

POLITECHNIKA OPOLSKA
Wydział Elektrotechniki, Automatyki i Informatyki

Rozprawa doktorska

Mgr inż. Paweł Michalski

**Identyfikacja i rekonstrukcja elementów rurowych
w instalacjach przemysłowych na potrzeby
inventaryzacji**

Promotor:
dr hab. inż. Sławomir Zator, prof. PO

Opole 2014

*Pragnę podziękować wszystkim,
bez których niniejsza praca nie mogła by powstać,
przede wszystkim mojemu promotorowi i mentorowi
Profesorowi Sławomirowi Zatorowi
za wszelką pomoc, jaką udzielił mi
w czasie dotychczasowej współpracy,
a zwłaszcza za cenne uwagi merytoryczne.*

*Pragnę podziękować również kolegom z zespołu
za stworzenie wspaniałej atmosfery naukowej (i nie tylko).*

Dziękuję rodzicom za ciągłe wsparcie i zachętę.

*Pracę dedykuję
mojej ukochanej żonie i synowi.*

Spis treści

1.	<i>Wprowadzenie</i>	6
1.1.	Cel pracy	8
1.2.	Zakres pracy	9
1.3.	Teza pracy	10
2.	<i>Diagnostyka procesów przemysłowych</i>	11
2.1.	Wprowadzenie	11
2.2.	Proces inżynierii rekonstrukcyjnej	12
2.3.	Błędy pomiaru skanerem laserowym	13
2.3.1.	Błędy przyrządu pomiarowego.....	13
2.3.2.	Błędy związane z naturą badanego obiektu.....	16
2.3.3.	Błędy powstałe poprzez wpływ otoczenia podczas wykonywania pomiaru	17
2.3.4.	Błędy metodologiczne	18
2.4.	Badanie skanera laserowego Trimble FX.....	18
2.4.1.	Ogólna charakterystyka skanera	18
2.4.2.	Powtarzalność pomiaru skanerem podczas pomiaru wielokrotnego płaskiej powierzchni	19
2.4.3.	Szacowanie niepewności wybranych typów pomiarów	22
2.5.	Budowa systemu identyfikacji wizualnej	25
2.6.	Podsumowanie.....	26
3.	<i>Możliwości rekonstrukcji obiektów do postaci trójwymiarowych modeli cyfrowych z wykorzystaniem metod przetwarzania obrazu</i>	27
3.1.	Realizowane funkcje.....	27
3.2.	Metody akwizycji danych reprezentujących obiekty 3D	29
3.2.1.	Klasyfikacja stosowanych układów.....	29
3.2.2.	Metody fotogrametryczne.....	30
3.2.3.	Metody skaningowe.....	32
3.2.4.	Metody triangulacyjne jedno i dwuobrazowe	35
3.3.	Metody reprezentacji obiektu	36
3.4.	Podsumowanie rozdziału.....	38
4.	<i>Metody filtracji chmur punktów</i>	38
4.1.	Problem szumu w pomiarach	38
4.2.	Metody bazujące na wartości współczynnika intensywności oraz barwie powierzchni.....	38
4.3.	Filtracja na bazie odległości od skanera	40
4.4.	Filtracja na bazie lokalnego sąsiedztwa.....	40
4.5.	Podsumowanie rozdziału.....	42
5.	<i>Metody segmentacji chmur punktów</i>	42
5.1.	Cel segmentacji i klasyfikacja stosowanych metod	42
5.2.	Metoda rosnących płaszczyzn	43
5.3.	Wykrywanie obszarów o zwiększonej gęstości	45
5.4.	Metoda RANSAC.....	46
5.5.	Transformata Hougha	49
5.5.1.	Ogólny zarys metody	49
5.5.2.	Metoda transformaty Hougha dla obrazów dwuwymiarowych	50
5.5.3.	Metoda transformaty Hougha dla obrazów trójwymiarowych.....	51
5.6.	Podsumowanie rozdziału.....	56
6.	<i>Metoda identyfikacji obiektu wykorzystująca przetwarzanie pojedynczych linii</i>	57
6.1.	Problemy implementacji algorytmów	57
6.2.	Środowisko programistyczne	57

