



**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**

**TECHNIKI INFORMACYJNE
TEORIA I ZASTOSOWANIA**

Wybrane problemy
Tom 1(13)

poprzednio

**ANALIZA SYSTEMOWA W FINANSACH
I ZARZĄDZANIU**

Pod redakcją
Jerzego HOŁUBCA

Warszawa 2011



**INSTYTUT BADAŃ SYSTEMOWYCH
POLSKIEJ AKADEMII NAUK**

TECHNIKI INFORMACYJNE TEORIA I ZASTOSOWANIA

Wybrane problemy
Tom 1(13)

poprzednio

**ANALIZA SYSTEMOWA W FINANSACH
I ZARZĄDZANIU**

Pod redakcją
Jerzego HOŁUBCA

Warszawa 2011

Wykaz opiniodawców artykułów zamieszczonych
w niniejszym tomie:

Dr hab. inż. Przemysław GRZEGORZEWSKI, prof. PAN

Prof. dr hab. inż. Jerzy HOŁUBIEC

Dr inż. Tatiana JAWORSKA

Dr hab. inż. Wiesław KRAJEWSKI, prof. PAN

Dr hab. inż. Maciej KRAWCZAK, prof. PAN

Dr hab. Michał MAJSTEREK

Dr hab. inż. Andrzej MYŚLIŃSKI, prof. PAN

Prof. dr hab. inż. Witold PEDRYCZ

Dr hab. inż. Ryszard SMARZEWSKI, prof. KUL

Prof. dr hab. inż. Andrzej STRASZAK

Dr Dominik ŚLĘZAK

Prof. dr hab. inż. Stanisław WALUKIEWICZ

© Instytut Badań Systemowych PAN
Warszawa 2011

ISBN 9788389475336

METODY DETEKCCJI CECH OBRAZÓW W ANALIZIE WIELOKADROWEJ

Konrad Koniarski

Studia Doktoranckie IBS PAN

Abstract: *The paper presents review of selected methods for detection of image features. Three common used methods are compared for stereo viewing correspondence problem. The first is Harris corner detection method, next is gradient base method from SIFT (Scale Invariant Feature Transformation) detector and the last is FAST (Features from Accelerated Segment Test) method. Selected points are evaluated with regard to use epipolar geometry for view matching. RANSAC algorithm is used for computing of Fundamental Matrix and Epipolar geometry constraints. Special attention is paid to stability of point selection and performance. Based on the obtained numerical results FAST method is recommended as the most appropriate for augmented reality solutions.*

Key words: *Corner detection methods, stereo image correspondence, Harris method, FAST, SIFT, RANSAC, Epipolar Geometry*

1. Wprowadzenie

Jednym z podstawowych problemów w rozwoju informatyki jest analiza obrazów oraz detekcja i interpretacja informacji na nich przedstawionych. W wielu zastosowaniach wykorzystuje się nie tylko pojedyncze obrazy. Często analizowane są również sekwencje filmowe lub obrazy pochodzący z wielu kamer równocześnie. Szczególnym przypadkiem jest obraz stereoskopowy gdzie mamy do czynienia z dwoma obrazami otrzymanymi z różnych ujęć. W tym przypadku wykorzystując założenia geometrii epipolarnej (Hartley & Zisserman, 2010) możemy uzyskać informacje na temat przedstawionej sceny na obrazie. Niemniej jednak analiza obrazów stereoskopowych jest zbliżona do analizy sekwencji filmowej z jednego ujęcia kamery przy założeniu, że w czasie pomiędzy kolejnymi kadrami położenie elementów tworzących scenę nie ulega zmianie. Problem dopasowania elementów w kadrach jest szeroko omawiany w literaturze dotyczącej sterowania i robotyki, przetwarzania obrazów i widzenia komputerowego (ang. Image Processing, Computer Vision). Podobnym

zastosowaniem może być rozszerzona rzeczywistość (ang. Augmented Reality) (Azuma, 1997), gdzie wykorzystywane są informacje o głębi obrazu w celu wkomponowania obrazu sztucznego.

