

Rejestracja chmur punktów: porównanie wariantów wzajemnej rejestracji

Marta Jolanta Łepicka

Politechnika Warszawska, Instytut Automatyki i Informatyki Stosowanej, ul. Nowowiejska 15/19, 00-665 Warszawa

Tomasz Kornuta

IBM Research – Almaden, 650 Harry Rd, San Jose, CA 95120, Stany Zjednoczone

Streszczenie: W dwuczęściowym artykule skupiono uwagę na problemie rejestracji chmur punktów. W pierwszej części omówiono kluczowe komponenty systemu V-SLAM uzupełnione przykładowymi algorytmami i rozwiązaniami stosowanymi w tych komponentach. W poniższej, drugiej części omówiono różne rodzaje wariantów algorytmu ICP, atrybuty punktów oraz operujące na nich metryki. Następnie omówiono metodykę badań oraz przedstawiono wyniki porównania wybranych wariantów wzajemnej rejestracji.

Słowa kluczowe: obraz RGB-D, chmura punktów, rejestracja, wzajemne łączenie, ICP, SIFT, KAZE

1. Wprowadzenie

Proces rejestracji (ang. *registration*) [10, 16] polega na łączeniu wielu widoków (obrazów, chmur punktów) w jeden spójny, trójwymiarowy model sceny bądź pojedynczego obiektu. W pierwszej części artykułu [11] dokonano przeglądu metod rejestracji oraz pokrótce omówiono komponenty stosowane w systemach rejestracji. W szczególności uwagę skupiono na jednym z ważniejszych algorytmów, tzn. na algorytmie ICP (ang. *Iterative Closest Point*) wykorzystywanym do iteracyjnej rejestracji wzajemnej chmur punktów. Jednym z kroków ICP jest asocjacja punktów mająca na celu znalezienie dopasowań między poszczególnymi punktami obu chmur. Znalezione dopasowania służą następnie do oszacowania transformacji między chmurami, po zastosowaniu której zmniejszony zostanie sumaryczny błąd wzajemnego niedopasowania chmur.

W pracy zawężono uwagę do dwóch kluczowych elementów kroku asocjacji: atrybutów punktów oraz operujących na tych atrybutach metrykach służących do szacowania błędu niedopasowania. Przedstawiono analizę różnych wariantów algorytmu ICP pod kątem wykorzystywanych przez nich atrybutów oraz metryk. Zaprezentowano również wyniki porównania kilka wybranych odmian algorytmu ICP, operujących zarówno na rzadkich, jak i gęstych chmurach punktów.

2. Atrybuty punktów

Podczas asocjacji (tzn. znajdowania dopasowań) między punktami należącymi do dwóch chmur można wykorzystać nie tylko geometryczne atrybuty punktu, typu położenie kartezjańskie czy lokalna krzywizna, ale również dodatkowe, fotometryczne atrybuty, np. deskryptory charakteryzujące kolor i teksturę w pewnym otoczeniu danego punktu. Innymi słowy, asocjacja może korzystać z:

- geometrycznych atrybutów punktów – prostych atrybutów typu wektor normalny lub złożonych reprezentacji opisujących powierzchnie w pewnym otoczeniu tego punktu,
- fotometrycznych atrybutów punktu – prostych typu kolor lub złożonych w postaci deskryptorów punktowych cech obrazu,
- obu rodzajów atrybutów jednocześnie.

W tabeli 1 przedstawiono przykładowe atrybuty, które mogą zostać przypisane punktom i zastosowane w procesie asocjacji. Warto zauważyć, iż do łączenia chmur punktów niezbędna jest znajomość informacji dotyczących położenia punktów obu chmur w przestrzeni – z tego powodu atrybut ten został wyróżniony podkreśleniem.

Mimo niskiej złożoności obliczeniowej proste atrybuty dostarczają bardzo zgrubnej charakterystyki otoczenia. Ponieważ opisują geometrię sąsiedztwa punktu zaledwie kilkoma parametrami, większość scen zawierała będzie wiele punktów o takich samych lub bardzo zbliżonych wartościach parametrów, co może skutkować niepoprawnymi dopasowaniami. Dlatego też rozpoczęto prace nad bardziej złożonymi opisami otoczenia punktu, tzw. deskryptorami, które charakteryzują otoczenie w postaci wielowymiarowych wektorów. Użycie dodatkowych atrybutów, z racji zwiększenia ilości dostępnej informacji na temat danego punktu, umożliwia lepsze parowanie punktów, co w konsekwencji może znacznie poprawić działanie algorytmu. Ekstrakcja deskryptorów jest z reguły procesem o dużej złożoności obliczeniowej, dlatego w celu skrócenia czasu działania systemu deskryptory te wylicza się jedynie dla wybranych punktów (tzw. punktów kluczowych). W efekcie powstają tzw. rzadkie

Autor korespondujący:

Tomasz Kornuta, tkornuta@gmail.com

Artykuł recenzowany

nadesłany 22.02.2017 r., przyjęty do druku 23.06.2017 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

Tabela 1. Przykładowe atrybuty, które można przypisać punktom chmury, a następnie użyć w procesie asocjacji chmur punktów

Table 1. Exemplary attributes that can be assigned to points of cloud and used later in point cloud association

Typ chmury	Atrybut Geometryczny		Atrybut Fotometryczny	
	Prosty	Deskryptor	Prosty	Deskryptor
Gęsta	współrzędne wektor normalny krzywizna	–	intensywność kolor krawędzie	–
Rzadka	współrzędne	3DSC [8] FPFH [18] SHOT [20]	–	SIFT [14] KAZE [2] FREAK [1]

chmury (cech) – terminy te wytłumaczone zostały w sekcji 2.1. *Ekstrakcja cech* w pierwszej części artykułu [11].


Niestety, każdy rodzaj deskryptora ekstrahowany jest za pomocą innego, z reguły wyrafinowanego algorytmu, dlatego też zdecydowano się omówić pokrótce jedynie kilka wybranych deskryptorów. Zainteresowanego czytelnika odsyłamy do artykułów przeglądowych i porównujących cechy punktowe, np. do klasycznego porównania deskryptorów fotometrycznych [21], deskryptorów binarnych [7] lub do artykułu przeglądowego omawiającego deskryptory geometryczne [9].

2.1. Atrybuty geometryczne

2.1.1. Atrybuty proste


Pojedynczy punkt p nie niesie informacji o swoim sąsiedztwie. Jednak podczas obliczania odległości między punktami (np. podczas parowania) można wykorzystać ich współrzędne jako najprostszy, elementarny atrybut geometryczny punktu. Na rys. 1 zaprezentowano proste atrybuty stosowane do reprezentacji geometrii otoczenia S w przestrzeni dwuwymiarowej: współrzędne punktu p , wektor styczny t w punkcie oraz krzywa opisana przez krzywiznę κ , wektor normalny n i wektor styczny t .

Analogicznie, proste atrybuty stosowane do reprezentacji geometrii otoczenia w przestrzeni trójwymiarowej tworzą: współrzędne punktu p , wektor normalny n oraz kwadryka opisana przez wektory styczne t i krzywizny główne κ_{min} , κ_{max} (rys. 2).