6.3. Ekstrakcja pojedynczej linii z chmury	58
6.4. Segmentacja I poziomu w obrębie jednej linii	64
6.5. Segmentacja II poziomu w obrębie pojedynczego klastra	67
6.6. Proponowana struktura danych	73
6.7. Podsumowanie rozdziału	77
7. <i>Rekonstrukcja obiektu w oparciu o jego model parametryczny</i>.....	77
7.1. Dopasowanie płaszczyzn	77
7.2. Dopasowanie walca	80
7.3. Podsumowanie rozdziału	84
8. <i>Analiza wyników działania opracowanej metody</i>	84
8.1. Realizacja na danych rzeczywistych	84
8.2. Podsumowanie rozdziału i uzyskanych rezultatów	90
9. <i>Podsumowanie i wnioski</i>.....	90
10. <i>Kierunki dalszych badań</i>.....	95
<i>Bibliografia</i>	97
<i>Spis rysunków</i>	105
<i>Spis tabel</i>	107
<i>Streszczenie</i>	108
<i>Abstract</i>	109

Wykaz oznaczeń i skrótów

ρ_r - odległość względna do punktu pomiarowego

r - promień wiązki lasera

r_0 - minimalny promień wiązki lasera

λ_m - długość fali elektromagnetycznej

SNR - stosunek sygnału do szumu

δ_z - dokładność pomiaru odległości

I_d - natężenie światła punktowego źródła światła

k_d - współczynnik odbicia

s_t - liczba minimalnych zbiorów

M_t - parametry modelu

T_{iter} - ilość iteracji wyszukiwania

φ - kąt pomiędzy płaszczyzną XY, a wektorem normalnym w kierunku osi Z

θ - kąt pomiędzy wektorem normalnym, a płaszczyzną XY

r - odległość punktu od początku układu współrzędnych

p - punkt na płaszczyźnie

ω - kąt nachylenia

κ - kąt skręcenia

$R_z(\theta)$ – macierz obrotu

$Rf(\theta, t)$ - transformacja Radona

DSM – Dense surface Modeling

TLS -Terrestrial Laser Scanner

RANSAC - Random Sample Consensus

PCL - Point Cloud Library

LIDAR - Light Detection And Ranging

CSG - Constructive Solid Geometry

kNN – k Nearest Neighbor

RHT - Randomized Hough Transform

SHT - Standardized Hough Transform

PHT - Probabilistic Hough Transform

PPHT - Progressive Probabilistic Hough Transform

1. Wprowadzenie

Zagadnienia dotyczące diagnostyki wrażliwych elementów jak i całości instalacji są zagadnieniem zawsze aktualnym. Wiąże się to z faktem, że niezależnie od specyfiki obiektu zawsze w określonym okresie eksploatacji nastąpi zużycie części czy całych elementów. Istotnym elementem diagnostyki jest umiejętność prognozowania, czyli formułowania ocen prawdopodobnego stanu obiektu na podstawie historycznych obserwacji zmian symptomowych. Podejście takie pozwala określić, które z elementów instalacji zużyją się najszybciej oraz wyznaczyć przybliżony czas ich zużycia. Problemy diagnostyki obiektów i procesów stają się coraz częściej problemami interdyscyplinarnymi, które wymagają wiedzy z takich dziedzin jak eksploatacja i budowa maszyn, automatyka i robotyka, metrologia czy informatyka. Jest to związane ze wzrostem złożoności obiektów, a wymagania dotyczące diagnostyki stają się zagadnieniem coraz bardziej skomplikowanym. Istotnym elementem jest określenie warunków bezpiecznej pracy instalacji. W badaniach stanu technicznego obiektów na ogół wyróżnia się dwie fazy: kontrolę stanu (diagnozowanie ogólne) oraz lokalizację uszkodzeń (diagnozowanie szczegółowe). Warunkiem wysokiego poziomu bezpieczeństwa, a przy tym wysokiej jakości oraz niskiego kosztu utrzymania procesu danej instalacji, jest właśnie społeczna zdolność do prognostycznej oceny stanu [85]. Jest ona rozumiana, jako diagnostyka procesu oraz krytycznego urządzenia z dominującą rolą diagnostyki technicznej oraz opracowanych modeli prognostycznych dla danego obiektu, które wymagają również znajomości z takich dziedzin jak informatyka oraz inżynieria oprogramowania.

