sigma) - G(x, y, \sigma)) * I(x, y) = L(x, y, k\sigma) - L(x, y, \sigma) \quad (7)$$

Algorytm wyszukuje lokalne minima funkcji $D(x, y, \sigma)$ w otoczeniu 8 punktów z analizowanego obrazu i 9 z obrazów leżących poniżej i powyżej na skali.

Dla odnalezionych ekstremów wyliczana jest funkcja


$$D(x) = D + \frac{\partial D^T}{\partial x} x + \frac{1}{2} x^T \frac{\partial^2 D}{\partial x^2} x \quad (8)$$

w której funkcja D i jej pochodne wyliczane są dla badanego punktu, a $x=(x, y, \sigma)^T$ jest przesunięciem względem tego punktu.

Położenie ekstremum jest wyliczane jako

$$\hat{x} = \frac{\partial^2 D^{-1}}{\partial x^2} \frac{\partial D}{\partial x} \quad (9)$$

Jeżeli wartość funkcji D w punkcie ekstremalnym nie przekracza zadanego progu, to taki punkt jest eliminowany z dalszych obliczeń.




Rys. 2. Lokalizacja narożników przy pomocy algorytmu SIFT. Na zdjęciu zaznaczono punkty kluczowe wraz z charakterystycznymi je wektorami

W celu jednoznacznego określenia punktu wyznacza się jego cechy niezmiennicze. Będą one podstawą do porównywania punktów na różnych zdjęciach (Rys. 2).

2.3. Porównanie algorytmów

Rozpatrując problem dopasowywania zdjęć w celu budowy modelu 3D należy rozpatrzyć takie cechy operatora detekcji i przypisanej mu techniki dopasowywania punktów jak szybkość działania, jakość dopasowanych punktów i ich lokalizacja. Analizując jakość (dopasowywania lub łączenia odpowiadających punktów) punktów, to wyniki osiągnięte przez algorytm SIFT są lepsze niż uzyskane poprzez połączenie detektora SUSAN i algorytmu ABM. Jednak ten aspekt algorytmu nie musi być decydujący. Wykorzystując przy dopasowywaniu techniki oparte na próbkowaniu, takie jak RANSAC (Fichler, Bolles 1981) wymagamy, aby istniała pewna ograniczona liczba poprawnie dopasowanych punktów.



Rys. 3 Dopasowanie punktów metodą SIFT

Algorytm SUSAN działa szybciej. Przy budowie pełnego modelu 3D, który składa się z kilkudziesięciu zdjęć porównywanych parami nie pozostaje to bez znaczenia. Jednak najważniejszą cechą jest położenie lokalizowanych punktów. Oba algorytmy lokalizują część punktów poza rozpoznawanym modelem.

Wyniki dopasowania pokazane na rysunku 3 wskazują, że problem ten jest bardziej dotkliwy w wypadku algorytmu SIFT. Jednak przynajmniej część takich punktów można wyeliminować poprzez analizę przesunięcia punktów na kolejnych zdjęciach (punkty te powinny zostać nieruchome). Większym problemem jest fakt, że znaczna część punktów rozpoznawanych przez SIFT nie jest rzeczywistym narożnikiem rozpoznawanego obiektu. W wypadku algorytmu SUSAN większość wykrytych punktów znajduje się na krawędziach bryły, które co prawda także nie są narożnikami, ale w lepszy sposób oddają geometrię bryły, niż ulokowane na jej powierzchni punkty wykryte przez algorytm SIFT.

3. DOPASOWYWANIE ZDJĘĆ

Przedstawione zostaną dwie metody dopasowywania zdjęć. Pierwsza bazuje na macierzy fundamentalnej i dopasowuje pary zdjęć, druga opiera się na tensorze trójogniskowym i operuje na trójkach zdjęć.

