

Przemysław Korohoda*

Efektywność wykrywania punktów charakterystycznych w obrazach stereoskopowych za pomocą wartości własnych hesjanu**

1. Wprowadzenie

Algorytm SIFT (*Scale Invariant Feature Transform*), którego kolejne etapy rozwoju można prześledzić w publikacjach [11] i [2], a który został sformułowany w pracy [12], stanowi efektywne i bardzo interesujące rozwiązanie problemu wyszukiwania odpowiedników, np. w problematyce dopasowania stereopar [6], komponowania obrazów panoramicznych [3] czy dopasowywania obrazów medycznych [4]. Metoda przedstawiona w [12] stała się przedmiotem dalszych prac. Przeprowadzono badania porównawcze lokalnych deskryptorów [14], zwiększono wymiarowość przestrzeni [4], wprowadzono analizę PCA (*Principal Component Analysis*) oraz rozbudowano koncepcję wykorzystania histogramów [8]. W [10] zwrócono uwagę na fakt, iż sugerowana w [12] metoda selekcji punktów charakterystycznych, bazująca na proporcji wartościach własnych macierzy hesjanu, w wyniku dyskretyzacji dziedziny obrazu może powodować podejmowanie nieprawidłowych decyzji, zależnie od wyboru metody wyznaczania aproksymacji macierzy hesjanu. Zaproponowane w [10] nowe kryterium, bazujące na różnicy wartości własnych hesjanu, dawało jednakowe wyniki niezależnie od wybranej metody. Dla potwierdzenia wniosków zawartych w [10], a także w celu pozyskania liczbowych danych porównawczych, opracowano eksperyment obliczeniowy, wykorzystujący skalibrowaną parę obrazów stereoskopowych pochodzenia naturalnego [6, 9]. W kolejnych rozdziałach zostanie przedstawiony przeprowadzony eksperyment wraz z otrzymanymi wynikami. Wszystkie przedstawione obliczenia zrealizowano z wykorzystaniem pakietu MATLAB [16, 17].

* Katedra Elektroniki, Akademia Górniczo-Hutnicza w Krakowie

** Praca wykonana w ramach prac statutowych AGH, nr 11.11.120.766

2. Opis eksperymentu

2.1. Uzasadnienie zastosowanej procedury

Istota algorytmu SIFT polega na:

- 1) utworzeniu dla danego obrazu zbioru obrazów reprezentujących jego treść w różnych skalach, co uzyskuje się poprzez filtrację operatorem Gaussa [7, 16] ze stopniowo zwiększonym rozmyciem obrazu;
- 2) wyznaczeniu różnic między kolejnymi reprezentacjami, oznaczonymi jako obrazy DoG (*Difference of Gaussian*);
- 3) wstępnym wyznaczeniu lokalnych ekstremów w obrazach DoG, na podstawie zawartości kostki $3 \times 3 \times 3$ -pikselowej otaczającej dane ekstremum w ramach danego DoG oraz w dwóch sąsiednich obrazach DoG;
- 4) odrzuceniu ekstremów, które nie wyróżniają się dostatecznie z otoczenia – np. gdy leżą one na krawędzi – pozostawione punkty tworzą zbiór punktów charakterystycznych danego obrazu;
- 5) określeniu orientacji punktów charakterystycznych z wykorzystaniem operatorów gradientowych;
- 6) wyznaczeniu wektorów parametrów opisujących lokalne cechy punktów charakterystycznych, tzw. lokalnych deskryptorów, stanowiących podstawę do wyznaczania odpowiedników w różnych obrazach.

Opisywane rozważania dotyczą punktu 4, zatem projektując eksperyment, należało skoncentrować się na zagadnieniu wyznaczania lokalnych ekstremów, dla których obie krzywizny kierunkowe nie różnią się nadmiernie, co można zbadać, porównując wartości własne hesjanu, wyznaczonego w obszarze bloku 3×3 pikseli. W pełnym algorytmie SIFT obliczenia punktu 3 prowadzone są na obrazach DoG, jednak na potrzeby badania wybranego elementu algorytmu uznano, iż celowe jest posłużenie się obrazami, przygotowanymi zgodnie z opisem przedstawionym poniżej.