Sam proces badania stanu można podzielić na trzy niezależne fazy: detekcji, lokalizacji i identyfikacji [86]. Fazy te wykonywane są w ściśle określonej kolejności. Pierwszym etapem jest detekcja, czyli zauważenie uszkodzenia w obiekcie, następnie następuje lokalizacja, czyli określenie miejsca i czasu wystąpienia uszkodzenia. Ostatnia faza dotyczy już samej identyfikacji.

Pojęcie identyfikacji jest pojęciem różnie interpretowanym przez badaczy z różnych dziedzin. Automatycy identyfikują obiekty określając ich strukturę (identyfikacja strukturalna), która polega na dobraniu takiego modelu, który jak najlepiej odwzoruje badany obiekt. Następnie wykonuje się estymację parametrów modelu (identyfikacja parametryczna) w celu minimalizacji określonej funkcji celu, którą może być np. skrócenie czasu trwania jakiegoś procesu. Badacze zajmujący się diagnostyką obiektów i procesów poprzez identyfikację rozumieją proces, który ma na celu określenie charakteru uszkodzenia, jego rozmiarów oraz zmienności w czasie. Często, aby uściślić znaczenie terminu wykorzystuje się pojęcie identyfikacja uszkodzeń, które jednoznacznie wskazuje na podejście diagnostyczne. Jednym z elementów pracy jest wykorzystanie metod przetwarzania obrazu, w których również wykorzystuje się pojęcie identyfikacji. Interpretowane jest ono, jako wyszukiwanie obiektów o określonej strukturze oraz określaniu parametrów je opisujących. Dobrym przykładem mogą być na przykład systemy identyfikujące osoby w obrazie gdzie każdy człowiek opisany jest macierzą cech charakterystycznych takich jak kontur twarzy, geometria dłoni czy wygląd tęczówki oka [69].

Kolejnym równie istotnym podziałem diagnostyki jest jej podział ze względu na sposób prowadzenia diagnostyki, to czy jest ona wykonywana w sposób ciągły czy cykliczny, wynikający ze specyfiki instalacji. Ten podział wynika najczęściej z czasu powstania instalacji. Nowe instalacje najczęściej wyposażone są w systemy diagnostyczne funkcjonujące od początku ich eksploatacji. Proponowana metoda diagnostyczna, przedstawiona w niniejszej pracy, mieści się w tej grupie metod.

W przypadku maszyn i układów eksploatowanych długotrwale często się je gruntownie remontuje, co nierzadko połączone jest z ich modernizacją. Stąd podział na diagnostykę eksploatacyjną oraz remontową [31]. Specyfika pracy niektórych instalacji, którą można przedstawić np. na podstawie pracy bloku energetycznego w elektrowni często uniemożliwia przeprowadzenie badań (niszczących, nieniszczących, metalograficznych) podczas jej normalnej eksploatacji. Dlatego też podczas okresowego remontu wykonuje się szereg procedur diagnostycznych. Problemem w instalacjach eksploatowanych w długim horyzoncie czasu jest dokładna ewidencja oraz inwentaryzacja poszczególnych elementów składowych, która zdecydowanie ułatwia prowadzenie prac m.in. w zakresie planowania produkcji, planowania polityki konserwacyjno-remontowej oraz oceny bieżącego wykorzystania i zużycia poszczególnych elementów [88].