Rys. 1. Atrybuty geometrii otoczenia danego punktu w przestrzeni dwuwymiarowej [16]

Fig. 1. Geometrical attributes of a given point in two dimensional space [16]



Rys. 2. Atrybuty geometrii otoczenia danego punktu w przestrzeni trójwymiarowej [16]

Fig. 2. Geometrical attributes of a given point in three dimensional space [16]

Atrybuty te są ściśle związane z pochodnymi wyznaczonymi w punktach. Punkt odpowiada brakowi pochodnej, wektor styczny/normalny odpowiada pierwszej pochodnej w punkcie, natomiast krzywa/kwadryka – drugiej pochodnej.

2.1.2. Atrybuty złożone (deskryptory)

Deskryptor 3DSC (ang. *3D Shape Context*) [8] jest jednym z pierwszych opracowanych deskryptorów cech ekstrahowanych z chmur punktów i stanowi uogólnienie idei deskryptora *Shape Context* (SC) [3] dla przestrzeni trójwymiarowej. Punkty należące do sąsiedztwa danego punktu p (tzn. znajdujące się wewnątrz sfery o zadanym promieniu) są kulekowane (grupowane) pod kątem należności do wycinka sfery określonego przedziałami kątów azymutu oraz elewacji względem wektora normalnego rozważanego punktu centralnego p . Ostateczna wartość poszczególnych elementów deskryptora obliczana jest przez normalizację poszczególnych kulek.

Deskryptor FPFH (ang. *Fast Point Feature Histogram*) [18] danego punktu p obliczany jest na podstawie jego relacji z punktami należącymi do jego sąsiedztwa (określonego analogicznie jak w 3DSC). Relacja z każdym sąsiadującym punktem opisana jest czteroelementową krotką, definiującą relacje kątowe między wektorami normalnymi obu punktów. Krotki te grupowane są (z uwzględnieniem odległości między punktami jako wagi), w wyniku czego otrzymany histogram jest deskryptorem FPFH.

Pierwszy krok ekstrakcji deskryptora SHOT (ang. *Signature of Histograms of Orientations*) [20] ma na celu obliczenie orientacji lokalnego układu współrzędnych związanego z rozważanym punktem p , na podstawie wektorów normalnych punktów należących do sąsiedztwa (kuli). Następnie algorytm dzieli sąsiedztwo punktu p na 32 wycinki kuli, biorąc pod uwagę obliczoną wcześniej orientację lokalnego układu współrzędnych. Dla każdego wycinka obliczany jest histogram, w którym grupowane są kosinusy kątów między wektorami normalnymi punktów należących do wycinka a wektorem stanowiącym oś Z lokalnego układu współrzędnych. Zebrane histogramy tworzą deskryptor SHOT.

2.2. Atrybuty fotometryczne

2.2.1. Atrybuty proste

W przypadku obrazów w odcieniach szarości najprostszym atrybutem poszczególnych punktów obrazu (pikseli) jest intensywność (odcień szarości). Gdy mamy do czynienia z obrazami kolorowymi, atrybutami mogą być składowe koloru, w zależności od wykorzystywanej przestrzeni barw, np. składowe R, G i B w przypadku przestrzeni RGB lub składowe H, S i V dla przestrzeni HSV.

Proste atrybuty mogą być również obliczane za pomocą prostych przekształceń, np. konwolucji (spłotu) obrazu z innym obrazem (maską). W szczególności przez konwolucję obrazu z odpowiednimi maskami oraz zastosowanie progowania można otrzymać tzw. obraz krawędziowy, a więc obraz binarny, w którym jedynki oznaczają obecność krawędzi, a zera ich brak. Krawędź można również potraktować jako prosty atrybut fotometryczny punktu obrazu.

2.2.2. Atrybuty złożone (deskryptory)

Postęp w obszarze tradycyjnej (tj. dwuwymiarowej) wizji komputerowej zaowocował wieloma różnorodnymi cechami lokalnymi ekstrahowanymi z obrazów. W dalszej części artykułu ograniczono się do omówienia trzech wybranych cech (tab. 1).

Algorytm SIFT (ang. *Scale-Invariant Feature Transform*) [14] stosowany jest do ekstrakcji cech z obrazów w odcieniach szarości. Motywacją utworzenia cech SIFT było określenie cech lokalnych obrazu niezależnych od położenia, skali, rotacji, oświetlenia, zmiany kąta widzenia lub zakłóceń. W tym celu zaproponowano złożony algorytm lokalizacji punktów kluczowych uwzględniający sąsiedztwo punktów różnej wielkości, a więc różne skale. Dla każdej skali obliczany jest zestaw obrazów o różnym stopniu rozmycia, na podstawie których obliczane są obrazy różnicowe. Proces ten stanowi odpowiednik filtru krawędziowego zwracającego kierunki zmian (gradienty) intensywności pikseli. Obrazy te wykorzystywane są następnie w procesie ekstrakcji deskryptorów poszczególnych punktów kluczowych, zarówno do wyznaczenia dominującej orientacji punktu kluczowego, jak i podczas obliczania histogramów składających się na właściwy deskryptor. Histogramy te tworzone są oddzielnie dla poszczególnych regionów wchodzących w skład otoczenia punktu kluczowego. Każdy z histogramów grupuje kierunki zmiany intensywności pikseli należących do danego regionu. Ze względu na bardzo dużą odporność oraz dobrą powtarzalność cechy SIFT, mimo dużej złożoności obliczeniowej, są nadal jednymi z najbardziej cenionych i szeroko stosowanych cech lokalnych ekstrahowanych z obrazów.

Cechy KAZE zaproponowane zostały w pracy [2]. Motywacją do utworzenia cech KAZE był fakt, że przy konstrukcji cech SIFT – podczas obliczania obrazów różnicowych – stosuje się rozmycie Gaussa, które w równym stopniu rozmywa zarówno szum w obrazie, jak i istotne detale. Wiąże się to często z utratą dokładności położenia punktu kluczowego, jak i ze zmianą kształtu (spłaszczeniem) histogramów wchodzących w skład deskryptora. Idea stosowania cech KAZE opiera się na użyciu nieliniowego filtru w celu otrzymania lokalnego, adaptacyjnego rozmycia obrazu, które pozwalałoby na rozmycie szumu przy zachowaniu informacji o detalach lub krawędziach obrazu.

Deskryptor FREAK (ang. *Fast Retina Keypoint*) jest deskryptorem otrzymanym przez porównanie intensywności par pikseli. Pary te określone są przez zadany odgórnie wzorec, inspirowany układem pól receptorów w siatkówce oka. FREAK należy do rodziny tzw. deskryptorów binarnych, których zaletami są zarówno szybkość ekstrakcji, jak i szybkość porównania (podobieństwo deskryptorów można obliczyć za pomocą miary Hamminga).

3. Metryki

Istnieje szereg klasycznych metryk odległości, np. miara euklidesowa, Hamminga. W przedstawionym przeglądzie skupiono się na metrykach użytecznych w kontekście rejestracji chmur punktów.


3.1. Metryki bazujące na informacji geometrycznej

3.1.1. Metryka punkt-punkt

Metryka punkt-punkt (ang. *point-to-point*) [4] jest metryką najpopularniejszą i najprostszą. Przyjęto oznaczenia: współrzędne punktu chmury źródłowej jako $s_i = (s_i^x, s_i^y, s_i^z)^T$ oraz współrzędne punktu chmury docelowej jako $t_i = (t_i^x, t_i^y, t_i^z)^T$. Funkcja odległości między dwoma punktami definiowana jest jako odległość euklidesowa:

$$d(s_i, t_i) = \sqrt{(s_i^x - t_i^x)^2 + (s_i^y - t_i^y)^2 + (s_i^z - t_i^z)^2}, \quad (1)$$

natomiast miara odległości między zbiorami jest sumą odległości między odpowiadającymi sobie punktami w obu zbiorach. Graficzna reprezentacja powyższego wzoru pokazana została na rys. 3.