2.2. Przygotowanie danych

W roli materiału eksperymentalnego wykorzystano skalibrowaną parę obrazów zarejestrowanych za pomocą dwóch kamer w układzie kanonicznym [6, 10]. W celu stworzenia warunków zbliżonych do algorytmu SIFT [12] dla każdego z obrazów = lewego i prawego – utworzono czteropoziomą piramidę Gaussa [1, 6, 7], bazując na maskach o następujących parametrach:

- a) $\delta_{5 \times 5} = 0,6$;
- b) $\delta_{7 \times 7} = 0,8$;
- c) $\delta_{9 \times 9} = 1,1$;
- d) $\delta_{11 \times 11} = 1,5$.

W dolnym indeksie podano rozmiar maski w pikselach, natomiast wartość odchylenia standardowego δ określa kształt dwuwymiarowej funkcji Gaussa generującej maskę. Na rysunku 1 przedstawiono zastosowane maski. Zastosowana filtracja ma na celu zmniejszenie niekorzystnego wpływu szumu oraz utworzenie zbioru obrazów o tej samej zawartości przy

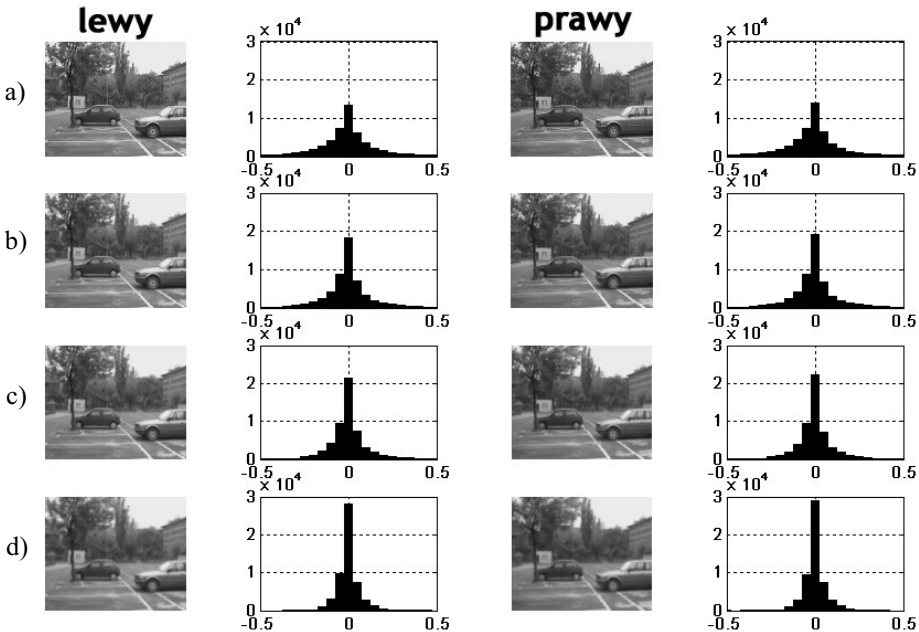
różnych poziomach rozdzielczości. Uśredniający efekt filtracji powoduje, że dla większej maski otrzymuje się obraz o tej samej rozdzielczości w pikselach traktowanej jako gęstość próbkowania obrazu, jednak mniejszej rozdzielczości z punktu widzenia zróżnicowania wartości pikseli.



Rys. 1. Maski zastosowanych filtrów gaussowskich dla odpowiednich wartości odchylenia standardowego (w indeksie podano rozmiary maski):


a) $\delta_{5 \times 5} = 0,6$; b) $\delta_{7 \times 7} = 0,8$; c) $\delta_{9 \times 9} = 1,1$; d) $\delta_{11 \times 11} = 1,5$

Na rysunku 2 pokazano otrzymane zbiory obrazów o rozmiarach w pikselach: 210×260 . Efekt coraz silniejszej filtracji dla kolejnych poziomów nie jest wyraźnie widoczny dla obserwatora, jednak w sposób istotny wpływa na efekty obliczeń, co uwidoczniło za pomocą filtracji laplasjanem [1, 7, 15], podkreślającej lokalne zmienności w wartościach pikseli.