Przyjmując bardzo ogólny podział diagnostyki można wyróżnić dwie grupy badań. Pierwszą z nich są badania niszczące przeprowadzane na specjalnie przygotowanych próbkach lub gotowych wyrobach, które podczas badań ulegają zniszczeniu. Zwykle badaniu poddane jest do kilka wyrobów. Drugim typem badań są badania nieniszczące, które mają zdecydowanie szersze zastosowanie, jeśli chodzi o instalacje eksploatowane. Szczególne korzystne jest, że w niektórych przypadkach nie wymagają one przerywania procesu technologicznego. Ponadto metody nieniszczące można podzielić na dwie kolejne grupy. Pierwsza grupa pozwala wykryć wady wewnętrzne elementu, np. w przypadku diagnostyki w mechanice rozumiane najczęściej, jako wszelkiego rodzaju nieciągłości wewnątrz materiału np. wtrącenia, pęcherze, czy pęknięcia. W drugiej grupie metod wady wykrywane są na podstawie zewnętrznych cech np. związanych z geometrią obiektu lub deformacją jego powierzchni. Wykorzystuje się tu m.in. systemy wizyjne wykorzystujące metody przetwarzania obrazu do diagnostyki powierzchni [89] [90] [91], które znalazły szerokie zastosowanie w procesach, w których jakość produktu musi spełniać określone normy [20]. Konwencjonalne metody wizyjne aktualnie wspierane są poprzez skanery 3D pozwalające badać geometrię obiektów oraz strukturę ich powierzchni w przestrzeni. Rozwiązania techniczne skanerów w ostatnich latach bardzo się rozwinęły, zarówno pod względem technologicznym samych urządzeń, jak i oprogramowania i metod pozwalających przetwarzać dane ze skanerów. Aktualnie urządzenia skanujące typu laserowego np. RIEGL VZ - 6000 mają relatywnie duży zasięg skanowania (max 6000 m). W wyniku pomiarów uzyskuje się dane w postaci tzw. chmury punktów o współrzędnych kartezyjskich (X,Y,Z) oraz parametrze dodatkowym, jakim jest współczynnik odbicia powierzchni. Chmura punktów pozyskana ze skanera reprezentuje odwzorowanie powierzchni skanowanego obiektu, która może zostać wykorzystana na potrzeby jego diagnostyki. Proces inwentaryzacyjny instalacji z wykorzystaniem skaningu

laserowego znacznie go przyspiesza oferując niepewność pomiaru odległości na poziomie kilku dziesiątych milimetra. Aktualnym problemem do rozwiązania jest ogromna ilość danych często sięgająca kilku milionów punktów uniemożliwiająca przetworzenie danych w relatywnie krótkim czasie pozwalającym na ich wykorzystanie do diagnostyki obiektu.

1.1. Cel pracy

Polityka remontowa i konserwacyjna w przedsiębiorstwie jest procesem wykonywanym cyklicznie. Okres pomiędzy kolejnymi cyklami jest uwarunkowany specyfiką eksploatacji danego obiektu przemysłowego, jednak w większości przypadków jest on stały. Celem niniejszej pracy było opracowanie metodologii pozwalającej na określenie aktualnego stanu geometrii wybranych elementów eksploatowanej instalacji. Współcześnie, wszystkie nowopowstałe obiekty przemysłowe posiadają dokumentację techniczną w postaci cyfrowej. W przypadku instalacji istniejących, już eksploatowanych, proces ich inwentaryzacji jest żmudny i niejednokrotnie obciążony dużymi błędami. Dysponowanie aktualną dokumentacją, zweryfikowaną metrologicznie, jest podstawą nowoczesnej diagnostyki będąc bazą do podejmowania wszystkich decyzji związanych z polityką remontową obiektu. W efekcie końcowym przekłada się to na zmniejszenie nakładów finansowych na remonty.

Drugim aspektem niniejszej pracy jest diagnostyka wrażliwych punktów instalacji, poprzez identyfikację ich stanu oraz cyfrową rekonstrukcję na potrzeby diagnostyki, które ze względu na możliwe duże odkształcenia, względem stanu pierwotnego, powinny być kontrolowane w czasie rzeczywistym.

Głównymi celami niniejszej pracy są:

- Wykorzystanie metod przetwarzania obrazu 2D do przetwarzania obrazów 3D reprezentowanych przez chmury punktów
- Opracowanie metody pozwalającej na przetwarzanie danych rzeczywistych w postaci chmury punktów pod kątem identyfikacji w nich elementów rurowych
- Opracowanie struktury danych pozwalającej na szybkie identyfikowanie wybranych elementów sceny pomiarowej.

Docelowo opracowane oprogramowanie ma na celu wspierać pracę inżynierów oraz osób odpowiedzialnych za nadzorowanie procesu eksploatacji oraz konserwację obiektu.