Rys. 3. Metryka punkt-punkt
Fig. 3. Point-to-point metric

3.1.2. Metryka punkt-styczna

Metryka punkt-styczna (ang. *point-to-plane*) [13] jest drugą pod względem popularności, w zastosowaniu do chmur punktów, metryką odległości. Przyjęto oznaczenia: współrzędne punktu chmury źródłowej jako $s_i = (s_i^x, s_i^y, s_i^z, 1)^T$, współrzędne punktu chmury docelowej jako $t_i = (t_i^x, t_i^y, t_i^z, 1)^T$ oraz wektor normalny określony dla punktu chmury docelowej jako $n_i = (n_i^x, n_i^y, n_i^z, 0)^T$. Funkcja odległości definiowana jest jako:

$$d(s_i, t_i) = |(s_i - t_i) \cdot n_i|. \quad (2)$$

Wektor normalny n_i określa wektor prostopadły do płaszczyzny stycznej w punkcie t_i . Jako wynik iloczynu skalarnego wektora zawieszono w punktach s_i oraz t_i z wektorem normalnym n_i otrzymuje się rzutowaną odległość między punktami na wektor normalny. W związku z tym powyższa miara odległości jest interpretowana jako odległość punktu s_i od stycznej w punkcie t_i . Geometryczną interpretację zależności (2) przedstawiono na rys. 4.




Rys. 4. Metryka punkt-styczna
Fig. 4. Point-to-plane metric

3.1.3. Metryka styczna-styczna

Metryka styczna-styczna bazuje na informacjach o wektorach normalnych obu chmur. Przyjęto oznaczenia: współrzędne punktu chmury źródłowej określone są jako $s_i = (s_i^x, s_i^y, s_i^z, 1)^T$, wektor normalny w punkcie s_i jako $n_{s_i} = (n_{s_i}^x, n_{s_i}^y, n_{s_i}^z, 0)^T$, współrzędne punktu chmury docelowej dane są jako $t_i = (t_i^x, t_i^y, t_i^z, 1)^T$, wektor normalny w punkcie t_i jako $n_{t_i} = (n_{t_i}^x, n_{t_i}^y, n_{t_i}^z, 0)^T$. Funkcja odległości kątowej między płaszczyznami stycznymi w punktach (rys. 5) definiowana jest jako:

$$d(s_i, t_i) = \arccos \left(\frac{n_{s_i} \cdot n_{t_i}}{|n_{s_i}| \cdot |n_{t_i}|} \right). \quad (3)$$




Rys. 5. Metryka styczna-styczna
Fig. 5. Plane-to-plane metric

3.1.4. Metryka kwadryka-kwadryka

Metryka kwadryka-kwadryka została zaproponowana w [6]. Przyjęto oznaczenia: współrzędne punktu chmury źródłowej określone są jako $s_i = (s_i^x, s_i^y, s_i^z)$, wektor normalny w punkcie s_i jako $n_{si} = (n_{si}^x, n_{si}^y, n_{si}^z)$, krzywizny główne dla punktu s_i z chmury źródłowej jako $\kappa_{si} = (\kappa_{si}^{\min}, \kappa_{si}^{\max})$, współrzędne punktu chmury docelowej dane są jako $t_i = (t_i^x, t_i^y, t_i^z)$, wektor normalny w punkcie t_i jako $n_{ti} = (n_{ti}^x, n_{ti}^y, n_{ti}^z)$ oraz krzywizny główne dla punktu t_i z chmury docelowej jako $\kappa_{ti} = (\kappa_{ti}^{\min}, \kappa_{ti}^{\max})$. Odległość między kwadrykami w punktach definiowana jest jako:

$$d(s_i, t_i) = \left[\alpha_1 (s_i^x - t_i^x)^2 + \alpha_2 (s_i^y - t_i^y)^2 + \alpha_3 (s_i^z - t_i^z)^2 + \alpha_4 (n_{si}^x - n_{ti}^x)^2 + \alpha_5 (n_{si}^y - n_{ti}^y)^2 + \alpha_6 (n_{si}^z - n_{ti}^z)^2 + \alpha_7 (\kappa_{si}^{\min} - \kappa_{ti}^{\min})^2 + \alpha_8 (\kappa_{si}^{\max} - \kappa_{ti}^{\max})^2 \right]^{1/2} \quad (4)$$

W powyższym wzorze współczynniki α_i , $i = 1, \dots, 8$, wprowadzono w celu normalizacji. Każdy współczynnik równy jest odwrotności różnicy między maksymalną i minimalną wartością zmiennej, którą normalizuje. Na rysunku 6 zobrazowano tylko parametry stosowane we wzorze na odległość, ponieważ trudno zobrazować geometryczną reprezentację wzoru (4).



Rys. 6. Parametry punktów używane do wyznaczenia odległości na podstawie kwadryk
Fig. 6. Quadric-to-quadric metric parameters

3.2. Metryki wykorzystujące informację fotometryczną

Wymienione metryki bazują na geometrycznych atrybutach punktów. W metrykach można również wykorzystać informację fotometryczną, np. kolor (lub intensywność) piksela powiązanego z danym punktem chmury.

Przykładem najprostszej metryki tego typu jest metryka euklidesowa operująca w przestrzeni RGB , bazująca jedynie na podobieństwie kolorów. Przyjęto oznaczenia: atrybuty punktu chmury źródłowej jako $s_i = (s_i^R, s_i^G, s_i^B)$ oraz atrybuty punktu

chmury docelowej jako $t_i = (t_i^R, t_i^G, t_i^B)$. Odległość dana jest równaniem:

$$d(s_i, t_i) = \sqrt{(s_i^R - t_i^R)^2 + (s_i^G - t_i^G)^2 + (s_i^B - t_i^B)^2}. \quad (5)$$

3.3. Metryki bazujące na atrybutach mieszanych

Przykładem metryki korzystającej zarówno z kształtu, jak i koloru, jest metryka zaproponowana w pracy [15], bazująca na współrzędnych punktu oraz odcieniu koloru H z przestrzeni HSV . Przyjęto oznaczenia: współrzędne punktu chmury źródłowej jako $s_i = (s_i^x, s_i^y, s_i^z)$ oraz współrzędne punktu chmury docelowej jako $t_i = (t_i^x, t_i^y, t_i^z)$. Parametr określający odcień koloru H w i -tym punkcie chmury źródłowej oznaczono jako s_i^h , a chmury docelowej jako t_i^h . Funkcja odległości między zbiorami punktów definiowana jest jako:

$$d(s_i, t_i) = \sqrt{(s_i^x - t_i^x)^2 + (s_i^y - t_i^y)^2 + (s_i^z - t_i^z)^2 + (s_i^h - t_i^h)^2}. \quad (6)$$

Warto podkreślić, że próba wykorzystania jednocześnie informacji wymaga odpowiedniej normalizacji składowych wchodzących w skład wektora, na którym operuje metryka. W pracy [15] współrzędne w przestrzeni XYZ oraz parametr określający odcień H zostały uprzednio znormalizowane. Do normalizacji współrzędnych przestrzennych użyto promienia poszukiwań, który jest używany podczas poszukiwania najbliższych sąsiadów punktów. Wartości odcienia natomiast znormalizowano przez podzielenie przez różnicę wartości maksymalnej i minimalnej odcieni występujących w obrazie.