Proces dopasowania obrazów (np. stereoskopowych) jest podzielony na trzy główne kroki. W pierwszej kolejności obraz jest przetwarzany pod kątem detekcji punktów charakterystycznych zwanych cechami. Takimi punktami często są skupiska pikseli przedstawiające krawędzie, kąty, łączenia w kształcie litery T lub Y lub inne charakterystyczne obszary. Operacja ta powinna być wykonana tak, aby zmiany położenia kamery nie wpływały na powtarzalność wyników. Zmiana przy tworzeniu ujęcia kamery bardzo często wpływa na zmianę intensywności pikseli obrazu, zniekształceń np. pochodzących z aberracji układu optycznego urządzenia, czy choćby ukrywania obiektów dalszych przez obiekty bliższe. Dodatkowo należy uwzględnić zmiany będące wynikiem translacji, rotacji lub skalowania. W literaturze algorytm realizujący ten krok jest nazywany detektorem. W drugim kroku, zwanym deskryptorem, budowany jest unikalny opis znalezionej punktu w postaci wektora. Aby stworzyć unikalną cechę obrazu w jego zadanym punkcie brane są pod uwagę piksele z otoczenia zadanego punktu. Wynikiem tego kroku jest utworzenie zbioru wektorów. Ostatnim krokiem metody jest dopasowanie cech z porównywanych obrazów. W literaturze zaproponowano wiele takich metod np. wykorzystujących korelację lub mierzenie odległości pomiędzy wektorami cech. Najbardziej miarodajną jest metoda wykorzystująca specyfikę zależności geometrii epibiegunowej (Hartley & Zisserman, 2010). Każdy krok metody oznacza konieczność rozwiązania istotnych zagadnień z analizy obrazów.

W tym artykule jest rozważany pierwszy krok metody dopasowywania obrazów. Przedstawione są trzy podejścia do detekcji tych punktów obrazu, które w najwłaściwszy sposób go charakteryzują. Dla pary obrazów wyznaczono numerycznie ich punkty charakterystyczne przy użyciu rozważanych metod detekcji. Wyznaczone zbiory punktów charakterystycznych porównano przy pomocy metod geometrii epibiegunowej. Wskazano metodę detekcji obrazu najlepszą ze względu na najmniejszą liczbę odrzucanych punktów charakterystycznych.

2. Przegląd literatury

W 1988 roku Harris i Stephens (Cris & Stephens, 1988) zaproponowali metodę detekcji punktów na podstawie drugich pochodnych funkcji intensywności badanego obrazu. Metoda ta jest nadal bardzo popularna i często

występuje w pracach porównawczych do nowo proponowanych detektorów (Mikołajczyk & Schmid, 2005) (Bauer, Sunderhauf, & Protzel, 2007). Metoda ta doczekała się też wielu modyfikacji (Shi & Tomasi, 1994). Ponieważ detektor Harris'a jest wrażliwy na zmiany skali (Mikołajczyk & Schmid, 2005), zatem metoda ta nie jest użyteczna dla dopasowywania obrazów w różnej skali. Jednak w wielu zastosowaniach problem skali nie jest istotny np. w dopasowywaniu obrazu stereoskopowego przy tworzeniu obrazu głębi sceny. Lindeberg (Lindeberg, Scale space, 2009) (Lindeberg, Scale-space Theory in Computer Vision, 1994) przedstawił teorię przestrzeni skali (ang. Scale Space Theory) - wykorzystanie piramidy obrazów do rozwiązania problemu skalowalności. W metodzie Lindeberga wykrywane są punkty z różnych skal piramidy. Podejście to jest fundamentem wielu późniejszych metod detekcji cech obrazu jak np. SIFT (ang. Scale Invariant Feature Transform) (Lowe, 2004) czy SURF (ang. Speeded Up Robust Features) (Bay, Ess, Tuytelaars, & Van Gool, 2008). Z kolei jeszcze innym podejściem do detekcji punktów jest metoda FAST (ang. Features from Accelerated Segment Test) (Drummond & Rosten, 2006). W metodzie tej wybierane są punkty o charakterystycznym układzie pikseli wskazującym na możliwość istnienia początku lub końca krawędzi bądź występowania kąta. Przedstawione metody charakteryzują się całkowicie różnym podejściem do rozwiązania problemu detekcji punktów.