Opracowana metoda pomiarowa, korzystając z metod przetwarzania obrazu, pozwoli na identyfikację wszystkich obiektów w scenie pomiarowej spełniających kryteria wyszukiwania wprowadzone przez operatora.

Oprogramowanie zostało tak skonstruowane, aby można było rozszerzać jego funkcjonalność o nowe modele.

1.2. Zakres pracy

Niniejsza rozprawa została podzielona na 10 rozdziałów, które obejmują przegląd literatury, możliwości wykorzystania danych ze skanera Trimble FX do zastosowań praktycznych, propozycję wykorzystania metod przetwarzania obrazów 2D do segmentacji chmur punktów oraz badania i przykłady.

W **rozdziale 2** przeprowadzono analizę literatury dotyczącej diagnostyki procesu obejmującej problematykę związaną z identyfikacją obiektu oraz procesem jego rekonstrukcji. Zwrócono uwagę na możliwości wykorzystania metod przetwarzania obrazu na potrzeby diagnostyki. Omówiono możliwe źródła zakłóceń dla wykorzystywanego w pracy skanera laserowego. Przedstawiono porównanie badań literaturowych skanerów innych producentów z skanerem Trimble FX, z którego korzystano podczas badań. Określono możliwe zakresy niepewności pomiaru odległości i współrzędnych, w zależności od odległości badanego obiektu, wykonując szereg badań skanera na bazie zaleceń literaturowych.

Rozdział 3 przedstawia zagadnienia związane z specyfiką danych powstałych w wyniku skanowania laserowego oraz możliwością ich reprezentacji. Przedstawiono również alternatywne możliwości pozyskiwania analogicznych danych przy użyciu innych technik.

Rozdział 4 poświęcony jest metodom filtracji danych skaningowych. Przedstawiono metody najczęściej wykorzystywane opisane w literaturze oraz ich modyfikacje i implementacje wykorzystane na potrzeby opracowanego systemu.

Kolejny **5 rozdział** opisuje proces segmentacji danych oraz jego celowości w przypadku danych pozyskanych ze skanerów. W rozdziale przedstawiono istniejące metody wykorzystywane dla danych skaningowych oraz przykłady ich wykorzystania w opracowanym systemie.

Dla potrzeb niniejszej pracy opracowano i zrealizowano implementację komputerową Transformaty Hougha tak, aby można ją było wykorzystać na potrzeby segmentacji danych skaningowych. Szczegółowy opis zaproponowanego podejścia przedstawiono w **rozdziale 6**.

Rozdział 7 opisuje zaproponowany algorytm i realizację poszczególnych etapów przetwarzania algorytmicznego danych. Na przykładzie działania stworzonego oprogramowania pokazano możliwości identyfikacji obiektu przy użyciu metod przetwarzania obrazu 2D na potrzeby rekonstrukcji obiektów 3D.

W **rozdziale 8** przeprowadzono weryfikację działania metody oraz analizę uzyskanych wyników dla zebranych danych rzeczywistych.

Rozdział 9 stanowi podsumowanie, zawiera konkluzje i wnioski autora na temat możliwości oraz ograniczeń związanych z interpretacją danych skaningowych.

W **rozdziale 10** przedstawiono kierunki dalszych badań w zakresie rozwoju funkcjonalnego opracowanego systemu oraz jego potencjalnie nowe zastosowania.

1.3. Teza pracy

Praca zmierza do wykazania zasadności następującej tezy:

Na podstawie pomiarów, uzyskanych ze skanera laserowego, powierzchni geometrii obiektu, w skład, którego wchodzi elementy rurowe oraz znajomości modeli elementów składowych obiektu, zbudowanych w oparciu o dokumentację techniczną, możliwe jest określenie parametrów określających geometrię i położenie wyszukiwanych elementów.