Rys. 2. Kolejne poziomy – a, b, c, d, zgodnie z rysunkiem 1 – piramidy gaussowskiej dla badanej stereopary (obrazy: lewy i prawy). Na prawo od każdego obrazu pokazano histogram otrzymany w wyniku filtracji tego obrazu filtracji 8-punktowym laplasjanem [1, 7, 15], umożliwiający ocenę narastającego wygładzania obrazu, wynikającego z uśredniającej filtracji gaussowskiej maskami według rysunku 1

Na rysunku 3 pokazano dla porównania obrazy stereopary po filtracji w wersji a oraz ten sam obraz po filtracji d z rysunku 2. Istotą kolejnych filtracji jest nieznaczne zmniejszenie rozdzielczości przy zachowaniu najważniejszych detali. Zatem ocena wizualna powinna wykazywać jak najmniejsze różnice, podczas gdy wprowadzane zmiany powinny się ujawnić w trakcie dalszych obliczeń komputerowych, w tym przypadku reprezentowanych przez zastosowanie operatora laplasjanu.



Rys. 3. Badana stereopara po filtracji Gaussa typu a oraz d (patrz rys. 1 i 2) w powiększeniu uwidaczniającym różnice

2.3. Opis porównywanych metod

Macierz hesjanu [1, 7, 10, 12] zawiera pochodne cząstkowe drugiego rzędu

$$\mathbf{H} = \begin{bmatrix} f_{xx} & f_{xy} \\ f_{xy} & f_{yy} \end{bmatrix} \quad (1)$$

Ślad (Tr) i wyznacznik (Det) macierzy \mathbf{H} mogą być wykorzystane do wyznaczenia sumy i iloczynu jej wartości własnych wykorzystanych w dalszych obliczeniach [10, 12]:

$$\begin{aligned}\text{Tr}(\mathbf{H}) &= f_{xx} + f_{yy} = \lambda_1 + \lambda_2 \\ \text{Det}(\mathbf{H}) &= f_{xx} \cdot f_{yy} - (f_{xy})^2 = \lambda_1 \cdot \lambda_2\end{aligned}\quad (2)$$

W praktyce wyliczenie wartości odpowiednich pochodnych cząstkowych prowadzi się do zastosowania odpowiednich masek i filtracji liniowej. Jak wykazano w [10], możliwe są dwa podstawowe dyskretyzacje dla szeregu Taylora drugiego rzędu, prowadzące do dwóch zestawów masek. Pierwszy z nich, którego zastosowanie zostanie oznaczone w dalszej części jako *metoda A*, jest następujący [10]:

$$\mathbf{M}_{xx} = \begin{bmatrix} 0 & +1 & 0 \\ 0 & -2 & 0 \\ 0 & +1 & 0 \end{bmatrix}; \quad \mathbf{M}_{yy} = \begin{bmatrix} 0 & 0 & 0 \\ +1 & -2 & +1 \\ 0 & 0 & 0 \end{bmatrix}; \quad \mathbf{M}_{xy} = \frac{1}{4} \cdot \begin{bmatrix} +1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & +1 \end{bmatrix}\quad (3)$$

Drugi wariant, prowadzący do *metody B*, wynika z zastosowania masek \mathbf{W} :

$$\mathbf{W}_{xx} = \frac{1}{3} \cdot \begin{bmatrix} +1 & +1 & +1 \\ -2 & -2 & -2 \\ +1 & +1 & +1 \end{bmatrix}; \quad \mathbf{W}_{yy} = \frac{1}{3} \cdot \begin{bmatrix} +1 & -2 & +1 \\ +1 & -2 & +1 \\ +1 & -2 & +1 \end{bmatrix}; \quad \mathbf{W}_{xy} = \frac{1}{4} \cdot \begin{bmatrix} +1 & 0 & -1 \\ 0 & 0 & 0 \\ -1 & 0 & +1 \end{bmatrix}\quad (4)$$

W [12] i wcześniejszych publikacjach [2, 11] w roli wskaźnika określającego lokalnie wyróżniający się punkt zastosowano iloraz wartości własnych hesjanu

$$r = \frac{\lambda_1}{\lambda_2}\quad (5)$$

przy czym wartości własne muszą być wcześniej uporządkowane: $\lambda_1 = \lambda_2$. Wskaźnik (5) jest w praktyce zastępowany podobnym, jednak prostszym do wyliczenia [12]

$$q = \frac{\text{Tr}(\mathbf{H})^2}{\text{Det}(\mathbf{H})} = \frac{(r+1)^2}{r}\quad (6)$$

Zaproponowany w [12] próg o wartości 10, wskazujący na obecność punktów charakterystycznych, może być przeliczony następująco: $r < 10 \leftrightarrow q < 12,1$. Ta sama wartości progu została zastosowana dla wszystkich poziomów rozdzielczości.

