

Filtracja chmur punktów za pomocą dopasowania danych 2D-3D

Karol Rzepka, Michał Kulczykowski, Paweł Wittels

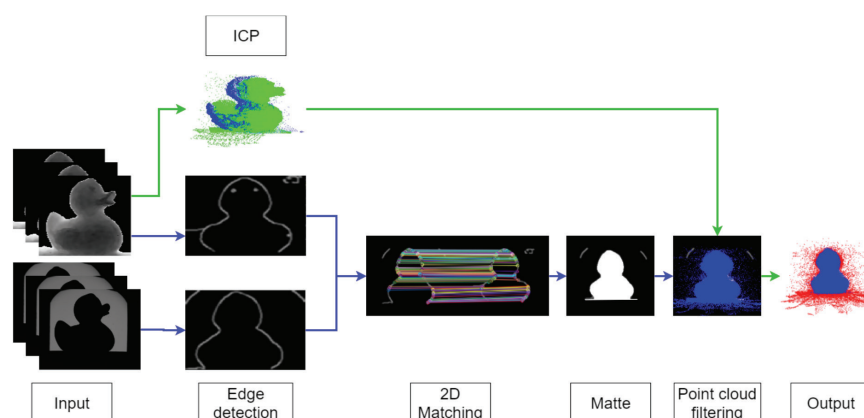
Avicon, Al. Jerozolimskie 202, 02-486 Warszawa

Streszczenie: Precyzja jest cechą kluczową dla rozwoju systemów pomiarowych 3D. Wykorzystywane do takich pomiarów kamery Time-of-Flight tworzą chmury punktów zawierające dużo szumu, przez co mogą się okazać mało użyteczne w dalszej analizie. W ramach badań nad rozwiązaniem tego problemu proponujemy nową metodę precyzyjnego filtrowania chmur punktów. Do usuwania punktów odstających z pomiarów 3D, zarejestrowanych za pomocą kamery Time-of-Flight, wykorzystujemy informacje 2D z kamery z obiektywem telecentrycznym. Zastosowanie kamery telecentrycznej pozwala uzyskać najbardziej precyzyjną informację o konturze obiektu, co przekłada się na precyzyjne filtrowanie rekonstrukcji obiektu w 3D.

Słowa kluczowe: chmury punktów 3D, filtracja chmur punktów, dopasowanie 2D

1. Wprowadzenie

Przemysł nieustannie ewoluuje, a klienci systemów kontroli jakości wymagają coraz bardziej szczegółowych pomiarów. W zaawansowanych systemach kontroli jakości wykorzystanie klasycznej analizy obrazów 2D może okazać się niewystarczające [1]. Informację o głębokości jest w stanie wyznaczyć wiele urządzeń pomiarowych dostępnych na rynku, takich jak kamery stereowizyjne, systemy fotogrametryczne, skanery laserowe i kamery ToF (ang. *Time-Of-Flight*) [26]. Tego rodzaju sensory rejestrują chmury punktów [32], które mogą zawierać duże ilości szumu [36]. Występowanie takiego problemu może być spowodowane przez wiele czynników, między innymi przez błędy kwantyzacji czy warunki oświetleniowe i temperaturowe otoczenia (punkt 1.1). Problemy te w przypadku niektórych systemów mogą uniemożliwiać przeprowadzenie poprawnej analizy. Do rozwiązania problemu zaszumionych pomiarów 3D powszechnie próbuje się stosować algorytmy filtracji, które na bazie analizy lokalnego otoczenia poszczególnych punktów, starają się zidentyfikować punkty odstające (ang. *outliers*) – nienależące do skanowanego obiektu



Rys. 1. Uproszczony schemat działania zaproponowanej metody – niebieskie strzałki przedstawiają operacje na danych 2D, a zielone na danych 3D

Fig. 1. Simplified diagram of the proposed method. Blue arrows represent operations on 2D data while green arrows represent operations on 3D data. See text for details

lub algorytmy wykorzystujące dodatkowe informacje z wyspecjalizowanych kamer [39].

W pracy skupiono się na drugim podejściu: do odfiltrowania punktów odstających z chmury uzyskanej za pomocą kamery Time-of-Flight wykorzystujemy obraz z dodatkowej kamery z obiektywem telecentrycznym. Zaprojektowany i skonstruowany system rejestruje obrazy głębokości, które pozwalają na rekonstrukcję obiektu w 3D, oraz obrazy 2D, które są wykorzystywane do filtracji chmury punktów. Wykorzystana do akwizycji 2D kamera z obiektywem telecentrycznym pozwala na uzyskanie idealnej reprezentacji kształtu obiektu na obrazie. Obiekt poddawany analizie jest obracany w trakcie akwizycji, a obie kamery zbierają dane w tym samym położeniu względem obiektu.

Uproszczony schemat działania filtracji został przedstawiony na rys. 1. Na początku zostają pobrane dane 2D z kamery telecentrycznej oraz dane 3D z kamery ToF. Na wygenerowanych chmurach punktów zostaje przeprowadzona rekonstrukcja 3D

Autor korespondujący:

Paweł Wittels, pawel.wittels@avicon.pl

Artykuł recenzowany

nadesłany 21.03.2022 r., przyjęty do druku 10.06.2022 r.