Przedstawione podejścia do detekcji cech same w sobie nie gwarantują, że uda się znaleźć relację pomiędzy tożsamymi punktami na dwóch obrazach. Zależności geometryczne pomiędzy dwoma kadrami są opisywane przez geometrię epipolarną (ang. Epipolar Geometry) (Hartley & Zisserman, 2010) (Koniarski, 2010). Inną techniką porównywania kadrów stereoskopowych jest korelacja wzdłuż linii epipolarnych (Manjunath, Shekhar, & Chellappa, 1996). W przypadku obrazów stereoskopowych ta technika jest uproszczona (Konrad, 2009). W geometrii epipolarniej zależność pomiędzy dwoma obrazami jest opisana przy pomocy macierzy fundamentalnej (Hartley & Zisserman, 2010) (ang. Fundamental Matrix). Do wyznaczenia tej macierzy na podstawie zbioru punktów można użyć metody zaproponowanej przez Hartley'a i Zissermana w (Hartley & Zisserman, 2010). Metoda ta wykorzystuje 8 punktów do wyznaczenia macierzy fundamentalnej. W celu odrzucenia punktów nadmiarowych i niewnoszących nic nowego jest użyta metoda RANSAC (Koniarski, 2010) (ang. Random Sample Consensus).

3. Metody detekcji punktów

3.1. Detektor kątów Harris (ang. Harris corner detector)

Detektor kątów Harrisa (Cris & Stephens, 1988) jest wzorowany na wcześniejszej metodzie zaproponowanej przez Moraveca. Metoda wykorzystuje macierz drugich pochodnych H (Hesjan) funkcji intensywności obrazu

$$H = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial x \partial y} \\ \frac{\partial^2 I}{\partial y \partial x} & \frac{\partial^2 I}{\partial y^2} \end{bmatrix}. \quad (1)$$

Metoda Harrisa wykorzystuje macierz autokorelacji drugich pochodnych funkcji intensywności obrazu w obszarze wybranego małego okna. Macierz autokorelacji jest zdefiniowana w następujący sposób

$$M(x, y) = \begin{bmatrix} A & C \\ C & B \end{bmatrix} = \begin{bmatrix} \sum_{-K \leq i, j \leq K} w_{i,j} I_x^2(x+i, y+j) & \sum_{-K \leq i, j \leq K} w_{i,j} I_x(x+i, y+j) I_y(x+i, y+j) \\ \sum_{-K \leq i, j \leq K} w_{i,j} I_x(x+i, y+j) I_y(x+i, y+j) & \sum_{-K \leq i, j \leq K} w_{i,j} I_y^2(x+i, y+j) \end{bmatrix}, \quad (2)$$

gdzie $w_{i,j}$ jest wagą np. o rozkładzie Gaussa, a K to rozmiar okna.

Kąty w definicji Harrisa są wybierane w obrazie, gdy macierz autokorelacji drugich pochodnych ma dwie duże wartości własne. Oznacza to, że jest tekstura lub krawędź idąca w dwóch kierunkach przecinająca się w pobliżu tego punktu. Zaletą wykorzystania macierzy autokorelacji jest niewrażliwość metody detekcji na rotację obrazu. Aby wyznaczyć wierzchołek kąta Harris zaproponował analizę znaku

$$R = \text{Det}(M) - k \text{Tr}(M)^2. \quad (3)$$

k jest współczynnikiem zaproponowanym przez Harrisa o wartości 0.04, zaś

$$\text{Det}(M) = \alpha\beta = AB - C^2, \text{Tr}(M) = \alpha + \beta = A + B. \quad (4)$$

Na podstawie wartości R , α i β możemy każdy piksel klasyfikować w następujący sposób. Gdy R jest dodatnie to piksel wyznacza wierzchołek kąta (ang. corner region). Jeśli wartość R jest ujemna to piksel wyznacza krawędź kąta (ang. edge region). Gdy R ma wartość bliską zeru to piksel należy do obszaru płaskiego (ang. flat) (patrz Rysunek 1). Ostatnim krokiem jest progowanie wartości funkcji R dla obrazu, w celu otrzymania punktów będących kątami.