Zaproponowany w [10] wskaźnik bazujący na różnicy wartości własnych określony jest następująco

$$R = |\lambda_1 - \lambda_2|\quad (7)$$

Wyliczenie wskaźnika różnicowego (7) okazuje się jeszcze prostsze niż ilorazowego (5), gdzie konieczne jest przybliżenie (6), dzięki zastosowaniu zależności [10]

$$(\lambda_1 - \lambda_2)^2 = f_{xx}^2 + f_{yy}^2 - 2 \cdot f_{xx} \cdot f_{yy} + 4 \cdot f_{xy}^2 \quad (8)$$

Ponadto, jak wykazano w [6], wartość wskaźnika (7) jest identyczna dla obu zestawów masek (3) i (4).

W przypadku wskaźnika różnicowego dla uzyskania podobnej liczby wytypowanych punktów dla kolejnych poziomów rozdzielczości konieczne było zastosowanie następującej sekwencji wartości progowych: $R_a < 0,5$; $R_b < 0,4$; $R_c < 0,3$; $R_d < 0,2$. Podane wartości progowe zostały dobrane eksperymentalnie, tak by liczba punktów charakterystycznych dla kolejnych poziomów rozdzielczości była podobna dla danego obrazu i wybranej metody. Indeksy a , b , c i d odpowiadają oznaczeniom z rysunków 1 i 2.

Wskaźnik (7) z wyżej określonymi progami tworzy *metodę C*. We wszystkich metodach w roli kandydatów na punkty charakterystyczne brane są pod uwagę wyłącznie piksele, dla których iloczyn wartości własnych jest dodatni [10, 12].

2.4. Zastosowana metodyka

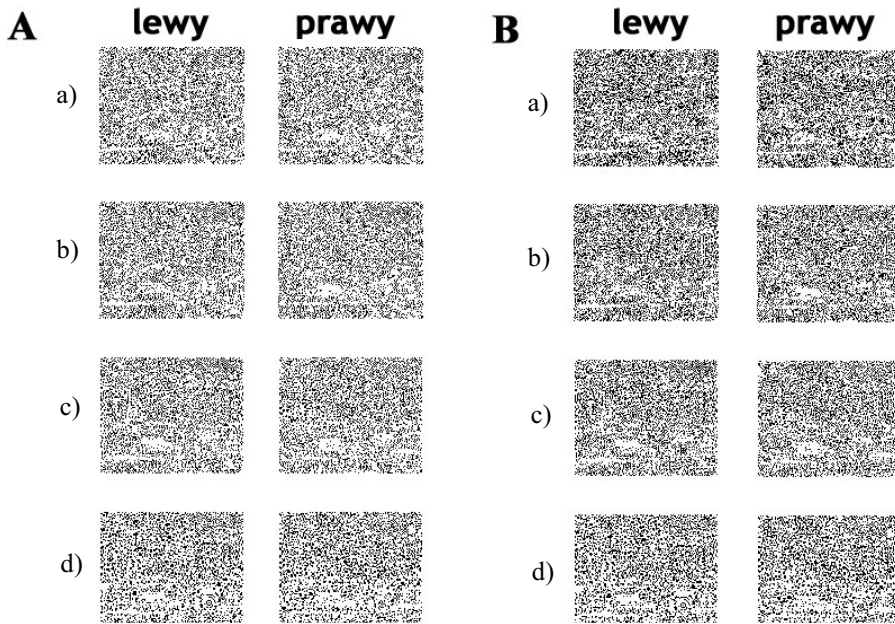
Po wyznaczeniu czterech wersji obrazów na kolejnych poziomach rozdzielczości dla obrazu lewego i prawego, zastosowano porównywane metody (A, B i C) w celu wytypowania kandydatów na punkty charakterystyczne. Następnie wyznaczono przecięcie (część wspólną) zbiorów wytypowanych punktów na kolejnych poziomach dla każdej metody osobno, traktując obrazy lewy i prawy niezależnie. Lokalizacje wytypowanych pikseli porównano wizualnie i metodami statystycznymi. Na ostatnim etapie wyznaczono dysparycje [6, 9] między obrazem lewym i prawym, traktując obraz prawy jako odniesienie, przy czym w tej operacji pod uwagę były brane wyłącznie punkty charakterystyczne wynikające z poprzedniego etapu. Dysparycje wyznaczane były nieliniową metodą korelacyjną (przez porównanie współczynnika korelacji) dla okna o rozmiarach 3×3 pikseli. W roli danych referencyjnych wykorzystano mapę dysparycji wyznaczoną dla badanej stereopary z wykorzystaniem tej samej metody, jednak biorąc pod uwagę wszystkie piksele i dla okna 11×11 pikseli.