Istnieje również szereg algorytmów, w których problem normalizacji rozwiązano w inny sposób. Jednym z ciekawych rozwiązań jest dwustopniowa asocjacja [12]. W pierwszym kroku znajdowanych jest $k = 25$ sąsiadów najbliższych w przestrzeni XYZ zgodnie z równaniem (1). Następnie spośród znalezionych dopasowań wybierany jest jeden najbliższy sąsiad w przestrzeni koloru RGB , na podstawie odległości danej równaniem (5).

3.4. Metryki operujące na deskryptorach cech punktowych

Wykorzystanie deskryptorów w procesie dopasowania punktów może znacznie polepszyć działanie algorytmu ICP z racji tego, że deskryptory niosą dużo informacji o otoczeniu danego punktu kluczowego, a parowanie punktów pod względem podobieństwa jest tym bardziej sensowne im więcej parametrów porównujemy. Wykorzystanie deskryptorów świetnie sprawdza się m.in. w wizualnej odometrii.

Niech $s_i = (s_i^1, \dots, s_i^N)$ oznaczają elementy deskryptora i -tego punktu chmury źródłowej, natomiast $t_i = (t_i^1, \dots, t_i^N)$ – elementy deskryptora punktu pochodzącego z chmury docelowej. Odległość w przestrzeni deskryptora cech można najprościej wyrazić za pomocą odległości euklidesowej:

$$d(s_i, t_i) = \sqrt{(s_i^1 - t_i^1)^2 + \dots + (s_i^N - t_i^N)^2}. \quad (7)$$

Warto zauważyć, że powyższa formuła może być stosowana dla różnego rodzaju deskryptorów, zarówno geometrycznych, jak i fotometrycznych. Należy zaznaczyć jednak, że wybór proponowanej metryki nie będzie optymalny dla każdego rodzaju deskryptora – np. dla deskryptorów binarnych lepszym wyborem będzie odległość Hamminga.

Przedstawione analityczne definicje metryk są w istocie dosyć prostymi operacjami na atrybutach par punktów. Czasochłonność obliczeń zależy od liczby punktów, dla których należy

Tabela 2. Zestawienie wybranych wariantów ICP wraz z wykorzystywanymi przez nie atrybutami i metrykami

Table 2. Selection of few ICP variants along with the used attributes and metrics

Wariant ICP	Typ chmury	Atrybut Geometryczny		Atrybut Fotometryczny		Metryka
		Prosty	Deskryptor	Prosty	Deskryptor	
Standard [4]	gęsta	współrzędne	–	–	–	Punkt-punkt (1)
Normalne [5]	gęsta	współrzędne + w. normalne	–	–	–	Punkt-styczna (2)
Kwadryki [6]	gęsta	współrzędne + w. normalne + krzywizny	–	–	–	Kwadryka-kwadrzyka (4)
XYZH [15]	gęsta	współrzędne	–	odcień H	–	Znormalizowana (6)
XYZ+RGB [12]	gęsta	współrzędne	–	RGB	–	Dwukrokowa (1) + (5)
XYZ+SIFT	rzadka	współrzędne	–	–	SIFT	Dwukrokowa (1) + (7)
XYZ+KAZE	rzadka	współrzędne	–	–	KAZE	Dwukrokowa (1) + (7)

Tabela 3. Klasyfikacja badanych obiektów ze względu na ich cechy zewnętrzne

Table 3. Classification of objects due to their appearance features

Obiekt	Kształt	Różnorodność tekstury	Wielkość	Złożoność sceny
Auto	nieregularny	średnia	średni	pojedynczy obiekt
Kartonik po soku	prostokątny	wysoka	mały	pojedynczy obiekt
Kubek	walec	niska	mały	pojedynczy obiekt
Pudełka po herbacie	zbiór prostokątów	wysoka	duży	kilka obiektów

obliczyć daną metrykę oraz od sposobu obliczania atrybutów. Gdy wykorzystywane są deskryptory cech punktowych, czas obliczeń wynika głównie z algorytmu detekcji punktu kluczowego oraz algorytmu ekstrakcji deskryptora.

4. Porównywane warianty ICP

Liczba różnorodnych wariantów ICP praktycznie uniemożliwia porównanie ich wszystkich, nie do końca miałoby również sens, gdyż istnieje szereg prac analizujących i porównujących działanie poszczególnych, wybranych wersji ICP. Przykładowo, dobre porównanie wariantów operujących na prostych atrybutach geometrycznych można znaleźć w [17]. W prezentowanym tu opracowaniu postanowiono porównać kilka wybranych wariantów ICP bazujących na różnych atrybutach (a w konsekwencji na różnych rodzajach chmur punktów). W szczególności, z uwagi na dobre wyniki dwukrokowej asocjacji (XYZ+RGB) [12] postanowiono przyjąć to rozwiązanie jako punkt wyjścia. Jednak zamiast prostych atrybutów typu składowe koloru RGB wykorzystano złożone atrybuty w postaci deskryptorów. Dla uzupełnienia zaprezentowano również wyniki standardowego ICP działającego jedynie na współrzędnych kartezjańskich punktów. Do porównania wybrano więc następujące cztery warianty ICP:

- Standard – wykorzystujący metrykę czysto geometryczną – odległość euklidesowa w przestrzeni XYZ, zgodnie z równaniem (1), zarówno podczas parowania punktów, jak i w minimalizacji funkcji błędu. Algorytm realizuje obliczenia na gęstej chmurze punktów.
- XYZ+RGB – wykorzystujący prostą metrykę mieszaną: geometryczną i fotometryczną. Wariant ten opisany został w sekcji 3.3. Parowanie dopasowań jest dwukrokowe: w pierwszym kroku znajdowanych jest $k = 25$ sąsiadów najbliższych w przestrzeni XYZ według równania (1) a następnie spośród tych punktów wybierany jest jeden najbliższy sąsiad w przestrzeni koloru RGB za pomocą miary odległości danej równaniem (5). Algorytm realizuje obliczenia na gęstej chmurze punktów.
- XYZ+SIFT – podczas parowania punktów wykorzystuje się również dwukrokową asocjację danych. Najpierw wybieranych jest $k = 5$ najbliższych sąsiadów w przestrzeni XYZ, a spośród nich wybierany jest jeden najbliższy deskryptor w odległości w przestrzeni deskryptorów SIFT, danej równaniem (7) przy $N = 128$. Algorytm realizuje obliczenia na rzadkiej chmurze punktów.
- XYZ+KAZE – wariant jest analogiczny do wariantu SIFT, z tym że w drugim kroku asocjacji danych korzysta z deskryptorów KAZE. Odległość wyznaczana jest na podstawie równania (7) przy $N = 64$, w dwukrokowej asocjacji analogicznie jak dla SIFT. Algorytm również realizuje obliczenia na rzadkiej chmurze punktów.

Rzadka chmura cech tworzona jest dla każdego widoku na podstawie cech lokalnych wyekstrahowanych z obrazu RGB. Współrzędne znalezionych punktów kluczowych są następnie przetwarzane do współrzędnych kartezjańskich przez wykorzystanie informacji z mapy głębi skojarzonej z obrazem RGB.