3.2. Detektor SIFT (ang. Scale Invariant Feature Transform)

Metoda SIFT została zaproponowana przez Lowe'a w (Lowe, 2004). Lowe wykorzystał wcześniejsze prace (Mikołajczyk & Schmid, 2005) (Lindeberg, Scale space, 2009) (Lindeberg, Scale-space Theory in Computer Vision, 1994) aby stworzyć metodę do wyodrębniania cech obrazu która jest niewrażliwa na zmiany intensywności, translację, rotację oraz zmianę skali. Detektor punktów jest tylko częścią tej metody. W pierwszym kroku budowana jest piramida ze skalowanych obrazów poddanych rozmyciu funkcją Gaussa (Rysunek 2, część lewa).

$$L(x, y, \sigma) = G(x, y, \sigma) * I(x, y), \quad (5)$$

gdzie σ jest parametrem rozmycia funkcją Gaussa. Lindeberg (Lindeberg, Scale-space Theory in Computer Vision, 1994) udowodnił, że tylko rozmywanie funkcją Gaussa ma sens w tym podejściu

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-(x^2+y^2)/2\sigma^2}. \quad (6)$$

Lowe (Lowe, 2004) pokazał, że ekstrema lokalne funkcji różnicy Gaussa kolejnych rozmytych skal z piramidy są punktami charakterystycznymi dla obrazu.

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

gdzie k jest parametrem skali pomiędzy kolejnymi stopniami piramidy. 3.3.

Następnie przestrzeń piramidy jest przeszukiwana w celu detekcji lokalnych ekstremów w przestrzeni skali tak jak na Rysunek 2 (część prawa).

3.3. Detektor FAST(ang. Features form Accelerated Segment Test)

Metoda FAST (Features form Accelerated Segment Test) zaproponowana przez Rostena i Drummonda (Drummond & Rosten, 2006) jest metodą detekcji obrazu o zupełnie innym podejściu. Metoda została stworzona dla zastosowań w robotyce, gdzie wydajność jest kluczowym argumentem. Każdy punkt obrazu p jest sprawdzany czy jest punktem wierzchołkowym kąta. Dla każdego punktu p rozważane jest jego otoczenie zawarte w okręgu zdefiniowanym funkcją Bresenhama (Drummond & Rosten, 2006). Drummond zaproponował promień okręgu $r = 3$ tak jak przedstawia tak jak przedstawia Rysunek 3. W ten sposób otrzymujemy obwód składający się z 16 punktów. Algorytm sprawdza kolejne punkty obwodu czy różnią się od punktu centralnego p o dany próg t wartości funkcji intensywności obrazu. Jeśli n kolejnych punktów obwodu spełnia ten warunek punkt jest klasyfikowany jako punkt wierzchołkowy kąta.

3.4. Geometria epibiegunowa (ang. Epipolar Geometry)

Geometria epibiegunowa opisuje związki pomiędzy wieloma widokami tej samej sceny przedstawionej z różnych ujęć kamery. Wprowadza ona powiązania pomiędzy powstałymi punktami na obrazach kadrów. Każda reprezentacja punktu w przestrzeni 3D na obrazie jest powiązana zależnością

$$x'_i{}^T F x_i = 0, \quad (8)$$

gdzie x_i i x'_i to punkty obrazów, a F to macierz fundamentalna (Hartley & Zisserman, 2010) (Koniarski, 2010).

Do wyznaczenia macierzy fundamentalnej F na podstawie wybranych reprezentacji punktów z dwóch lub więcej kadrów można użyć metody zaproponowanej przez Hartleya i Zissermana w (Hartley & Zisserman, 2010). Algorytm ten wyznacza wartości elementów macierzy rozwiązując układ 8 równań liniowych. Zatem do wyznaczenia macierzy fundamentalnej potrzebne jest 8 punktów. Ponieważ jednak nie jest wiadomo jak dopasować punkty z obu obrazów algorytm wykorzystuje metodę RANSAC (ang. Random Sample Consensus) do wyznaczenia maksymalnej ilości punktów obu obrazów odpowiadających sobie. Jednocześnie algorytm RANSAC eliminuje punkty niepasujące do siebie. Pierwszym krokiem w ośmiopunktowej metodzie Hartleya jest normalizacja punktów przy pomocy transformacji T