3. Wyniki


3.1. Wizualne porównanie lokalizacji punktów charakterystycznych

Najbardziej elementarnym, ale jednak wskazującym na istotne cechy sposobem badania efektów stosowania danej metody jest wizualna ocena rozmieszczenia wybranych punktów. Na rysunkach 4 i 5 przedstawiono rozmieszczenie punktów wynikających z zastosowania opisanych wyżej trzech metod. Zwraca uwagę dość chaotyczny – według oceny subiektywnej – rozkład wyników dla metod A i B oraz zauważalne pomijanie linii krawędziowych, co jest przecież podstawowym założeniem dla wykrywania punktów charakterystycznych [10, 12], w metodzie C. Na rysunku 5 świadczy o tym obecność białych obsza-

rów, oznaczających brak punktów charakterystycznych, w rejonach, w których w obrazach występują granice obiektów lub wyraźne linie. Na rysunku 4 analogiczne obszary są znacznie słabiej widoczne, co oznacza, że w rejonach tych punkty charakterystyczne zostały zachowane, wbrew przyjętemu założeniu.



Rys. 4. Lokalizacja w obrazach badanej stereopary (obraz lewy i prawy) punktów charakterystycznych (zaznaczonych kolorem czarnym) na kolejnych poziomach piramidy: a, b, c, d, zgodnie z rysunkiem 1 i 2; dla metod A i B, wykorzystujących wskaźnik ilorazowy (5) (6)



Rys. 5. Lokalizacja w obrazach badanej stereopary (obraz lewy i prawy) punktów charakterystycznych (zaznaczonych kolorem czarnym) na kolejnych poziomach piramidy: a, b, c, d, zgodnie z rysunkiem 1 i 2; dla metody C, wykorzystującej kryterium różnicowe (7)

3.2. Statystyczne porównanie lokalizacji punktów charakterystycznych

Kolejnym sposobem zbiorczego porównania otrzymywanych wyników jest sporządzenie zestawienia o charakterze statystycznym. W tabelach 1 i 2 przedstawiono wyniki umożliwiające konfrontację trzech porównywanych metod. Wyniki zawarte w tabeli 1 wskazują na bardzo zbliżoną skuteczność wszystkich trzech metod. Jednak zawartość tabeli 2 informuje o istotnych różnicach w lokalizacji punktów, uzyskanych przy stosowaniu porównywanych metod. Jak wynika z tabel, około połowa punktów wytypowanych przez metodę C nie odpowiada wynikom metod A i B, które w tym porównaniu również różnią się wzajemnie w sposób wyraźny. Rezultat taki potwierdza wstępne obserwacje poczynione po przeprowadzeniu analizy teoretycznej w [10].

Tabela 1

Procentowy udział punktów charakterystycznych wybranych za pomocą metod A, B i C w odniesieniu do liczby wszystkich pikseli w obrazie (210×260); a,b,c,d oznacza poziomy piramidy gaussowskiej (patrz rysunki 1, 2 i 3). Koniunkcja oznacza liczbę punktów o zgodnych lokalizacjach dla wszystkich czterech poziomów piramidy.