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

poprzez rotację każdej chmury o znany kąt (obrotu stolika między kolejnymi akwizycjami) oraz dopasowanie chmur z wykorzystaniem algorytmu ICP. Na obrazach z kamery z obiektywem telecentrycznym oraz na mapach głębi z chmur punktów zostaje przeprowadzona detekcja krawędzi. Na wynikowych obrazach zawierających krawędzie zostają wykryte punkty charakterystyczne. Deskryptory ORB tych punktów są następnie ze sobą porównywane między odpowiadającymi sobie obrazami z kamery telecentrycznej i z kamery ToF. Wynikiem dopasowania jest przekształcony obraz krawędziowy z kamery telecentrycznej. Na to przekształcenie zostaje następnie rzutowana chmura punktów (oznaczona kolorem niebieskim). Punkty tej chmury, znajdujące się poza przekształconymi krawędziami, zostają oznaczone jako punkty odstające (oznaczone kolorem czerwonym).

1.1. Błędy w pomiarach kamerami Time-of-Flight

Błędy systematyczne w pomiarach kamerami ToF są konsekwencją:

- kwantyzacji pomiarów [10],
- zmian temperatury urządzenia pomiarowego [2],
- kąta padania wiązki lasera na przeszkodę [11],
- koloru i właściwości powierzchni przeszkody (np. refleksyjności) [2, 11, 37],
- warunków oświetleniowych [11],
- szumu generowanego przez urządzenie dokonujące akwizycji [18].

Oprócz błędów systematycznych, w pomiarach kamerami ToF występują także błędy losowe (ang. *flying pixels*) [12], pojawiające się w miejscach braku ciągłości powierzchni – między krawędzią jednej powierzchni a powierzchnią znajdującą się w tle, kiedy na ten sam piksel matrycy kamery ToF pada światło odbite z dwóch różnych punktów znajdujących się w różnej odległości od sensora [28]. W takim przypadku, zmierzona odległość (punkt chmury) wypada gdzieś między jedną powierzchnią a drugą.

2. Powiązane prace

2.1. Filtrowanie chmur punktów

Filtracja, obok m.in. dopasowania składowych chmur punktów, jest jednym z kluczowych etapów przetwarzania chmur punktów 3D. Jej celem jest oczyszczenie pomiarów 3D z szumów, czyli tzw. punktów odstających. Pozwala uzyskać lepszą dokładność wyników, dlatego techniki filtracji podlegają ciągłym badaniom i ulepszeniom. Do technik filtracji chmur punktów 3D zalicza się [3, 8, 33] metody statystyczne, metody bazujące na sąsiedztwie, metody bazujące na projekcji oraz metody oparte o uczenie maszynowe.

Chmury punktów zawierają cechy, które sprawiają, że z powodzeniem mogą zostać do nich zastosowane metody statystyczne. W pracy [34] wykonano obliczenia prawdopodobieństwa wystąpienia punktu p_i w zaszumionej chmurze punktów. Następnie wykorzystując podejście iteracyjne, wygładzono chmurę punktów, co pozwoliło uzyskać dobre wyniki w filtrowaniu punktów odstających. Wadą tej metody jest destrukcja „ostrych” cech powierzchni: zaokrąglanie ostrych krawędzi czy też usuwanie lokalnych „szpilek”. Innym podejściem jest wykorzystanie statystyki Bayesowskiej. W pracy [16] zaproponowano funkcję modelującą rozkład prawdopodobieństwa między estymowaną i zmierzoną chmurą punktów. Następnie ta funkcja była maksymalizowana w celu usunięcia szumu. Wadą również tej metody jest zaokrąglanie ostrych krawędzi.

Metody oparte na sąsiedztwie wykorzystują informacje o punktach bezpośrednio sąsiadujących z danym punktem z chmury punktów. Najbardziej podstawową metodą jest wykorzystanie filtra bilateralnego 3D [29]. Inne metody polegają na przepro-

wadzeniu filtrowania w dwóch krokach: w pierwszym następuje usunięcie punktów odstających, a w drugim wygładzenie szumu. Te techniki wykorzystują modyfikacje algorytmów takich jak: *mean shift* [13] lub *non-local means filter* [15] z różnymi dodatkowymi źródłami danych: wektorami normalnymi oraz kolorem.

Trzecia grupa metod obejmuje podejścia wykorzystujące specjalne operatory nazywane LOP (ang. *Locally Optimal Projection*). Po raz pierwszy raz przedstawiono je w pracy [20], następnie starano się je ulepszyć [14, 19], przeprowadzając modyfikację wag. W pracy [35] zaproponowano metodę, w której do usuwania punktów odstających i wygładzania chmur punktów wykorzystano wykrywanie płaszczyzn stycznych. Zaletą tej metody jest zachowywanie ostrych krawędzi i płaszczyzn, przez co dobrze nadaje się do rekonstrukcji naturalnych scen.