Cecha SIFT została wybrana z uwagi na fakt, iż jest uważana za jedną z najlepszych (pod kątem odporności, powtarzalności itp.) cech ekstrahowanych z obrazów. Natomiast z zaprezentowanych przez autorów KAZE badań wynika, iż cechy te są bardziej odporne na zniekształcenia i zakłócenia od cech SIFT. Celem jest sprawdzenie, czy zastosowanie tego algorytmu da lepsze efekty również w procesie rejestracji.

5. Metodyka badań

5.1. Zbiór testowy

Porównanie różnych wersji algorytmu ICP wymagało odpowiedniej metodyki badań, obejmującej m.in. wykorzystanie właściwego zbioru testowego. Widoki, które postanowiono zastosować w eksperymentach, pochodzą ze zbioru sekwencji obrazów WUT VPD¹ (ang. *Visual Perception Dataset*) [19]. Podczas testów wykorzystano widoki zebrane za pomocą czujnika Kinect dla kilku różnych obiektów. Wybrano cztery zbiory widoków: dziecięcą zabawkę – auto *auto_1_kinect*, kartonik po soku *vega_1_kinect*, kubek *kubek_1_kinect* oraz pudełko po herbatce *teas_1_kinect*. W tabeli 3 zawarto klasyfikację wybranych obiektów ze względu na ich cechy zewnętrzne. Poszczególne zbiory widoków dla badanych obiektów składały się z 12 widoków zebranych pod różnymi kątami. Przykładowe widoki analizowanych obiektów z kamery RGB przedstawiono na rys. 7. Średnia liczba punktów wygenerowanych z poszczególnych




Rys. 7. Przykładowe widoki dla wybranych obiektów ze zbiorów *auto_1_kinect*, *vega_1_kinect*, *kubek_1_kinect*, *teas_1_kinect*
 Fig. 7. One of the views of the selected object from the *auto_1_kinect*, *vega_1_kinect*, *kubek_1_kinect*, *teas_1_kinect* datasets

widoków w przypadku chmur gęstych wynosiła po kilka tysięcy punktów, natomiast w przypadku chmur rzadkich (cech) nie przekraczała 300 punktów. Testy powtarzano dziesięciokrotnie dla każdego z wybranych wariantów ICP oraz każdego widoku ze zbioru.

Dla każdego widoku obiektu wygenerowano dwie chmury. Pierwsza z nich pozostawała niezmienną, natomiast drugą poddawano transformacji z wykorzystaniem znanej macierzy jednorodnej H_p . Oryginalna chmura punktów stanowiła chmurę źródłową, natomiast jej transformowana kopia była traktowana

jako chmura docelowa (patrz rys. 8 oraz sekcja 3. *Iterative Closest Point* w pierwszej części artykułu). Chmura docelowa była następnie dodatkowo zaszumiana. W ten sposób określono prawidłową postać macierzy transformacji H_{odn} , będącej odwrotnością macierzy H_p .

Wybrane cztery warianty ICP przetestowano dla jednej zadanej transformacji, określonej parametrami translacji $t_x = t_y = t_z = 5$ mm oraz kątami Eulera $\alpha = \beta = \gamma = 0,1$ rad. Wprowadzona transformacja jest mała, głównie ze względu na fakt, iż postanowiono pominąć krok szacowania transformacji wstępnej. Pozwoliło to na bardziej dokładne porównanie działania algorytmów ICP, gdyż błąd oszacowania transformacji



Rys. 8. Weryfikacja poprawności zbieżności działania ICP: transformacje między chmurami źródłową (lewa) a docelową (prawa)
 Fig. 8. Verification of the ICP convergence: transformations between source (left) and target (right) point clouds

wstępnej mogłaby w znaczący sposób wpływać na wyniki dla różnych wariantów algorytmu.

5.2. Wprowadzanie szumu

Podczas badań zaszumiano zarówno położenie w przestrzeni XYZ, jak i skorelowaną informację fotometryczną. Zaszumienie współrzędnych XYZ polegało na zaburzaniu pozycji losowych 10% punktów chmury docelowej i źródłowej przez dodanie wartości wylosowanych z rozkładu normalnego ze średnią $\mu = 0$ mm oraz odchyleniem standardowym $\sigma = 5$ mm. Zaszumienie informacji fotometrycznej, w przypadku korzystania w asocjacji z cech SIFT i KAZE, polegało na zaburzaniu obrazu jasności rozkładem normalnym o parametrach $\sigma = 10$, $\mu = 0$. Obrazy jasności, z których ekstrahowane były cechy dla chmury źródłowej, zaburzano oddzielnie od obrazów wykorzystywanych do utworzenia chmury docelowej. W ten sposób cechy tworzące źródłową i docelową rzadką chmurę różniły się od siebie. Dla wariantu XYZ+RGB zaburzano 50% punktów chmur źródłowej i docelowej w przestrzeni RGB, przy wykorzystaniu rozkładu normalnego o wartościach parametrów danych jako $\sigma = 5$, $\mu = 0$.

5.3. Weryfikacja poprawności

Jednym ze sposobów sprawdzenia poprawności algorytmów było wyznaczenie przekształcenia H_{error} między macierzą H_{ICP} otrzymana w wyniku działania algorytmu ICP a macierzą odniesienia H_{odn} według wzoru:

$$H_{error} = H_{ICP}^{-1} \cdot H_{odn} \quad (8)$$

Ideę tę pokazano na rys. 8. Na podstawie otrzymanej macierzy homogenicznej H_{error} wyznaczono błędy transformacji:

$$\Delta H_{error} = [\Delta R, \Delta t] \quad (9)$$

gdzie błąd translacji Δt jest długością wektora translacji, a błąd kąta obrotu ΔR wyznaczono w reprezentacji oś – kąt na podstawie macierzy rotacji. Ponieważ szukana transformacja między chmurami jest w praktyce transformacją między wyznaczonymi centrami tych chmur, błąd translacji oraz kąt obrotu można

¹ <http://robotyka.ia.pw.edu.pl/datasets/>

interpretować kolejno jako odległość między centrami chmur punktów oraz obrót między nimi.

Druga metoda analizy i porównania działania wariantów algorytmów ICP polegała na wyznaczeniu średniego błędu kwadratowego między odpowiadającymi sobie punktami z obu rejestrowanych chmur punktów. Metoda ta ma sens tylko wtedy, gdy obie chmury są identyczne, w przeciwnym razie nie jest znane prawidłowe parowanie punktów. W celu spełnienia tego warunku, niezależnie od warunków działania algorytmu (z zaszumieniem czy bez), odległości liczone były na niezaszumionych, gęstych chmurach punktów. W przypadku wariantów ICP **Standard** i **XYZ+RGB** chmury te stanowiły niezaszumiona kopie chmury źródłowej i docelowej. W przypadku algorytmów ICP korzystających z cech SIFT oraz KAZE, chmury te były niezaszumionymi chmurami gęstymi skojarzonymi z tym samym widokiem, co źródłowa i docelowa chmura rzadka.

Dodatkowo mierzono następujące średnie parametrów działania: liczba iteracji i , czas działania algorytmu t_{ICP} , czas wyznaczania cechy t_c w przypadku wykorzystania cech KAZE i SIFT. W celu uzyskania pełniejszego obrazu podano również średnią liczbę punktów w chmurze p .