Wyniki podano dla obu obrazów stereopary: lewy/prawy

| | A | B | C |
|------------|---------------|---------------|---------------|
| a | 29,7 / 29,3 | 37,6 / 37,3 | 30,7 / 30,7 |
| b | 29,8 / 29,7 | 35,1 / 35,0 | 31,8 / 32,2 |
| c | 29,9 / 29,4 | 33,1 / 31,4 | 33,6 / 34,9 |
| d | 29,5 / 29,4 | 31,6 / 31,3 | 34,5 / 34,9 |
| Koniunkcja | 11,90 / 11,52 | 13,88 / 13,74 | 13,13 / 13,11 |

Tabela 2

Czteropolowe tabele wielorozdzielcze [13] statystycznych zgodności lokalizacji punktów otrzymanych w wyniku stosowania różnych metod (A, B i C). Każda tabela konfrontuje dwie metody. A:1 oznacza liczbę pikseli uznanych za punkt charakterystyczny za pomocą metody A, A:0 to liczba pikseli odrzuconych. Wartości podano w procentach w odniesieniu do wszystkich pikseli obrazu; dla obrazu lewego (na górze) i obrazu prawego (na dole)

| | A:1 | A:0 |
|-----|-------|-------|
| B:1 | 10,35 | 3,53 |
| B:0 | 1,55 | 84,56 |

| | C:1 | C:0 |
|-----|------|-------|
| A:1 | 8,66 | 3,24 |
| A:0 | 4,47 | 83,63 |

| | C:1 | C:0 |
|-----|------|-------|
| B:1 | 8,78 | 5,10 |
| B:0 | 4,35 | 81,77 |


| | A:1 | A:0 |
|-----|-------|-------|
| B:1 | 10,04 | 3,70 |
| B:0 | 1,48 | 84,78 |

| | C:1 | C:0 |
|-----|------|-------|
| A:1 | 8,37 | 3,15 |
| A:0 | 4,74 | 83,74 |

| | C:1 | C:0 |
|-----|------|-------|
| B:1 | 8,64 | 5,10 |
| B:0 | 4,47 | 81,79 |

3.3. Efektywność wyznaczania dysparycji

Na rysunku 6 pokazano referencyjną mapę dysparycji, otrzymaną po wyznaczeniu dysparycji dla każdego z poziomów rozdzielczości osobno z oknem 11×11 , a następnie wybraniu jedynie tych punktów, dla których zachodziła zgodność wartości dysparycji dla wszystkich czterech poziomów jednocześnie (55,89%). Otrzymana mapa posiada rozmiar 193×248 pikseli, co wynika z ograniczeń występujących w pobliżu brzegu obrazu [9].



Rys. 6. Referencyjna mapa dysparycji o rozmiarach 193×248 uzyskana dla okna korelacyjnego o rozmiarach 11×11 . Obszary czarne oznaczają brak zgodności pomiędzy poziomami – wyniki odrzucone. Im jaśniejszy kolor, tym większa wartość dysparycji, odpowiadająca mniejszej odległości od układu kamer rejestrujących obraz

W tabeli 3 zawarto statystyczne porównanie wyników dysparycji wyznaczonych na bazie punktów charakterystycznych wyznaczonych badanymi metodami, w odniesieniu do referencyjnej mapy dysparycji. Zawartość tabeli jednoznacznie wskazuje na przewagę metody C, wyprowadzonej teoretycznie w [10].

Tabela 3

Zgodność wyznaczania dysparycji między punktami wynikającymi z porównywanych metod oraz referencyjną mapą dysparycji – rysunek 5. Wartości w tabeli wyrażono w procentach w odniesieniu do: x – liczby pikseli w obrazie referencyjnym (193×248), y – liczby punktów w obrazie referencyjnym (55,89%), dla których uzyskano zgodność dysparycji dla wszystkich czterech poziomów rozdzielczości

| | Metoda A | Metoda B | Metoda C |
|------------|----------|----------|----------|
| wersja x | 0,98 | 1,14 | 5,23 |
| wersja y | 1,76 | 2,04 | 9,35 |

4. Podsumowanie

Wyniki otrzymane z przeprowadzonego eksperymentu potwierdziły różnice wynikające z różnych metod wyznaczania macierzy hesjanu w przypadku stosowania kryterium ilorazowego (metody A i B), wynikające wstępnie z analizy teoretycznej [10]. Potwierdzono sformułowane w [10] obawy, iż zastosowanie obu typowych technik może prowadzić do różniących się wyników w postaci wskazania innych zbiorów punktów charakterystycznych, jedynie częściowo pokrywających się. Te różnice nabierają szczególnego znaczenia w aspekcie relatywnie niedużej liczby punktów wytypowanych po zastosowaniu proponowanego w [12] kryterium. Należy również podkreślić fakt, iż liczba punktów charakterystycznych, które były wspólne dla wszystkich czterech poziomów piramidy gaussowskiej, była w tym przypadku znacznie mniejsza niż liczba punktów wskazanych dla każdego z poziomów z osobna, co dodatkowo potwierdza wyrażone uprzednio wątpliwości, co do efektywności kryterium ilorazowego przy zastosowaniu typowych metod wyznaczania macierzy hesjanu.