W kolejnej pracy [38] zaproponowano nowatorską metodę automatycznej (niewymagającej dostrajania parametrów) filtracji chmur punktów w oparciu o uczenie maszynowe. Autorzy traktują rzeczywistość, zarejestrowaną chmurę punktów jako zbiór punktów, będący wynikiem transformacji idealnego zbioru punktów, z których każdy przesunięty został o pewien wektor szumu. Zaproponowane podejście wykorzystuje sieci neuronowe do wyznaczenia tych wektorów szumu. Rozwiązanie bazuje na architekturze enkoder-dekoder. Sieć, nazwana *Pointfilter*, przyjmuje na wejściu surowy punkt wraz z jego otoczeniem (punktami sąsiadującymi) i wyznacza wektor przemieszczenia zaszumionego punktu do jego „prawdziwej” pozycji. Funkcja strat zaprojektowana została tak, aby lokalne cechy charakterystyczne nie były przez tę sieć wygładzane. Metoda ta cechuje się wysoką precyzją, nie degradując jednocześnie ostrych krawędzi.

2.2. Dopasowanie 2D

W literaturze znajduje się wiele prac dotyczących algorytmów dopasowania danych 2D. Te najbardziej znane wykorzystują algorytm najbliższych sąsiadów, przykładowo korzystając z dystansu Mahalanobisa [17, 25]. Podejście to ewoluowało do kilku ulepszonych wersji [23, 24], a te najnowsze zaczynają wykorzystywać sieci neuronowe [22]. Obecnie kładzie się nacisk na określanie coraz lepszych deskryptorów punktów oraz na znajdowanie punktów najbardziej charakterystycznych. Mimo to, powszechnie stosowane deskryptory, takie jak SIFT [21], ORB [31] oraz SURF [4], wciąż dają zadowalające wyniki. Proces dopasowania 2D może być jednak bardzo wymagający, szczególnie jeżeli w zdjęciach zachodzą duże zmiany w oświetleniu oraz gdy zmienia się punkt widzenia obserwatora. W takich przypadkach stosuje się bardziej zaawansowane deskryptory lub narzędzia do określania cech, wykorzystujące sztuczne sieci neuronowe [7, 27]. W poniższej pracy zostały przetestowane trzy wspomniane wcześniej deskryptory: SIFT, ORB oraz SURF. Za pomocą ORB udało się uzyskać najlepsze wyniki, dlatego tylko ten deskryptor przedstawiamy.

2.3. Deskryptor ORB

ORB jest połączeniem detektora FAST [30] znajdowania punktów charakterystycznych oraz zoptymalizowanego binarnego deskryptora na bazie BRIEF, którego koszt obliczeniowy jest o dwa rzędy wielkości mniejszy niż popularnego SIFT [31]. Najpierw używa detektora FAST do odnajdowania tzw. narożników (punktów charakterystycznych), a następnie stosuje miarę odpowiedzi narożnika (ang. *measure of corner response*), aby znaleźć N najważniejszych punktów wśród wykrytych. Zastosowanie piramid umożliwia detekcję oraz tworzenie deskryptorów cech niezależnych od skali. Następnie obliczona zostaje ważona intensywność centroidu wycinka z narożnikiem znajdującym się w jego środku. Kierunek wektora od tego punktu wskazującego do środka ciężkości określa jego orientację. Aby poprawić niezmiennosć względem obrotu, momenty są obliczane za pomocą x i y , które powinny znajdować się w okręgu o promieniu r , gdzie r jest rozmiarem wycinka. Algorytm BRIEF

nie jest odporny na zmianę orientacji punktów kluczowych. ORB dyskretyzuje pełny obrót na 30 części, każda o wielkości 12 stopni i tablicuje policzone wzorce BRIEF dla każdego kąta. Tak długo jak orientacja punktu kluczowego jest spójna między obrotami, poprawny zestaw punktów zostanie użyty do wyliczenia jego deskryptorów.


3. Prezentowana metoda

W prezentowanej w niniejszym artykule metodzie wykorzystywane są dane z dwóch różnych źródeł: z kamery Basler Time-of-Flight ToF640-20gm_850nm oraz z monochromatycznej kamery matrycowej Basler z obiektywem telecentrycznym Opto Engineering TC16M096. Z tego powodu przedstawiana metoda została podzielona na dwa etapy: przetwarzanie obrazów 2D oraz przetwarzanie chmur punktów 3D.

3.1. Akwizycja obrazów

Mierzony obiekt umieszczono na środku stolika obrotowego tak, aby mógł być on precyzyjnie obrócony o dowolny kąt wokół osi obrotu stolika (rys. 2). Obok stolika zamocowano kolejno oba sensory skierowane w kierunku środka obrotu. Rozstaw kątowy pomiędzy sensorami wynosi 60°. W trakcie pomiaru, dla danego położenia zatrzymanego stołu, wykonywane są dwa niezależne pomiary każdym z sensorów. Następnie stół obracany jest o stały kąt, który powinien stanowić podwielokrotność kąta 60°, co pozwala na późniejsze dopasowanie obrazów rejestrowanych kamerą telecentryczną do chmur punktów zarejestrowanych kamerą ToF z tego samego położenia każdego z sensorów względem obracanego obiektu. Proces ten jest powtarzany aż do osiągnięcia pełnego obrotu obiektu. W przypadku opisywanych badań, obiekt obracano również co 60°, co pozwoliło zarejestrować po sześć obrazów z każdego z sensorów.