3.1. Macierz fundamentalna (Fundamental Matrix .ang)

Dopasowywanie zdjęć przy pomocy macierzy fundamentalnej bazuje na założeniu, że punkty obrazujące na zdjęciach i punkt rzeczywisty tworzą razem z obrazowanym punktem trójkąt wyznaczający wspólną płaszczyznę. Dla macierzy fundamentalnej F relacja między współrzędnymi punktów na zdjęciach dana jest wzorem

$$x'^T F x = 0 \quad (10)$$

Macierz F jest macierzą osobliwą, rzędu 2 i posiada siedem stopni swobody. Można ją wyznaczyć znając wzajemne położenie na obu zdjęciach przynajmniej 7 punktów. Definiując odpowiadające sobie punkty $x = (x, y, 1)$ i $x' = (x', y', 1)$ i korzystając z wektorowej reprezentacji macierzy f można zapisać warunek jako

$$(x'x, x'y, x', y'x, y'y, y', x, y, 1)^T f = 0 \quad (11)$$

Wtedy znając n odpowiadających sobie punktów definiujemy równanie

$$Af = \begin{bmatrix} x'_1 x_1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ x'_n x_n & \cdots & 1 \end{bmatrix} f = 0 \quad (12)$$

Z powyższego rozwiązania (12) możemy uzyskać macierz f korzystając z rozkładu SVD (Singular Value Decomposition. ang). Jednakże, szczególnie jeżeli użyte do obliczeń punkty znajdują się w przybliżeniu na tej samej powierzchni epipolarnej, uzyskane rozwiązanie może nie zgadzać się z teoretycznymi założeniami odnośnie macierzy F . W zamian można zastosować metody oparte na tensorach.

3.2. Tensor trójogniskowy (Trifocal Tensor. ang)

Tensor trójogniskowy spełnia w przypadku trzech zdjęć identyczną rolę, jak macierz fundamentalna dla dwóch zdjęć. Opisuje geometryczne relacje między trzema zdjęciami. Tensor jest jednoznacznie określony przez elementy orientacji wewnętrznej i zewnętrznej. Podobnie jak macierz fundamentalna może być obliczony na podstawie zbioru połączonych punktów. Tensor trójogniskowy jest definiowany przez trzy macierze T_1, T_2, T_3 . Zależność geometryczną między prostymi l, l', l'' pochodzącymi z trzech różnych zdjęć da się opisać jako

$$l^T = l'^T [T_1 T_2 T_3] l'' \quad (13)$$

Z tensora można uzyskać macierze fundamentalne dla par zdjęć, a także macierz opisującą elementy orientacji wewnętrznej (bez dystorsji).

Do obliczenia tensora na podstawie połączonych punktów można wykorzystać algorytm RANSAC (Random Sample Consensus. ang). Algorytm wybiera losową próbkę 6 elementową spośród trójek punktów i wylicza tensor. Następnie estymuje błąd dopasowania, porównując rozwiązanie z pozostałymi punktami i powtarza operacje dla kolejnych próbek losowych. Finalnie wybiera tensor o najmniejszym błędzie.

Do wyliczenia tensora na podstawie 6 punktów należy rozwiązać układy równań

$$\begin{bmatrix} 1 & 0 & 0 & 1 & x_5^{(i)} & x_6^{(i)} \\ 0 & 1 & 0 & 1 & y_5^{(i)} & y_6^{(i)} \\ 0 & 0 & 1 & 1 & w_5^{(i)} & w_6^{(i)} \end{bmatrix} = \begin{bmatrix} \alpha^{(i)} & 0 & 0 & \delta^{(i)} \\ 0 & \beta^{(i)} & 0 & \delta^{(i)} \\ 0 & 0 & \gamma^{(i)} & \delta^{(i)} \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 & 0 & 1 & X \\ 0 & 1 & 0 & 0 & 1 & Y \\ 0 & 0 & 1 & 0 & 1 & Z \\ 0 & 0 & 0 & 1 & 1 & W \end{bmatrix} \quad (14)$$

dla trzech obrazów $i=1,2,3$. Macierz po lewej stronie równania zawiera odpowiednio przeskalowane współrzędne sześciu punktów. Macierze po prawej zawierają odpowiednio parametry orientacji wewnętrznej dla trzech zdjęć i tensor postaci $(X, Y, Z, W)^T$.

3.3. Porównanie algorytmów

Porównując obydwa podejścia do modelowania można zauważyć, że model oparty na macierzy fundamentalnej jest prostszy w implementacji i mniej kosztowny obliczeniowo. Niestety jest także bardziej podatny na błędy numeryczne, szczególnie przy złym wyborze punktów służących do budowy modelu. Z kolei bardziej skomplikowany model oparty na tensorze trójogniskowym jest stabilniejszy numerycznie i porównanie jakości wygenerowanych modeli skłania do oparcia na nim właśnie strategii działania. Należy jednak zauważyć, że pociąga on za sobą konieczność istnienia dopasowywanego punktu na trzech kolejnych zdjęciach. To oznacza konieczność stosowania małego kąta obrotu przy tworzeniu serii zdjęć. W przeciwnym wypadku może dojść do sytuacji, gdy otrzymany zbiór