$$\hat{x}_i = T x_i, \hat{x}'_i = T x'_i. \quad (9)$$

Układ ośmiu równań liniowych można zapisać, jako następujący iloczyn skalarny

$$(x'x, x'y, x', y'x, y'y, y', x, y, 1)f = 0, \quad (10)$$

gdzie f jest dziewięcioelementowym wektorem, stworzonym z elementów macierzy F' w kolejności wierszy. Kolejnym krokiem jest poprawienie tak uzyskanej macierzy, aby była ona macierzą osobliwą \hat{F}' . W tym celu wykonany jest rozkład SVD macierzy F' tak, aby zminimalizować odległość Frobeniusa gdzie $\det F' = 0$. Ostatnim krokiem jest denormalizacja

$$F = T'^T \hat{F}' T. \quad (11)$$

4. Wyniki obliczeń numerycznych


Powyższe metody zaimplementowano w środowisku Matlab. Wykorzystano algorytm FAST z pracy (Drummond & Rosten, 2006) oraz opracowano lub zmodyfikowano algorytmy SIFT i Harrisa.

W porównaniu metod pierwszym krokiem było wyznaczenie optymalnych parametrów dla każdej metody, aby można było porównać ich szybkość działania i jakość wyników. W tym celu były zmieniane kolejne parametry tak jak podano w Tabeli 1.


Tabela 1. Parametry metod

Metoda	Parametr	Wartość uznana za optymalną
Detektor Harrisa	sigma – parametr autokorelacji	0,5
	thresh – parametr progowania	150
	radius – parametr minimalnego sąsiedztwa wybranych punktów	4
Detektor SIFT	thresh – parametr progowania ekstremów	3
	scl – zmiana skali przy budowie piramidy	1.5
	sigma –rozmycie przy budowie piramidy	1.5
Detektor FAST	thresh – parametr progowania	50


Wszystkie metody poradziły sobie ze znalezieniem tożsamyh punktów w obu obrazach. Najlepsze wyniki osiągnęła metoda FAST. Jak widać na Rysunek 10. znaleziono bardzo dużo punktów i większość z nich została poprawnie dopasowana. Metoda FAST jest też najszybsza wyznaczając punkty w czasie 0,06 - 0,22 sekundy na badany kadr.



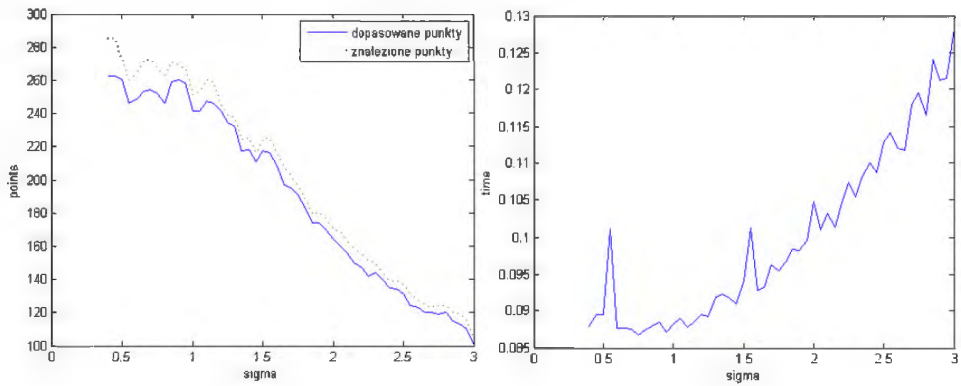
Rysunek 1. Przestrzeń wartości autokorelacji R detektora Harrisa (Cris & Stephens, 1988)