Aby możliwie zredukować liczbę nieistotnych artefaktów w chmurze punktów (punktów pochodzących spoza obszaru pomiarowego), ograniczono głębłą pomiarową kamery ToF.



Rys. 2. Schemat stanowiska pomiarowego (widok z góry): obiekt skanowany kamerą ToF znajduje się na stoliku obrotowym. Po obrocie o 60°, z tej samej perspektywy rejestrowany jest obraz obiektu za pomocą kamery z obiektywem telecentrycznym
Fig. 2. Diagram of the measurement setup (top view): the object to be scanned with the ToF camera is placed on a rotary table. After a 60 degree rotation, an image of the object is captured from the same perspective using a camera with a telecentric lens

Kamera telecentryczna dostarcza obrazy 2D w skali szarości, podczas gdy kamera ToF rejestruje mapę głębi (ang. *depth map*), przeliczaną następnie do chmury punktów 3D.


3.2. Obróbka danych wejściowych

Z map głębi, otrzymanych z kamery ToF, zostają wyznaczone chmury punktów na podstawie zbioru równań (1), gdzie I reprezentuje zbiór pikseli mapy głębi, d – wartości graniczne głębi, a f_x oraz f_y reprezentują długość ogniskowej odpowiednio dla osi X oraz Y .

$$\begin{aligned} z &= I(u, v) / 0xFFFF \cdot (d_{max} - d_{min}) + d_{min} \\ x &= u \cdot z / f_x \\ y &= v \cdot z / f_y \end{aligned} \quad (1)$$

Otrzymane chmury punktów zostają wstępnie obrócone względem ich środka o odpowiadającą wielokrotność zastosowanego kąta obrotu, który w omawianym przykładzie wynosił 60°.

Zbrane obrazy z obu kamer zostają sprowadzone do tej samej rozdzielczości poprzez przeskalowanie obrazu z kamery telecentrycznej. Pozwala to uprościć transformacje przeprowadzane w kolejnych krokach. Następnie, aby na tych obrazach znajdowały się te same zestawy cech, zostaje na obu z nich przeprowadzona operacja detekcji krawędzi Canny [6] (rys. 3).



Rys. 3. Kolejne etapy przetwarzania obrazu z kamery telecentrycznej: obraz surowy (po lewej), wykrycie krawędzi zoptymalizowanym detektorem Canny (w środku) oraz maska obiektu (po prawej stronie)
Fig. 3. Successive processing steps of the telecentric camera image: raw image (left), edge detection with the optimized Canny detector (center), and object mask (right)

3.3. Dopasowanie obrazów oraz chmur punktów

Na etapie dopasowania zostają rozdzielone dwa równoległe procesy: dopasowania danych 2D oraz dopasowania elementarnych chmur 3D (rys. 1).

3.3.1. Dopasowanie chmur 3D

Każda z elementarnych chmur punktów 3D zostaje obrócona o kąt odpowiadający położeniu stolika względem kamery ToF podczas jej akwizycji – tzn. dokonana jest ich transformacja do wspólnego układu współrzędnych. Następnie przy użyciu algorytmu ICP (ang. *Iterative Closest Point*), chmury te zostają kolejno dopasowane do siebie, tworząc jedną globalną chmurę punktów – precyzyjnie dopasowaną, ale obciążoną szumem (punktami odstającymi).

Podstawowym algorytmem wykorzystywanym do dopasowania chmur punktów jest algorytm ICP [5]. Pozwala on zniwelować pewne niedokładności wynikające z ograniczonej precyzji enkodera stolika, luzów na przekładni czy ograniczonej precyzji względnego rozmieszczenia sensorów. W praktyce, dla dużych chmur punktów i dla większych wstępnych transformacji (dla większych błędów wstępnego wzajemnego dopasowania) między dopasowywanymi chmurami, proces dopasowania chmur algorytmem ICP jest bardzo kosztowny obliczeniowo. Aby temu przeciwdziałać, wykorzystuje się wstępne dopasowanie chmur. Jako wstępne dopasowanie stosujemy rotację każdej chmury o wielokrotność kąta 60°, ponieważ o taki kąt obracany był skanowany obiekt między kolejnymi etapami akwizycji. Dopiero po tej operacji zostaje wykorzystany algorytm ICP w celu precyzyjnego dopasowania chmur. Chmura wynikowa, składająca się

ze wszystkich chmur elementarnych, przedstawia pełny obiekt wraz z wieloma punktami odstającymi, które mogą w znacznym stopniu niekorzystnie wpływać na wyniki dalszego przetwarzania oraz analizy pomiaru.