punktów będzie zbyt mały aby uzyskać poprawną wartość tensora, dobrze opisującą zależności pomiędzy kolejnymi zdjęciami. Zastosowanie małego kąta pociąga za sobą dwa niepożądane skutki. Pierwszym jest zwiększenie liczby przetwarzanych zdjęć co przekłada się bezpośrednio na czas potrzebny na wykonanie obliczeń. Drugi to zwiększony wpływ błędów w lokalizacji punktów na obliczenie współrzędnej Z. Weryfikację przyjętych rozwiązań zaprezentowano w dalszej części artykułu.

4. EKSPERYMENTALNE MODELOWANIE 3D

Analizując podstawy teoretyczne modelowania 3D, analizując różne rozwiązania publikowane w literaturze, opracowany został program, który weryfikuje proponowane rozwiązania. Dokonując wyboru określonych algorytmów wykrywania punktów charakterystycznych czy też dopasowywania zdjęć, podczas weryfikacji ich działania zostały praktycznie wyznaczone takie parametry, które pozwoliły na prawidłowe wyznaczenie kształtu badanych obiektów. Program działa wieloetapowo. Tworzenie modelu składa się z trzech etapów; pozyskanie punktów, dopasowanie ich na kolejnych zdjęciach, wyznaczenie tensora, kalibracja, generowanie chmury punktów 3D.

4.1. Wykrywanie punktów charakterystycznych

Wyznaczanie punktów charakterystycznych zostało oparte na algorytmie SUSAN (Rys.4). Proces odbywa się dwuetapowo. W pierwszym pozyskiwane są punkty przy standardowych parametrach dla tego algorytmu. Następnie program analizuje czy dla wykorzystywanego progu liczba wyznaczonych punktów nie jest zbyt mała. Jeśli tak jest, to próg jest zmniejszany a cały proces wykrywania punktów jest powtarzany. Po uzyskaniu listy punktów na kolejnych zdjęciach następuje ich dopasowanie z użyciem algorytmu ABM. Ze względu na obrót, współczynnik korelacji przyjmuje niższe wartości niż w przypadku zdjęć równoległych. Jego minimalna wartość została określona w szeregu testów, może być jednak definiowana każdorazowo dla kolejnego pomiaru.



Rys.4. Dopasowywanie opowiadających punktów na podstawie operatora SUSAN i tensora trójogniskowego

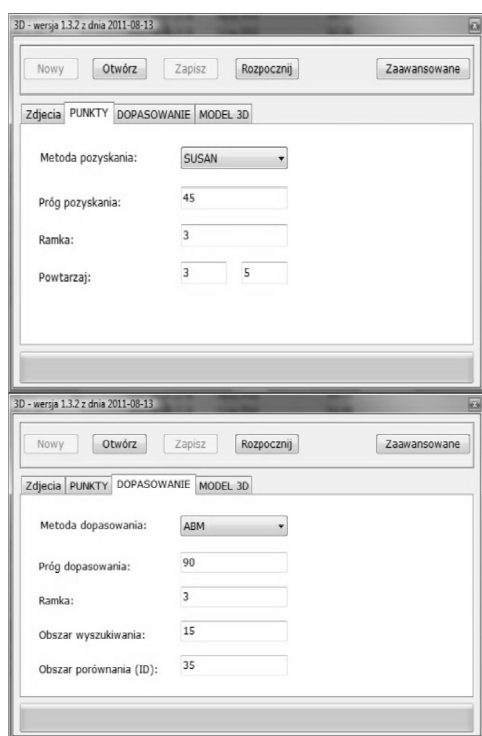
4.2. Wyznaczanie chmury punktów 3D

Po uzyskaniu listy dopasowanych na kolejnych trójkach zdjęć punktów, obliczane są wartości tensora, wyznaczana jest automatyczna kalibracja a następnie wyznaczana jest chmura punktów 3D opisująca kształt mierzonego obiektu. Aby zminimalizować ryzyko występowania błędów oraz uzyskać najlepsze przybliżenie tensora, do jego obliczania wykorzystywane są

punkty o najwyższych współczynnikach dopasowania, leżące w centralnej części obrazka. To ostatnie założenie zwiększa prawdopodobieństwo wykorzystania punktów leżących na modelowanym obiekcie a nie punktów tła itp. Jako proste kryterium określające czy punkt leży na obiekcie, przyjmuje się jego położenie w okręgu o promieniu równym 70% szerokości/wysokości obrazu i środkiem pokrywającym się ze środkiem zdjęcia .