6. Wyniki

W tabelach 4–7 zamieszczono wyniki wariantów ICP przy zastosowaniu zaszumienia informacji geometrycznej i fotometrycznej. Błąd translacji między dopasowanymi chmurami był praktycznie tego samego rzędu (10^{-2} mm) dla wariantów **Standard**, **XYZ+RGB** i **XYZ+KAZE**. Wariant **XYZ+SIFT** charakteryzował się błędem translacji o jeden rząd wielkości większym w porównaniu do pozostałych algorytmów. Błąd kąta obrotu był najmniejszy dla wariantu **Standard** oraz **XYZ+RGB** i wynosił około 1° w przypadku każdego badanego obiektu. Dla wariantu **XYZ+SIFT** oraz **XYZ+KAZE** błąd ten był nieco większy i mieścił się w przedziale $2-4^\circ$ dla auta, kartonika po soku i kubka. W przypadku prostej sceny błąd kąta obrotu dla wariantów korzystających z cech SIFT i KAZE wynosił prawie 7° .

Średnia liczba iteracji była największa, w większości przypadków, dla wariantu **Standard**, jednak warianty **XYZ+RGB** oraz **XYZ+SIFT** charakteryzowały się jedynie nieznacznie mniejszą liczbą iteracji. Najlepiej pod tym względem wypadł algorytm **XYZ+KAZE**, który potrzebował od 13 do 33 iteracji do osiągnięcia zadowalającego wyniku. Efektywny czas działania algorytmów był największy dla wariantu **XYZ+RGB** i wynosił minimum jedną sekundę. Dla prostej sceny wariant kolorowy potrzebował aż 4,5 s do osiągnięcia minimum. Najszybszy pod względem czasu działania okazał się wariant **XYZ+SIFT**, którego efektywny czas działania wynosił tylko 0,25–0,36 s.

Histogramy wartości średniokwadratowego błędu odległości dla zaszumienia informacji geometrycznej i fotometrycznej przedstawiono na rysunkach 9–12. Na wykresach tych można zauważyć, że wariant **XYZ+RGB** dał najlepsze rezultaty dla każdego badanego obiektu – co najmniej 53% wyników trafiło do przedziału 0,1–1 mm, a tylko 43–45% do przedziału 1–10 mm. Nieco gorsze rezultaty otrzymano dla wariantu **Standard**, dla którego w przypadku każdego badanego obiektu ponad 47% wyników osiągnęło wartości z przedziału 0,1–1 mm, a około 50% z przedziału 1–10 mm. Warianty **XYZ+KAZE** i **XYZ+SIFT** uzyskały różne wartości błędu średniokwadratowego odległości uzależnione od rodzaju obiektu. Wyniki zarówno dla wariantu **XYZ+KAZE**, jak i **XYZ+SIFT** były najlepsze dla prostej sceny – zbioru pudełek po herbatach. W przypadku **XYZ+KAZE** aż 50% wartości mieściło się w przedziale 0,1–1 mm, a pozostałe 50% w przedziale 1–10 mm. Dla wariantu **XYZ+SIFT** oraz prostej sceny około 1% wartości należało do przedziału 0,001–0,1 mm, 44% do przedziału 0,1–1 mm, ponad 53% do przedziału 1–10 mm, natomiast niemal 2% do przedziału ponad 10 mm. Najgorsze rezultaty oba warianty **XYZ+KAZE** i **XYZ+SIFT** osiągnęły w przypadku kubka, co wynika wprost z małej różnorodności tekstury tego obiektu. Tylko 32,5% wyników dla wariantu **XYZ+KAZE** i 23,33% w przypadku **XYZ+SIFT** osiągnęło wartości z przedziału 0,1–1 mm, natomiast oba warianty miały minimum 10% wartości powyżej 10 mm. Dla pozostałych obiektów: auta i pudełka po soku wyniki dla zaproponowanych wariantów osiągały podobne wartości (nieco lepsze jednak dla pudełka po soku) uwzględniając, że wariant **XYZ+KAZE** osiągał najlepsze wyniki.

Tabela 4. Porównanie wariantów algorytmu ICP dla auta przy zaszumieniu informacji geometrycznej i fotometrycznej


Table 4. Comparison of different ICP flavours for noising geometric and fotometric information

Wariant ICP	Typ chmury	p	Δt [mm]	ΔR [°]	i	t_{ICP} [s]	t_c [s]	t_{sum} [s]
Standard	Gęsta	2890,08	$3,29 \cdot 10^{-2}$	1,00	34,67	0,58	–	0,58
XYZ+RGB	Gęsta	2890,08	$1,57 \cdot 10^{-2}$	1,21	29,22	1,22	–	1,22
XYZ+SIFT	Rzadka	66,17	$1,53 \cdot 10^{-1}$	3,82	35,97	0,0282	0,2209	0,25
XYZ+KAZE	Rzadka	51,33	$8,95 \cdot 10^{-2}$	3,18	32,71	0,0200	0,3085	0,33

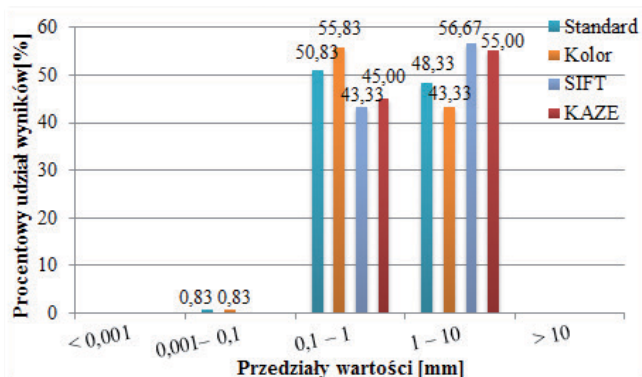
Tabela 5. Porównanie wariantów algorytmu ICP dla pudełka po soku przy zaszumieniu informacji geometrycznej i fotometrycznej

Table 5. Comparison of different ICP flavours for noising geometric and fotometric information

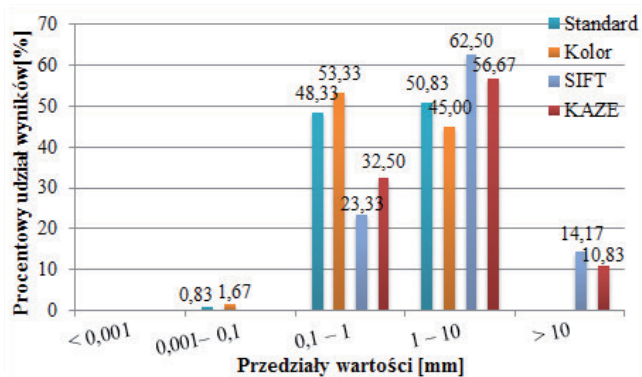
Wariant ICP	Typ chmury	p	Δt [mm]	ΔR [°]	i	t_{ICP} [s]	t_c [s]	t_{sum} [s]
Standard	Gęsta	4175,33	$4,56 \cdot 10^{-2}$	1,02	47,68	1,06	–	1,06
XYZ+RGB	Gęsta	4175,33	$1,52 \cdot 10^{-2}$	1,08	37,83	2,16	–	2,16
XYZ+SIFT	Rzadka	136,25	$1,21 \cdot 10^{-1}$	3,18	32,63	0,0431	0,1999	0,24
XYZ+KAZE	Rzadka	92,67	$8,66 \cdot 10^{-2}$	2,48	16,03	0,0137	0,2857	0,30