3.3.2. Dopasowanie obrazów 2D

Każdy obraz z kamery ToF, przedstawiony w postaci mapy głębi, zostaje dopasowany do odpowiadającego mu obrazu z kamery telecentrycznej. W tym celu konieczne jest wyznaczenie macierzy transformacji obrazu z kamery telecentrycznej do obrazu z kamery ToF. Jest to wymagane, ponieważ należy usunąć wszystkie problemy wynikające z nieidealnej akwizycji. Dopasowanie przeprowadzamy na obrazach krawędzi, uzyskanych poprzez zastosowanie filtra *Canny* zarówno na obrazie z kamery telecentrycznej jak i na mapie głębi z ToF. Następnie wykorzystujemy algorytm ORB do wyznaczenia na każdym z obrazów krawędziowych punktów charakterystycznych i ich deskryptorów. Dla punktów charakterystycznych opisanych deskryptorami ORB zostają znalezione dopasowania do najbliższych (najbardziej podobnych) deskryptorów punktów z drugiego obrazu. Niepoprawne dopasowania zostają wykryte i odfiltrowane przy zastosowaniu algorytmu RANSAC (ang. *Random sample consensus*) [9] z progiem reprojektacji (ang. *reprojection threshold*) wynoszącym pięć pikseli. Znalezione dopasowania pozwalają wyznaczyć macierz homograficzną, która pozwala na przeprowadzenie transformacji obrazu krawędziowego z kamery telecentrycznej do obrazu z kamery ToF. Przekształcony obraz zostaje następnie wykorzystany jako maska, za pomocą której przeprowadza się odfiltrowanie odstających punktów w chmurze.

Dzięki zastosowaniu tak wyznaczonej macierzy transformacji homograficznej obrazu z kamery telecentrycznej do przestrzeni z kamery ToF, system nie wymaga przeprowadzania kalibracji.



3.4. Filtracja chmury punktów

Kontur obiektu, w postaci obrazu krawędziowego z kamery telecentrycznej, po transformacji do przestrzeni obrazu z ToF,



Rys. 4. Filtracja chmury punktów dla kolejnych widoków. Punkty w kolorze niebieskim są przekazywane do następnego kroku filtracji; punkty w kolorze czerwonym zostają usunięte z chmury

Fig. 4. Point cloud filtering of subsequent views. Blue points are transferred to the next filtering step; red points are removed from the cloud



Rys. 5. Wykres (a) pokazuje jak liczba punktów w chmurze maleje wraz z każdym kolejnym krokiem filtracji. Wykres (b) pokazuje jak wraz z kolejnym krokiem filtracji rośnie precyzja

Fig. 5. Graph (a) shows how the number of points in the cloud decreases with each successive filtering step. Graph (b) shows how the precision increases with each successive filtering step

zostaje wypełniony stałym kolorem. Powstały obraz binarny jest wykorzystany jako maska do odfiltrowania globalnej chmury punktów. Złożona chmura punktów utworzona według algorytmu z poprzedniego podrozdziału jest rzutowana bezpośrednio na maskę. Projekcja chmury na obraz jest operacją odwrotną do przekształcenia obrazu głębi do chmury punktów, dlatego można ją przeprowadzić wykorzystując znane wzory oraz parametry kamery, którą została wykonana akwizycja. Wszystkie punkty rzutowanej chmury, które znajdują się w obszarze wykraczającym poza maskę, zostają odrzucone.

Cała operacja zostaje powtórzona dla każdego zdjęcia otrzymanego z kamery telecentrycznej, za każdym razem obracając chmurę o kąt rotacji odpowiadający danemu zdjęciu przed projekcją. Pozwala to odrzucić punkty, które nie są widoczne z różnych widoków (przykładowo wykonując filtrację jedynie z jednego widoku, punkty odstające znajdujące się za obiektem nie zostaną usunięte). Wynik filtracji przykładowego obiektu został przedstawiony na rys. 4.

4. Wyniki

W ramach przeprowadzonych badań wykonano akwizycję pomiarów skanowanego obiektu w sześciu położeniach co 60°. Jak można zauważyć na rezultacie filtracji z rys. 4, wykorzystanie kilku widoków pozwala odfiltrować punkty odstające, które na pojedynczym widoku mogły znajdować się w obrębie maski. Warto zauważyć, że najwięcej punktów zostaje usuniętych przy pierwszej operacji filtrowania (przy filtracji z pierwszego widoku), co również widać wyraźnie na wykresie 5(a).

Do oceny poprawności filtracji punktów odstających za pomocą naszej metody wykorzystaliśmy model 3D zabawkowej kaczuszki – obiektu, którego fizyczny egzemplarz wytworzony z gumy został zeskanowany na opisanym stanowisku pomiarowym. Ta sama chmura punktów, złożona za pomocą algorytmu ICP z sześciu elementarnych pomiarów z kamery ToF, została poddana filtracji punktów odstających – za pomocą metody wykorzystującej dodatkową kamerę telecentryczną oraz za pomocą metod referencyjnych.

Jedną z miar, która pozwala określić, jak dobrze działa filtracja, jest precyzja. Pozwala ona określić, jaka część odfiltrowanych punktów jest tymi właściwymi. Właściwe punkty

to te, które znajdują się w bliskiej odległości od modelu referencyjnego. Równanie (2) przedstawia definicję precyzji:

$$Precyzja = \frac{TP}{TP + FP}, \tag{2}$$

gdzie: TP – true positive – punkty poprawnie zaklasyfikowane jako należące do obiektu, FP – false positive – punkty niepoprawnie zaklasyfikowane jako należące do obiektu.