4.3. Weryfikacja działania programu

Aby określić poprawność działania zarówno poszczególnych algorytmów oraz opracowanej aplikacji przeprowadzonych zostało szereg testów. Polegały one na wyznaczeniu modelu 3D przy różnych parametrach wejściowych dla poszczególnych algorytmów. Wykorzystano trzy testowe obiekty: dwudziestościan, kamienna bryła oraz fragment rzeźby (głowa). Obiekty umieszczono na obrotowej platformie a następnie wykonano serię zdjęć obracając ją o około 15 stopni przy kolejnych ekspozycjach. Przyjęty kąt zapewniał odpowiednie wspólne pokrycie analizowanego obszaru. Wszystkie zdjęcia wykonane zostały kamerą Hasselblad H4D 50 z obiektywem 80 mm – 50 Mpiksels (6132 × 8176 piksels), rozmiar matrycy 36.7 × 49.1 mm. Dodatkowo sprawdzono działanie aplikacji dla niepoprawnych danych. Oznaczało to pominięcie w serii zdjęć, kilku z nich, co przekładało się na zbyt duży kąt pomiędzy kolejnymi zdjęciami a tym samym zbyt małą liczbę dopasowanych punktów. Okno opracowanej aplikacji z możliwością ustawiania parametrów wejściowych przedstawiono na rysunku 5.



Metoda pozyskania: algorytm SUSAN lub Plessey/Harris/Próg pozyskania: próg poniżej którego punkty są odrzucane.

Ramka: obszar wokół wyszukiwanego punktu charakterystycznego.

Powtarzaj: funkcja, która określa liczbę wykrytych punktów dla danego progu. Możliwość powtórzenia obliczeń przy innych parametrach (pierwsza liczba – wielokrotność prób; druga – wartość progu).

Metoda dopasowania: ABM lub ImageDistance/ABM (ID+ABM)

Próg dopasowania: minimalna wartość współczynnika korelacji dla ABM


Ramka: rozmiar ramki

Obszar wyszukiwania: obszar wokół punktu, w którym wyszukiwana jest ramka


Obszar porównania (ID): rozmiar ramki dla algorytmu ID

Rys. 5. Parametry wejściowe programu do wykrywania oraz dopasowywania punktów

W przypadku dwudziestościanu oraz kamienia, jeśli seria zdjęć była kompletna, uzyskany model odpowiadał kształtem badanemu obiektowi (Rys. 6). Jeśli jednak pominięto niektóre zdjęcia lub nie udało się uzyskać odpowiedniej liczby dopasowanych punktów, niemożliwe było zbudowanie prawidłowego modelu. Natomiast w przypadku modelu przedstawiającego fragment rzeźby, nie udało się uzyskać odpowiedniej liczby punktów już na etapie działania algorytmu SUSAN. Wiązało się to z brakiem naturalnej tekstury na obiekcie – na gładkich powierzchniach bez załamań, o jednolitym kolorze i odcieniu, nie udało się wykryć wystarczająco wielu punktów charakterystycznych (Rys. 7).



Rys. 6. Zdjęcia wybranych obiektów i uzyskana chmura punktów 3D



Rys. 7. Obiekty dla których nie udało się zbudować modelu z powodu braku punktów dla dopasowania (po lewej – fragment rzeźby) lub błędnej serii zdjęć (po prawej)

Aby sprawdzić dokładność uzyskanych wyników wygenerowano model 3D dwudziestościanu w programie PhotoModeler Scanner (PMS). Następnie porównano z wynikami uzyskanymi z opracowanej aplikacji. Uzyskany model testowy przeskalowano do modelu z PMS i porównano długości trzech boków ściany modelu, których rzeczywista wartość wynosi 15 cm. Uzyskano następujące wyniki: 15,00 cm; 15,46 cm, 14,51 cm. W dalszej części badań planowana jest rozbudowana analiza dokładności uzyskanych wyników.