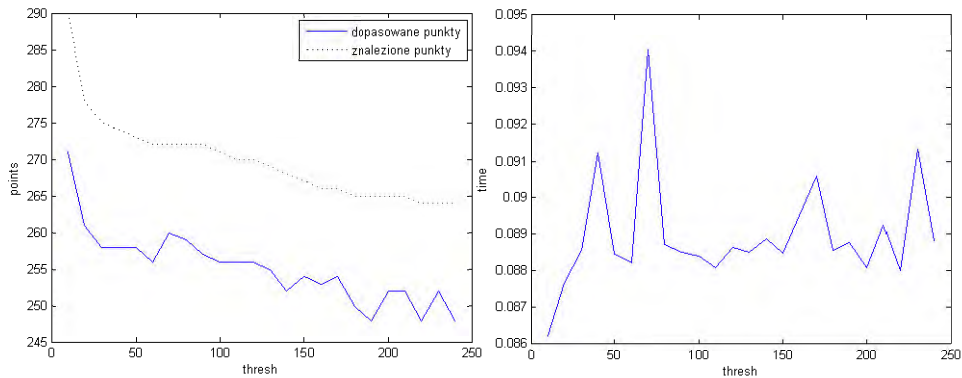
Rysunek 2. SIFT (Lowe, 2004): piramida skalowanych obrazów (strona lewa), poszukiwanie lokalnych ekstremów (strona prawa)




Rysunek 3. FAST: wyznaczenie punktów charakterystycznych




Rysunek 4 Detektor Harrisa. Wpływ parametru sigma na liczbę dopasowanych punktów (strona lewa) i czas wykonania(strona prawa).




Rysunek 5. Detektor Harrisa. Wpływ parametru thresh na liczbę dopasowanych punktów (strona lewa) i czas wykonania (strona prawa).



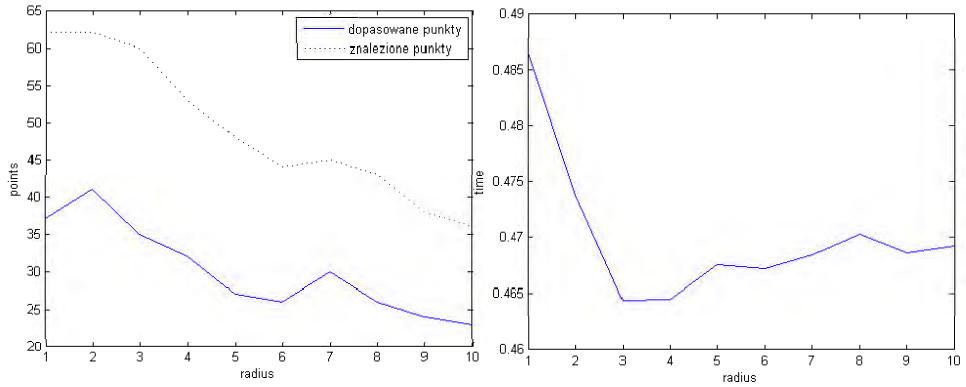
Rysunek 6. Detektor Harrisa. Wpływ parametru radius na liczbę dopasowanych punktów (strona lewa) i czas wykonania (strona prawa).




Rysunek 7. Detektor SIFT. Wpływ parametru scl na liczbę dopasowanych punktów (strona lewa) i czas wykonania(strona prawa).




Rysunek 8. Detektor SIFT. Wpływ parametru thresh na liczbę dopasowanych punktów (strona lewa) i czas wykonania(strona prawa).




Rysunek 9. Detektor SIFT. Wpływ parametru radius na liczbę dopasowanych punktów (strona lewa) i czas wykonania(strona prawa).




Rysunek 10. Detektor FAST. Wpływ parametru thresh na liczbę dopasowanych punktów (strona lewa) i czas wykonania(strona prawa).



Rysunek 11. Detektor Harris: (lewa strona) lewy kadr, (środek) prawy kadr, (prawa strona) dopasowanie obrazów.



Rysunek 12. Detektor SIFT: (lewa strona) lewy kadr, (środek) prawy kadr, (prawa strona) dopasowanie obrazów.



Rysunek 13. Detektor FAST: (lewa strona) lewy kadr, (środek) prawy kadr, (prawa strona) dopasowanie obrazów.