Dla porównania użyliśmy dwóch powszechnie stosowanych metod filtracji punktów odstających. Pierwszą z nich jest statystyczne odrzucanie¹, które polega na liczeniu średniej i odchylenia standardowego odległości punktu do jego sąsiadów. Przy założeniu rozkładu gaussowskiego tej miary, odrzucane są te punkty, których średnia odległość od sąsiadów jest powyżej średniej i powyżej odchylenia standardowego dla wszystkich punktów chmury. Druga metoda to odrzucanie radialne², które polega na odrzucaniu punktów, które zawierają niewielką liczbę sąsiadów wewnątrz sfery o zdefiniowanym promieniu, której środkiem jest dany punkt. Na wykresie 5(b) widać jak precyzja naszej metody rośnie wraz z kolejnym krokiem filtracji.

Dla każdej metody porównano również liczbę punktów, które mieszczą się w pewnej stałej, niewielkiej odległości od modelu referencyjnego. Punkty, które leżą poza tą odległością uznano za false positive a te, które leżą wewnątrz – za true positive. Na bazie tego wyliczono precyzję zgodnie ze wzorem (2). Wyniki umieszczono w tabeli 1.

Tabela 1. Precyzja zaproponowanej metody filtracji (*) oraz metod referencyjnych
Table 1. Precision of the proposed filtering method (*) compared to reference methods

Metoda	Dopasowanie 2D-3D*	Statystyczne odrzucanie	Radialne odrzucanie
Precyzja	0,701	0,485	0,495

Porównaliśmy również jaka jest średnia i mediana odległości punktów w chmurze do najbliższego sąsiada na modelu referencyjnym dla punktów odfiltrowanych przy pomocy naszej metody i metod referencyjnych.

Jako ostatnią metodę odniesienia użyliśmy chmury punktów odfiltrowanych poprzez usunięcie z pierwotnej chmury punktów położonych poza pewną odległością od modelu referencyjnego. W tabeli 2 widać wartości średnie oraz mediany odległości dla tych trzech metod.

Tabela 2. Porównanie zaproponowanej metody filtracji (*) z metodami referencyjnymi: średnia i mediana odległości punktów chmury od najbliższego sąsiadującego punktu na modelu referencyjnym
Table 2. Comparison of the proposed filtering method (*) with reference methods: mean and median distances of points of a given cloud to the nearest neighboring point on the reference model

Metoda	Dopasowanie 2D-3D*	Statystyczne odrzucanie	Radialne odrzucanie
Średnia odległość	3,913	6,194	6,463
Mediana odległości	3,097	4,658	4,557

5. Podsumowanie

W ramach niniejszej pracy opisano nowatorską metodę filtracji punktów odstających z zaszumionych chmur przy zastosowaniu dodatkowego sensora w postaci kamery z obiektywem telecentrycznym. Może ona znaleźć zastosowanie w szczególności

w warunkach laboratoryjnych, gdzie obiekty mierzone mogą być umieszczane na stole obrotowym. Z uwagi na swoją specyfikę, bazującą na porównaniu chmury z konturem obiektu, metoda nie pozwala na filtrację obszarów wklęsłych, znajdujących się w zagłębieniach powierzchni.

W ramach dalszego rozwoju planujemy przeprowadzić badania z wykorzystaniem innych sensorów głębi, np. skanerów laserowych. Planowane są również badania, które pozwolą wyznaczyć optymalną liczbę elementarnych skanów, potrzebną do uzyskania najlepszych wyników. Badania będą prowadzone na zróżnicowanych obiektach pomiarowych, o bardziej skomplikowanym kształcie, zmierzonym również za pomocą innych technik pomiarowych.

Podziękowania

System jest rozwijany w ramach projektu „System do pomiarów i analizy wymiarów wielkogabarytowych produktów metodami wizji maszynowej 2D/3D” dofinansowanego z Regionalnego Programu Operacyjnego Województwa Mazowieckiego.

Bibliografia

1. Al-Yoonus M., Abdullah M.F.L., Jawad M.S., Al-Shargie F., *Enhance quality control management for sensitive industrial products using 2D/3D image processing algorithms*, [In:] Electrical Power, Electronics, Communications, Control and Informatics Seminar (EECCIS), 2014, 126–131, DOI: 10.1109/EECCIS.2014.7003732.

2. Baek E.-T., Yang H.-J., Kim S., Lee G., Jeong H., *Distance error correction in time-of-flight cameras using asynchronous integration time*, “Sensors”, Vol. 20, No. 4, 2020, DOI: 10.3390/s20041156.

3. Balta H., Velagic J., Bosschaerts W., De Cubber G., Siciliano B., *Fast statistical outlier removal based method for large 3D point clouds of outdoor environments*, IFAC-PapersOnLine”, Vol. 51, No. 22, 2018, 348–353, 12th IFAC Symposium on Robot Control SYROCO 2018, DOI: 10.1016/j.ifacol.2018.11.566.

4. Bay H., Ess A., Tuytelaars T., Van Gool L., *Speeded-up robust features (SURF)*, “Computer Vision and Image Understanding”, Vol. 110, No. 3, 2008, 346–359, DOI: 10.1016/j.cviu.2007.09.014.

5. Besl P., McKay N.D., *A method for registration of 3-D shapes*, “IEEE Transactions on Pattern Analysis and Machine Intelligence”, Vol. 14, No. 2, 1992, 239–256, DOI: 10.1109/34.121791.