Rys. 9. Przedziały wartości średniokwadratowego błędu odległości dla auta przy zasumieniu informacji geometrycznej i fotometrycznej
Fig. 9. Mean squared error intervals for noising geometric and fotometric information



Rys. 10. Przedziały wartości średniokwadratowego błędu odległości dla pudełka po soku przy zasumieniu informacji geometrycznej i fotometrycznej
Fig. 10. Mean squared error intervals for noising geometric and fotometric information



Rys. 11. Przedziały wartości średniokwadratowego błędu odległości dla kubka przy zasumieniu informacji geometrycznej i fotometrycznej
Fig. 11. Mean squared error intervals for noising geometric and fotometric information



Rys. 12. Przedziały wartości średniokwadratowego błędu odległości dla prostej sceny przy zasumieniu informacji geometrycznej i fotometrycznej
Fig. 12. Mean squared error intervals for noising geometric and fotometric information

Tabela 6. Porównanie wariantów algorytmu ICP dla kubka przy zasumieniu informacji geometrycznej i fotometrycznej
Table 6. Comparison of different ICP flavours for noising geometric and fotometric information

Wariant ICP	Typ chmury	p	Δt [mm]	ΔR [°]	i	t_{ICP} [s]	t_c [s]	t_{sum} [s]
Standard	Gęsta	3313,83	$3,01 \cdot 10^{-2}$	1,08	42,68	0,78	–	0,78
XYZ+RGB	Gęsta	3313,83	$2,51 \cdot 10^{-2}$	1,44	34,66	1,63	–	1,63
XYZ+SIFT	Rzadka	54,42	$4,06 \cdot 10^{-1}$	6,42	22,51	0,0127	0,2016	0,21
XYZ+KAZE	Rzadka	46,33	$3,48 \cdot 10^{-2}$	6,88	13,42	0,0070	0,2743	0,28

Tabela 7. Porównanie wariantów algorytmu ICP dla prostej sceny przy zasumieniu informacji geometrycznej i fotometrycznej
Table 7. Comparison of different ICP flavours for noising geometric and fotometric information

Wariant ICP	Typ chmury	p	Δt [mm]	ΔR [°]	i	t_{ICP} [s]	t_c [s]	t_{sum} [s]
Standard	Gęsta	9888,35	$4,89 \cdot 10^{-2}$	0,52	48,66	2,81	–	2,81
XYZ+RGB	Gęsta	9888,35	$8,60 \cdot 10^{-3}$	0,63	34,40	4,50	–	4,50
XYZ+SIFT	Rzadka	267,55	$1,55 \cdot 10^{-1}$	2,14	35,15	0,0886	0,2677	0,36
XYZ+KAZE	Rzadka	188,38	$4,60 \cdot 10^{-2}$	1,52	21,82	0,0357	0,3579	0,39

Należy dodać, że podczas analizowania kubka część widoków została odrzucona z powodu niewystarczającej liczby znalezionych dopasowań (mniej niż 3 znalezione dopasowania). Dla wariantu **XYZ+SIFT** odrzucono 27 widoków, natomiast dla wariantu **XYZ+KAZE** odrzucono 10 widoków ze 120 badanych.

Wyniki potwierdziły tezę, iż wykorzystanie cech KAZE da lepsze rezultaty od cech SIFT z uwagi na ich większą odporność na zaszumienie. Jednak to wariant **XYZ+RGB** osiągał najmniejsze błędy translacji oraz rotacji, w praktyce działał on jednak o wiele wolniej od wariantów **XYZ+SIFT** czy **XYZ+KAZE**. Wariant **XYZ+KAZE** stanowi pewnego rodzaju kompromis między najszybciej działającym wariantem **XYZ+SIFT**, a najdokładniejszym pod względem błędów translacji i rotacji wariantem **XYZ+RGB**.

7. Podsumowanie

Celem dwuczęściowego artykułu było przybliżenie czytelnikowi problematyki rejestracji chmur punktów. W pierwszej części przedstawiono komponenty typowego systemu służącego do rejestracji trójwymiarowych modeli sceny z sekwencji widoków oraz zogniskowano uwagę na algorytmie ICP, stanowiącym jeden z kluczowych elementów tego rodzaju systemów. Algorytm ICP jest bardzo elastyczny w swoich założeniach, dzięki czemu może bazować na różnego typu danych wejściowych, wykorzystywać różnego rodzaju przetwarzanie wstępne, metody asocjacji lub algorytmy optymalizacji.

W drugiej części artykułu skupiono uwagę na asocjacji danych, zaprezentowano oraz omówiono klasyfikację atrybutów punktów oraz zaprezentowano szereg operujących na tych atrybutach metryk. Przedstawiono również wyniki eksperymentów służących do porównania kilku wariantów algorytmu ICP. Wyniki dla nowo utworzonych wariantów wykorzystujących cechy SIFT oraz KAZE pokazały, że wykorzystanie cech lokalnych obrazu w iteracyjnej rejestracji chmur punktów może znacznie przyspieszyć generowanie modeli, niestety kosztem dokładności dopasowania. Należy pamiętać, że z uwagi na fotometryczny charakter tych atrybutów zaproponowane warianty będą najlepiej działały dla obiektów o bogatej, różnorodnej teksturze, co potwierdziły wyniki eksperymentów.

Warto zauważyć, iż wybrane warianty stanowią mały podzbiór opracowanych przez ostatnie dwie dekady różnych wersji tego algorytmu. Dlatego też w pracy zaproponowano kryteria podziału, wywiedzione z opracowanej klasyfikacji atrybutów punktów chmury, które nie tylko umożliwiają klasyfikację istniejących wariantów ICP, ale również wskazanie wariantów, których zbadanie wydaje się sensowne (np. ICP operujących na deskryptorach geometrycznych).

Oczywiście zaproponowane kryteria nie wyczerpują tematu, gdyż dotyczą w istocie dwóch kroków: asocjacji danych oraz kryterium stopu. Przykładowo, w [16] zaproponowano kryterium podziału wykorzystywanych metod optymalizacji. Opracowanie spójnej taksonomii algorytmów rejestracji jest jednym z kierunków dalszych badań.

Podziękowania

Autorzy pragną podziękować redakcji oraz recenzentom kwartalnika *Pomiary Automatyka Robotyka* za szereg uwag, których uwzględnienie w znacznym stopniu podniosło jakość obu części artykułu. Szczególne podziękowania należą się Panu Profesorowi Piotrowi Skrzypczyńskiemu (Politechnika Poznańska), z którym konsultowano zawartość merytoryczną prezentowanego materiału oraz polską nomenklaturę.