Powyższą tezę można przedstawić w postaci tez pośrednich:

- **Istnieje możliwość automatyzacji procesu identyfikacji i określania pozycji elementu instalacji przemysłowej korzystając z metod segmentacji danych w postaci chmury punktów.**
- **Segmentacja danych, pozyskanych w postaci chmury punktów, na segmenty spełniające odpowiednie kryteria podobieństwa, pozwala znacząco przyspieszyć proces identyfikacji obiektu.**
- **Zastąpienie punktów odpowiadających poszczególnym elementom instalacji obiektami sparametryzowanymi pozwala na śledzenie ich przemieszczeń w przestrzeni z uwzględnieniem interwału czasowego.**

2. Diagnostyka procesów przemysłowych

2.1. Wprowadzenie

Celowość stosowania systemów doradczych i wspierających w diagnostyce jest niekwestionowana. W literaturze można wyróżnić dwie kategorie systemów doradczych. Pierwszą z nich są systemy statyczne tzw. off-line ich zadaniem jest poszukiwanie rozwiązania w stałym otoczeniu. Drugą kategorią są systemy dynamiczne on-line, dla systemów dynamicznych należy dodatkowo rozróżnić systemy działające cyklicznie oraz te, które formułują odpowiedź na zapytania użytkownika [39]. Systemy dynamiczne dodatkowo zwykle cechują się dużą liczbą sygnałów wejściowych przy zmiennych warunkach pracy obiektu, co znacznie komplikuje zadanie wnioskowania systemu doradczego. Zadaniem diagnostyki procesu przemysłowego jest rozpoznawanie stanów obiektów technicznych, które jest zadaniem na pograniczu dziedzin automatyki i diagnostyki technicznej. Rezultatem badań w zakresie diagnostyki procesu przemysłowego może być np. zmiana masy, energii czy położenia. W dużej mierze dziedzina ta rozwijana przez automatyków pod kątem zadań wykrywania stanów awaryjnych oraz odpowiedniej reakcji na nie. Zagadnienia te stanowią integralną część projektowanych systemów automatyki i zabezpieczeń. Dlatego też dziedzina ta posiada wiele elementów wspólnych takich jak podejście do modelowania oraz identyfikacji obiektów dynamicznych [96].

Identyfikacja jest procesem wyznaczania parametrów modelu systemu lub obiektu na podstawie badań eksperymentalnych. Zwykle znana jest struktura modelu, a nawet część jego parametrów. W celu wyznaczenia pozostałych parametrów należy wykorzystać istniejące znane metody lub opracować algorytm identyfikacji, który określa jak należy przetworzyć dane pomiarowe, aby wyznaczyć wartości poszukiwanych parametrów [30]. Dla danych jednowymiarowych identyfikacja ma na celu wyznaczenie najlepszej wartości parametru α w modelu:

$$y=F(x,\alpha) \quad (2.1)$$

tj. takiej wartości α , dla której model najlepiej przybliży rzeczywisty obiekt w sensie określonego wskaźnika jakości.

Model jest schematem opisującym pewną klasę zjawisk i jest fragmentem rozważanej rzeczywistości. Można zatem identyfikować jego parametry w stosunku do klasy zjawisk, jaką ujmuje, jak i w zależności od zakresu problemowego, jaki wyznacza [32]. Pojęcie identyfikacji jest w takim ujęciu pojęciem bardzo szerokim określającym pewien sposób ogólnego postępowania. Obecnie, gdy obiektem sterowania stają się całe procesy technologiczne, a celem sterowania jest ich optymalizacja, zadania identyfikacji istotnie zwiększają się. Należy wybrać właściwe kryterium optymalizacji, dogodne z punktu widzenia sterowania. Następnie należy wybrać wielkości wejściowe i wyjściowe, a więc określić strukturę obiektu i w końcu wyznaczyć własności statyczne i dynamiczne tego obiektu [66]. Z punktu widzenia diagnostyki obiektu, proces identyfikacji rozumiany jest tutaj jako

identyfikacja uszkodzeń. Sam proces badania stanu można podzielić na trzy niezależne fazy: detekcji, lokalizacji i identyfikacji [31]. Proces identyfikacji uszkodzeń musi zostać poprzedzony poprzez fazę detekcji oraz lokalizacji. Fazy te wykonywane są w ściśle określonej kolejności. Pierwszym etapem jest detekcja, czyli wykrycie zaistnienia uszkodzenia w obiekcie, następnie następuje jego lokalizacja, czyli określenie miejsca i czasu wystąpienia uszkodzenia. Ostatnia faza dotyczy już samej identyfikacji, czyli określeniu charakteru uszkodzenia, jego rozmiarów oraz zmienności uszkodzenia w czasie.