6. Canny J., *A computational approach to edge detection*, “IEEE Transactions on Pattern Analysis and Machine Intelligence”, Vol. PAMI-8, No. 6, 1986, 679–698, DOI: 10.1109/TPAMI.1986.4767851.

7. DeTone D., Malisiewicz T., Rabinovich A., *SuperPoint: Self-supervised interest point detection and description*, [In:] The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, June 2018.

8. Duan Y., Yang C., Li H., *Low-complexity adaptive radius outlier removal filter based on PCA for lidar point cloud denoising*, “Applied Optics”, Vol. 60, No. 20, 2021, E1–E7, DOI: 10.1364/AO.416341.

9. Fischler M.A., Bolles R.C., *Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography*, “Communications of the ACM”, Vol. 24, No. 6, 1981, 381–395, DOI: 10.1145/358669.358692.

10. Frank M., Plaue M., Rapp H., Köthe U., Jähne B., Hamprecht F., *Theoretical and experimental error analysis of continuous-wave time-of-flight range cameras*, “Optical Engineering”, Vol. 48, No. 1, 2009, DOI: 10.1117/1.3070634.

1 z parametrami: liczba sąsiadów = 1000; std_ratio = 0,3
2 z parametrami: liczba sąsiadów = 100; promień = 8,0

11. He Y., Liang B., Zou Y., He J., Yang J., *Depth errors analysis and correction for time-of-flight (ToF) cameras*, "Sensors", Vol. 17, No. 1, 2017, DOI: 10.3390/s17010092.
12. Hoegg T., Lefloch D., Kolb A., *Time-of-Flight camera based 3D point cloud reconstruction of a car*, "Computers in Industry", Vol. 64, No. 9, 2013, 1099–1114, DOI: 10.1016/j.compind.2013.06.002.
13. Hu G., Peng Q., Forrest A.R., *Mean shift denoising of point-sampled surfaces*, "The Visual Computer", Vol. 22, 2006, 147–157, DOI: 10.1007/s00371-006-0372-0.
14. Huang H., Li D., Zhang H., Ascher U., Cohen-Or D., *Consolidation of unorganized point clouds for surface reconstruction*, "ACM Transactions on Graphics", Vol. 28, No. 5, 2009, DOI: 10.1145/1618452.1618522.
15. Huhle B., Schairer T., Jenke P., Strasser W., *Robust non-local denoising of colored depth data*, [In:] IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops, 2008, DOI: 10.1109/CVPRW.2008.4563158.
16. Jenke P., Wand M., Bokeloh M., Schilling A., Strasser W., *Bayesian point cloud reconstruction*, "Computer Graphics Forum", Vol. 25, No. 3, 2006, 379–388, DOI: 10.1111/j.1467-8659.2006.00957.x.
17. Johansen S., Juselius K., *Maximum likelihood estimation and inference on cointegration—with applications to the demand for money*, "Oxford Bulletin of Economics and Statistics", Vol. 52, No. 2, 1990, 169–210.
18. Leal E., Leal N., *Point cloud denoising using robust principal component analysis*, 2006, 51–58, DOI: 10.5220/0001358900510058.
19. Liao B., Xiao C., Jin L., *Efficient Feature-preserving Local Projection Operator for Geometry Reconstruction*, [In:] Eurographics 2011 – Short Papers, Avis N., Lefebvre S., eds., The Eurographics Association, DOI: 10.2312/EG2011.short.013-016.
20. Lipman Y., Cohen-Or D., Levin D., Tal-Ezer H., *Parameterization-free projection for geometry reconstruction*, "ACM Transactions on Graphics", Vol. 26, No. 3, 2007, DOI: 10.1145/1276377.1276405.
21. Lowe D.G., *Object recognition from local scale-invariant features*, [In:] Proceedings of the 7th IEEE International Conference on Computer Vision, 1999, DOI: 10.1109/ICCV.1999.790410.
22. Melekhov I., Tiulpin A., Sattler T., Pollefeys M., Rahtu E., Kannala J., *DGC-Net: Dense geometric correspondence network*, 2018, DOI: 10.48550/arXiv.1810.08393.
23. Muja M., Lowe D.G., *Fast matching of binary features*, [In:] Ninth Conference on Computer and Robot Vision, 2012, 404–410, DOI: 10.1109/CRV.2012.60.
24. Muja M., Lowe D.G., *Scalable nearest neighbor algorithms for high dimensional data*, "IEEE Transactions on Pattern Analysis and Machine Intelligence", Vol. 36, No. 11, 2014, DOI: 10.1109/TPAMI.2014.2321376.
25. Muthukrishnan S., Sahinalp S.C., *Simple and practical sequence nearest neighbors with block operations*, [In:] Proceedings of the 13th Annual Symposium on Combinatorial Pattern Matching, 2002, 262–278, DOI: 10.5555/647821.736373.
26. Park J., Kim H., Yu-Wing Tai, Brown M. S., Kweon I., *High quality depth map upsampling for 3D-TOF cameras*, [In:] International Conference on Computer Vision, 2011, 1623–1630, DOI: 10.1109/ICCV.2011.6126423.
27. Revaud J., Weinzaepfel P., Harchaoui Z., Schmid C., *Deep-Matching: Hierarchical deformable dense matching*, "International Journal of Computer Vision", Vol. 120, 2016, 300–323, DOI: 10.1007/s11263-016-0908-3.
28. Reynolds M., Doboš J., Peel L., Weyrich T., Brostow G.J., *Capturing Time-of-Flight data with confidence*, [In:] CVPR 2011, 945–952, DOI: 10.1109/CVPR.2011.5995550.
29. Rosli N.A.I.M., Ramli A., *Mapping bootstrap error for bilateral smoothing on point set*, [In:] AIP Conference Proceedings, Vol. 1605, No. 1, 2014, 149–154, DOI: 10.1063/1.4887580.
30. Rosten E., Drummond T., *Fusing points and lines for high performance tracking*, [In:] 10th IEEE International Conference on Computer Vision, Vol. 1, 2005, 1508–1515, DOI: 10.1109/ICCV.2005.104.
31. Rublee E., Rabaud V., Konolige K., Bradski G.R., *ORB: An efficient alternative to SIFT or SURF*, [In:] International Conference on Computer Vision, 2011, 2564–2571, DOI: 10.1109/ICCV.2011.6126544.
32. Rusu R.B., Cousins S., *3D is here: Point cloud library (PCL)*, [In:] IEEE International Conference on Robotics and Automation, 2011, 1–4, DOI: 10.1109/ICRA.2011.5980567.
33. Schall O., Belyaev A. G., Seidel H.-P., *Adaptive feature-preserving non-local denoising of static and time-varying range data*, "Computer-Aided Design", Vol. 40, No. 6, 2008, 701–707, DOI: 10.1016/j.cad.2008.01.011.
34. Schall O., Belyaev A., Seidel H.-P., *Robust filtering of noisy scattered point data*, [In:] Proceedings Eurographics/IEEE VGTC Symposium Point-Based Graphics, 2005, 71–144, DOI: 10.1109/PBG.2005.194067.
35. Wang J., Yu Z., Zhu W., Cao J., *Feature-preserving surface reconstruction from unoriented, noisy point data*, "Computer Graphics Forum", Vol. 32, No. 1, 2013, 164–176, DOI: 10.1111/cgf.12006.
36. Xie H., McDonnell K.T., Qin H., *Surface reconstruction of noisy and defective data sets*, [In:] IEEE Visualization, 2004, 259–266, DOI: 10.1109/VISUAL.2004.101.
37. Zaman F., Wong Y.-P., Ng B.-Y., *Density-based denoising of point cloud*, [In:] Proceeding of 9th International Conference on Robotics, Vision, Signal Processing & Power Applications (ROVISP), 2016, DOI: 10.48550/arXiv.1602.05312.
38. Zhang D., Lu X., Qin H., He Y., *Pointfilter: Point cloud filtering via encoder-decoder modeling*, "IEEE Transactions on Visualization and Computer Graphics", Vol. 27, 2021, 2015–2027, DOI: 10.1109/TVCG.2020.3027069.
39. Zhao J., Wang Y., Cao Y., Guo M., Huang X., Zhang R., Dou X., Niu X., Cui Y., Wang J., *The fusion strategy of 2D and 3D information based on deep learning: A review*, "Remote Sensing", Vol. 13, No. 20, 2021, DOI: 10.3390/rs13204029.