Bibliografia

1. Alahi A., Ortiz R., Vanderghenst P., *FREAK: Fast Retina Keypoint*. 2012 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 510–517, IEEE, 2012.
2. Alcantarilla P.F., Bartoli A., Davison A.J., *KAZE features*. European Conference on Computer Vision (ECCV), 2012, 214–227, DOI: 10.1007/978-3-642-33783-3_16.
3. Belongie S., Malik J., Puzicha J., *Shape matching and object recognition using shape contexts*. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 24, Iss. 4, 2002, 509–522, DOI: 10.1109/34.993558.
4. Besl P., McKay N., *A method for registration of 3-D shapes*. "IEEE Transactions on Pattern Analysis and Machine Intelligence", 14(2):239–256, 1992.
5. Chen Y., Medioni G., *Object modelling by registration of multiple range images*, 1991 IEEE International Conference on Robotics and Automation, Proceedings Vol. 3, 2724–2729.
6. Feldmar J., Ayache N., *Rigid, affine and locally affine registration of free-form surfaces*. "International Journal of Computer Vision", Vol. 18, Iss. 2, 1996, 99–119, DOI: 10.1007/BF00054998.
7. Figat J., Kornuta T., Kasprzak W., *Performance evaluation of binary descriptors of local features*. [in:] Proceedings of the International Conference on Computer Vision and Graphics, Vol. 8671, *Lecture Notes in Computer Science*, Springer Berlin /Heidelberg, 2014, 187–194, DOI: 10.1007/978-3-319-11331-9_23.
8. Frome A., Huber D., Kolluri R., Bülow T., Malik J., *Recognizing objects in range data using regional point descriptors*. European Conference on Computer Vision (ECCV), 2004, 224–237, 10.1007/978-3-540-24672-5_18.
9. Hänsch R., Weber T., Hellwich O., *Comparison of 3D interest point detectors and descriptors for point cloud fusion*. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. II-3, 2014, 57–64, DOI: 10.5194/isprsannals-II-3-57-2014.
10. Holz D., Ichim A.E., Tombari F., Rusu R.B., Behnke S., *Registration with the point cloud library – A modular framework for aligning in 3-D*. "IEEE Robotics & Automation Magazine", 22(4):110–124, 2015, DOI: 10.1109/MRA.2015.2432331.
11. Kornuta T., Łepicka M.J., *Rejestracja chmur punktów: komponenty systemu*. „Pomiary Automatyka Robotyka”, R. 21, Nr 1, 2017, 19–24, DOI: 10.14313/PAR_223/19.
12. Łepicka M., Kornuta T., Stefańczyk M., *Utilization of Colour in ICP-based Point Cloud Registration*, [in:] Proceedings of the 9th International Conference on Computer Recognition Systems CORES 2015. Advances in Intelligent Systems and Computing, Vol. 403. Springer International Publishing, 2016, 821–830, DOI: 10.1007/978-3-319-26227-7_77.
13. Low K.-L., *Linear Least-Squares Optimization for Point-to-Plane OCP Surface Registration*, Technical Report TR04-004, 2004, 1–3.
14. Lowe D., *Object recognition from local scale-invariant features*. The Proceedings of the Seventh IEEE International Conference on Computer Vision, 1999, Vol. 2, 1150–1157.
15. Men H., Gebre B., Pochiraju K., *Color point cloud registration with 4D ICP algorithm*. 2011 IEEE International Conference on Robotics and Automation (ICRA), 1511–1516, DOI: 10.1109/ICRA.2011.5980407.
16. Pomerleau F., Colas F., Siegwart R., *A review of point cloud registration algorithms for mobile robotics*. Foundations and Trends in Robotics, 4(1):1–104, 2015, DOI: 10.1561/23000000035.

17. Rusinkiewicz S., Levoy M., *Efficient variants of the ICP algorithm*. Third International Conference on 3-D Digital Imaging and Modeling, Proceedings, 145–152, IEEE, 2001, DOI: 10.1109/IM.2001.924423.
18. Rusu R.B., Blodow N., Beetz M., *Fast point feature histograms (FPFH) for 3D registration*. IEEE International Conference on Robotics and Automation, ICRA '09, 3212–3217. IEEE, 2009, DOI: 10.1109/ROBOT.2009.5152473.
19. Stefanczyk M., Laszkowski M., Kornuta T.. *WUT Visual Perception Dataset – a dataset for registration and recognition of objects*. [in:] Szewczyk R., Zieliński C., Kaliczyńska M. (eds) Challenges in Automation, Robotics and Measurement Techniques. Advances in Intelligent Systems and Computing, Vol. 440. Springer 2016, 635–645 DOI: 10.1007/978-3-319-29357-8_55.
20. Tombari F., Salti S., Di Stefano L., *Unique signatures of histograms for local surface description*. Proceedings of the 11th European Conference on Computer Vision Conference on Computer Vision: Part III, ECCV '10, 356–369, Berlin, Heidelberg, 2010. Springer-Verlag.
21. Tuytelaars T., Mikolajczyk K., *Local invariant feature detectors: a survey*. Foundations and trends in computer graphics and vision, Vol. 3, Iss. 3, 2008, 177–280, DOI: 10.1561/0600000017.

Registration of RGB-D images: comparison of pairwise registration variants

Abstract: The two-part article focuses on the problem of registration of point clouds. The first part briefly discussed the main components of V-SLAM systems and presented the main steps of the ICP (Iterative Closest Point) algorithm. In the following, second part of the paper, we analyse and compare diverse variants of the ICP algorithm. In particular, we discuss different attributes of points along with operating on them metrics that the ICP can employ. Finally, we present the research methodology and discuss the results of comparison of selected variants of ICP.

Keywords: RGB-D image, point cloud, pairwise registration, ICP, SIFT, KAZE

mgr inż. Marta Jolanta Łepicka

marta.lepicka@gmail.com

Absolwentka kierunku Informatyka na Wydziale Elektroniki i Technik Informatycznych Politechniki Warszawskiej. W ramach prac inżynierskiej i magisterskiej zajmowała się badaniami nad algorytmami łączenia chmur punktów wykorzystującymi zarówno informację geometryczną (kształt), jak i fotometryczną (tekstura). Jej aktywność naukowa w trakcie studiów zaowocowała udziałem w szeregu grantów badawczych oraz otrzymaniem stypendium Rektora Politechniki Warszawskiej za Wyjątkowe Osiągnięcia Naukowe, a także dwoma Głównymi Nagrodami w organizowanym przez Instytut PIAP ogólnopolskim konkursie „Młodzi Innowacyjni”: w ramach kategorii „Najlepsza Praca Dyplomowa Inżynierska” w 2015 r. oraz „Najlepsza Praca Dyplomowa Magisterska” w 2017 r. Jej zainteresowania naukowe obejmują wizję komputerową, przetwarzanie obrazów, uczenie maszynowe oraz systemy inteligentne.



dr inż. Tomasz Kornuta

tkornuta@gmail.com

Absolwent Wydziału Elektroniki i Technik Informatycznych Politechniki Warszawskiej. W 2003 r. uzyskał tytuł inżyniera, w 2005 r. tytuł magistra inżyniera, a w 2013 r. stopień doktora nauk technicznych. W latach 2008–2015 pracował w Instytucie Automatyki i Informatyki Stosowanej, początkowo jako asystent, potem jako adiunkt, dodatkowo od 2009 r. pełni funkcję kierownika Laboratorium Podstaw Robotyki. Od października 2015 r. przebywa na stażu post doktorskim w ośrodku IBM Research – Almaden, prowadząc badania nad wykorzystaniem technik sztucznej inteligencji i uczenia maszynowego w percepcji wizyjnej. Jego zainteresowania naukowe obejmują metody programowania robotów, architektury układów sterowania robotów, percepcję wizyjną (w szczególności trójwymiarową z wykorzystaniem czujników RGB-D) oraz sztuczną inteligencję i uczenie maszynowe. Autor/współautor 70+ publikacji dotyczących powyższych tematów. Organizator szeregu sesji specjalnych poświęconych tym tematom, recenzent krajowych oraz międzynarodowych konferencji i czasopism. Uczestnik kilkunastu projektów badawczych, w tym dwóch grantów europejskich oraz grantu finansowanego przez agencję DARPA.