Ponieważ wykorzystane obrazy ze zbioru [17] są jedynie przesunięte względem siebie pozwala to na oszacowanie jakości dopasowania punktów. Na Rysunek oprócz poziomych są widoczne inne linie, co oznacza, że niektóre dopasowania punktów są błędne. Metoda detekcji kątów Harrisa w porównywalnym czasie 0,8 - 0,13 na badany kadr wyznacza znacznie mniej punktów niż metoda FAST. Detektor SIFT cechuje najmniejsza efektywność. Wybierane przez niego cechy obrazu nie są dobre pod kątem dopasowania. Jest ich znacznie mniej niż w przypadku pozostałych metod.

Jak widać na mimo znalezienia dużej ilości cech przez detektor SIFT nie nadają się one do wyznaczenia cech z obrazu porównywanych przy pomocy metody RANSAC (Hartley & Zisserman, 2010).

Podsumowanie

W artykule zostały porównane metody detekcji cech obrazu w zastosowaniu dopasowania obrazów stereoskopowych. Z pośród trzech porównywanych metod metoda FAST jest metodą najszybszą i zwracającą największą liczbę dopasowanych punktów obrazów. Zatem jest ona najwłaściwsza do wykorzystania w obliczeniach w czasie rzeczywistym występujących w zagadnieniach rozszerzonej rzeczywistości.

Literatura

- [1] Richard Hartley and Andrew Zisserman (2010), *Multiple View Geometry*. New York: Cambridge University Press.
- [2] Ronald T. Azuma, "A Survey of Augmented Reality," *Teleoperators and Virtual Environments*, vol. 6, no. 4, pp. 355-385, 1997.
- [3] Harris Cris and Mike Stephens (1988), *A combined corner and edge detector*.
- [4] Krystian Mikołajczyk and Cordelia Schmid (2005), A performance evaluation of local descriptors. *IEEE transactions of Pattern Analysis and Machine Intelligence*, vol. 27, no. 10, pp. 1615-1630, October.
- [5] Johannes Bauer, Niko Sunderhauf, and Peter Protzel (2007), Comparing several implementations of two recently published feature detectors. *International Conference of Intelligent and Autonomous Systems*.

- [6] Jiango Shi and C. Tomasi (1994), Good Features to Track. *Computer Vision and Pattern Recognition*, pp. 593 - 600, Jun.
- [7] Tony Lindeberg (2009), Scale space. *Encyclopedia of Computer Science and Engineering*, vol. 4, pp. 2495-2504.
- [8] Tony Lindeberg (1994), *Scale-space Theory in Computer Vision*. Kluwer/Springer.
- [9] David G. Lowe (2004), Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*, vol. 60, no. 2, pp. 91-110.
- [10] Herbert Bay, Andreas Ess, Tinne Tuytelaars, and Luc Van Gool (2008), Speeded up robust features (SURF). *Computer Vision and Image Understanding*, vol. 110, pp. 346-359.
- [11] Tom Drummond and Edward Rosten (2006), Machine learning for high-speed corner detection. *European Conference on Computer Vision*, vol. 1, pp. 430-443, May.
- [12] Konrad Koniarski (2010), *Wielokadrowa analiza obrazów w zagadnieniach rozszerzonej rzeczywistości*. W: *Analiza systemowa w finansach i zarządzaniu, Wybrane problemy*. Red. J. Hołubiec, vol. 12, pp. 112-121.
- [13] B.S. Manjunath, C Shekhar, and R Chellappa (1996.), A new approach to image feature detection with applications. *Pattern Recognition*, vol. 29, no. 4, pp. 627-640, April [Online]. [http://www.ece.ucsb.edu/~manj/ece181bS04/L14\(morestereo\).pdf](http://www.ece.ucsb.edu/~manj/ece181bS04/L14(morestereo).pdf)
- [14] Koniarski Konrad (2009), *Stereoskopowa Segmentacja obrazu*. W: *Analiza systemowa w finansach i zarządzaniu, Wybrane Problemy*. Red. J. Hołubiec, vol. 11, pp. 148-152.
- [15] Roy Edward Davies (2005), *Machine Vision: Theory, Algorithms, Practicalities*, 3rd ed. San Francisco, USA: Elsevier.
- [16] Gary Bradski and Kaehler Adrian (2008.), *Learning OpenCV*. Sebastopol, USA CA: O'Reilly Media Inc.
- [17] [Online]. vision.middlebury.edu/stereo/

ISBN 9788389475336