Point Cloud Filtering Using 2D-3D Matching Method

Abstract: Precision is a key feature for the development of 3D measurement systems. Time-of-flight cameras used for such measurements create point clouds containing a lot of noise, which may not be useful for further analysis. In our research to solve this problem, we propose a new method for precise point cloud filtering. We use 2D information from a telecentric lens camera to remove outlier points from 3D measurements recorded with a Time-of-Flight camera. The use of a telecentric camera allows us to obtain the most precise information about the contour of an object, which allows us to accurately filter the object reconstruction in 3D.

Keywords: 3D point clouds, point cloud filtering, 2D matching

inż. Karol Rzepka
karol.rzepka@pw.edu.pl
ORCID: 0000-0002-7932-7764

W 2020 r. uzyskał tytuł inżyniera w dyscyplinie informatyka na Wydziale Elektroniki i Technik Informatycznych Politechniki Warszawskiej – specjalność Inżynieria Systemów Informatycznych. Obecnie zajmuje się zagadnieniami w obszarze bezpieczeństwa sieci oraz systemów.



dr inż. Michał Kulczykowski
michal.kulczykowski@avicon.pl
ORCID: 0000-0001-9739-0911

Absolwent Politechniki Gdańskiej na Wydziale Fizyki Technicznej i Matematyki Stosowanej. Obronił tytuł doktora z Fizyki Teoretycznej w Instytucie Fizyki PAN w 2018 r. Aktualnie zajmuje się zagadnieniami uczenia maszynowego w zastosowaniu do wizji i grafów.



mgr inż. Paweł Wittels
pawel.wittels@avicon.pl
ORCID: 0000-0001-7630-6629

Absolwent kierunku Automatyka i Robotyka na Wydziale Inżynierii Produkcji Politechniki Warszawskiej (2011 r.). Pracował m.in. w Przemysłowym Instytucie Automatyki i Pomiarów PIAP oraz PIAP Space. Obecnie pełni rolę kierownika ds. rozwoju oprogramowania w firmie Avicon Advanced Vision Control.