Wyniki uzyskane dla metody ze wskaźnikiem różnicowym (7) (metoda C) również potwierdziły wstępne sugestie wynikające z analizy teoretycznej [10]. Odpowiednio dobrane wartości progów umożliwiły uzyskanie podobnej jak w obu metodach ze wskaźnikiem ilorazowym (5) (6) liczby punktów, o lokalizacji znacznie wyraźniej omijającej krawędzie niż w przypadku metod A i B. W przypadku tej metody stwierdzono ponadto znacznie większą zgodność pomiędzy lokalizacjami punktów wytypowanymi na kolejnych poziomach piramidy, co dodatkowo wskazuje na korzystne cechy tego rozwiązania. Kolejnym etapem prac powinno być zweryfikowanie przydatności wytypowanych punktów charakterystycznych z punktu widzenia pozostałych kroków algorytmu SIFT [12].

Literatura

- [1] Bovik A. (ed.), *Handbook of Image and Video Processing*. Academic Press, 2000.
- [2] Brown M., Lowe D., *Invariant Features from Interest Points Groups*. Proceedings of the British Machine Vision Conference, Cardiff, Wales, 2002, 656–665.
- [3] Brown M., Lowe D.G., *Recognizing Panoramas*. Proceedings of the 9th IEEE International Conference on Computer Vision (ICCV 2003), France, Nice, October 2003, II 1218–1225.
- [4] Cheung W., Hamarneh G., *N-SIFT: N-Dimensional Scale Invariant Feature Transform for matching medical images*. Proceedings of the IEEE International Symposium on Biomedical Imaging (ISBI 2007), USA, Washington, April 2007, 720–723.
- [5] Cui Y., Hasler N., Thormaehlen T., Seidel H.P., *Scale Invariant Feature Transform with Irregular Orientation Histogram Binning*. Proceedings of the International Conference on Image Analysis and Recognition (ICIAR 2009), Canada, Halifax, July 2009.
- [6] Cyganek B., *Komputerowe przetwarzanie obrazów trójwymiarowych*. EXIT, 2002.
- [7] Hoggar S.G., *Mathematics of Digital Images*. Cambridge University Press, 2006.
- [8] Ke Y., Sukthankar R., *PCA-SIFT: a more distinctive representation for local image descriptors*. Proceedings of the IEEE Conference on Computer Vision and Pattern recognition (CVPR 2004), USA, Washington, July 2004, II 506–513.

- [9] Korohoda P., *Badanie możliwości akustycznej reprezentacji wybranych elementów opisu przestrzeni 3D*. Raport grantu badawczego KBN nr 8T11E00910, 1999.
- [10] Korohoda P., *Porównanie dwóch metod trójwymiarowego modelowania obrazu za pomocą szeregu Taylora drugiego rzędu*. Automatyka (półrocznik AGH), t. 12, z. 3, 2008, 683–693.
- [11] Lowe D.G., *Object recognition from local scale-invariant keypoints*. International Conference on Computer Vision, Corfu, Greece, 1999, 1150–1157.
- [12] Lowe D.G., *Distinctive image features from scale-invariant keypoints*. International Journal of Computer Vision, 60, 2, 2004, 91–110.
- [13] Magiera R., *Modele i metody statystyki matematycznej*. GiS, Wrocław, 2002.
- [14] Mikołajczyk K., Schmidt C., *A performance evaluation of local descriptors*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 27, 2005, 1615–1630.
- [15] Tadeusiewicz R., Korohoda P., *Komputerowa analiza i przetwarzanie obrazów*. Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków, 1997.
- [16] Wróbel Z., Koproński R., *Praktyka przetwarzania obrazów w programie Matlab*. EXIT, 2004.
- [17] Mathworks [www](http://www.mathworks.com) page: <http://www.mathworks.com>.