5. PODSUMOWANIE I WNIOSKI

W niniejszym artykule przedstawiono teoretyczne podstawy algorytmu SUSAN i SIFT oraz zweryfikowano praktyczne ich działanie. Następnie przeanalizowano proces dopasowywania zdjęć na podstawie wykorzystania macierzy fundamentalnej i rachunku tensorowego. Przeprowadzając szereg eksperymentów opracowano aplikację do automatycznego modelowania 3D z wykorzystaniem algorytmów SUSAN w połączeniu z algorytmem ABM oraz wykorzystaniem rachunku tensorowego. Weryfikacja działania programu wykazała, że przyjęte założenia są prawidłowe i algorytmy działają poprawnie, przy założeniu, że zdjęcia zostały wykonane wokół obiektu z odpowiednim wspólnym pokryciem dla trzech kolejnych zdjęć. W testach wykorzystano wariant, kiedy stanowisko aparatu jest stabilne a obiekt obracany jest na platformie. Przedstawione eksperymenty stanowią fragment badań wykonanych w ramach realizacji grantu habilitacyjnego nt. „Wieloobrazowe dopasowanie zdjęć bliskiego zasięgu dla automatycznej rekonstrukcji fotorealistycznych modeli 3D obiektów”.

6. LITERATURA

- Campbell N. A., Wu X., 2008. Gradient Cross Correlation For Sub-Pixel Matching. http://www.isprs.org/proceedings/XXXVII/congress/7_pdf/6_WG-VII-6/03.pdf
- M. Fichler and R. Bolles., 1981. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Graphics and Image Processing* 24, 6.
- Gang Hong, Yun Zhang, 2004. The Image Registration Technique For High Resolution Remote Sensing Image In Hill Area. www.isprs.org/proceedings/XXXVI/8-W27/hong_zhang_paper.pdf
- Richard Hartley and Andrew Zisserman., 2004. Multi View Geometry in Computer Vision. *Second Edition. Cambridge University Press.*
- Lang F, Förstner W, 1998. Matching Techniques. *Third Course in Digital Photogrammetry*, Chapter 5, 41 page, Bonn.
- David G. Lowe., 2004. Distinctive image features from scale-invariant key points. *International Journal of Computer Vision*, 60, 2, pp. 91–110.
- Luhmann T., Robson S., Kyle S. i Karley I., 2006. Close Range Photogrammetry – Principles, techniques and applications. Dunbeath: Whittles Publishing.
- S. M. Smith and M. Brady., 1997. SUSAN – A New Approach to Low Level Image Processing. *International Journal of Computer Vision*, Vol. 23(1), pp. 45–78.
- Zawieska D., 2010. Wybrane operatory w automatyzacji dopasowywania obrazów cyfrowych bliskiego zasięgu. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. XXI., 2010, str. 455–465.

**AUTOMATIC ORIENTATION OF DIGITAL IMAGES USING THE EXAMPLE
OF SELECTED GEOMETRY OF A NETWORK OF IMAGES**

KEY WORDS: operators of corner detection, image matching, 3D modelling

SUMMARY: The objective of this paper is to analyse operations of selected algorithms, which will automatically compute elements of external orientation of a network of photographs and then, they will determine co-ordinates of a 3D cloud of points, which describe a model of the analysed object. The author's software tool has been utilised for calculations; it performs successive stages of the 3D model generation: detection of characteristic points, point matching on successive photographs, determination of a tensor, calibration and 3D point cloud generation. A series of experiments have been performed in order to evaluate selection of the optimum solution. The first stage included distinguishing of characteristic elements on particular photographs; corner detection operators, SIFT and SUSAN were applied for that stage. The next step concerned connection of homological points on neighbouring photographs. The method of implementation of that step is determined by selection of the operator type. The SIFT operator has the dedicated mechanism of pair creation, whilst the SUSAN operator requires creation of separate methods. The Area Base Matching method, modified according to the demands of 3D modelling, was used for the needs of point matching. This method investigates correlation of the background within the neighbourhood of characteristic points and uses the results of that investigations to match the photographs. Basing on data collected this way, the next stage aims at determination of 3D co-ordinates of the cloud of points of the measured object. Two solutions have been presented in this paper. One of them allows for matching photographs in pairs, using the fundamental matrix; the second solution allows for threesome matching of photographs, using the tensor calculus. In practice, the first solution, which determines the model points, turned to be less numerically stable, what may lead to considerable errors of the final model. The second solution is more difficult to use, since it requires that corresponding points are found in at least three photographs. Experiments were performed for selected close range objects, with the appropriate specified geometry of photographs, which created a ring around the measured object.

Dorota Zawieska
e-mail: dorotaz8@wp.pl
telefon: 22 2347694