Proces identyfikacji parametrów obiektu rzeczywistego, w tym przypadku modelu opisanego parametrami geometrycznymi, jest etapem niezbędnym do przeprowadzenia jego rekonstrukcji. Poprzez rekonstrukcję autor rozumie technikę digitalizacji obiektu rzeczywistego do postaci cyfrowego modelu. Zagadnieniami związanymi z cyfrowym projektowaniem jak i odtwarzaniem wyrobów przemysłowych realizowanych za pomocą narzędzi komputerowo wspomaganego projektowania (CAD) zajmuje się dziedzina inżynierii odwrotnej [33]. W języku polskim jest to wynik tłumaczenia terminu anglojęzycznego reverse engineering. Termin ten nie do końca oddaje istotę prowadzonych badań, dlatego też na potrzeby pracy postanowiono posłużyć się terminem inżynierii rekonstrukcyjnej zaproponowanym w [34].

2.2. Proces inżynierii rekonstrukcyjnej

Techniki komputerowego wspomaganego projektowania najczęściej rozpoczynają się od pomysłu oraz zarysu koncepcji obiektu. Następnie korzystając z komputerowych środowisk inżynierskich CAD formułuje się dokładną cyfrową reprezentację takiego obiektu. Cyfrowa reprezentacja obiektu pozwala w bardzo krótkim czasie przejść do produkcji rzeczywistego obiektu wykonanego w oparciu o cyfrowy model.

Inżynieria rekonstrukcyjna pozwala na odwrócenie wyżej opisanego procesu, tj. dysponując obiektem rzeczywistym możliwe jest utworzenie jego reprezentacji cyfrowej, oczywiście z pewną niepewnością, wynikającą z dokładności procesu digitalizacyjnego [35]. Uzyskany model cyfrowy może zostać wykorzystany do produkcji nowych elementów lub na potrzeby opracowania cyfrowego systemu diagnostycznego. W pracy skupiono się na zagadnieniu drugim, ze względu na technikę digitalizacji obiektów jaką jest skanowanie laserowe, która ogranicza się tylko do pomiaru powierzchni obiektu. Informacja o powierzchni jest niewystarczająca, aby w pełni odtworzyć rzeczywisty obiekt jednak na jej podstawie można zbudować cyfrowy system diagnostyczny analizujący powierzchnię oraz przesunięcia obiektów.

2.3. Błędy pomiaru skanerem laserowym

2.3.1. Błędy przyrządu pomiarowego

Pomiędzy uzyskanymi wynikami pomiarów i wartością prawdziwą wielkości mierzonej występuje niezgodność, która dla pojedynczej realizacji pomiaru jest jego błędem. Dla skanerów laserowych wyróżnia się kilka źródeł błędów, które można podzielić na cztery kategorie [26]:

- błędy przyrządu pomiarowego
- błędy związane z naturą badanego obiektu
- błędy powstałe poprzez wpływ otoczenia podczas wykonywania pomiaru
- błędy metodologiczne

Wyróżnia się dwa typy błędów wynikających z niedokładności przyrządu pomiarowego. Są to błędy systematyczne oraz losowe. Błędy losowe wpływają głównie na dokładność pomiaru odległości oraz kąta w urządzeniach mierzących czas odbicia wiązki od powierzchni. Mogą one zostać określone poprzez wykonanie kilku serii pomiarowych. Błędy systematyczne to błędy, które przy wielu pomiarach tej samej wartości wielkości mierzonej, wykonywanych w tych samych warunkach pozostają stałe lub zmieniają się według określonego prawa wraz ze zmianą warunków.

Wpływ średnicy wiązki laserowej

Jednym z najistotniejszych parametrów pomiaru skanerem laserowym, który w znaczący sposób wpływa na rozdzielczość chmury punktów oraz niepewność pomiaru odległości, jest średnica wiązki laserowej. Średnica ta rośnie wraz z odległością do powierzchni pomiarowej. Powołując się na [23] średnicę wiązki można opisać równaniem (2.2).

$$r(\rho_r) = r_0 \sqrt{1 + \left(\frac{\lambda \rho_r}{\pi r_0^2}\right)^2} \quad (2.2)$$

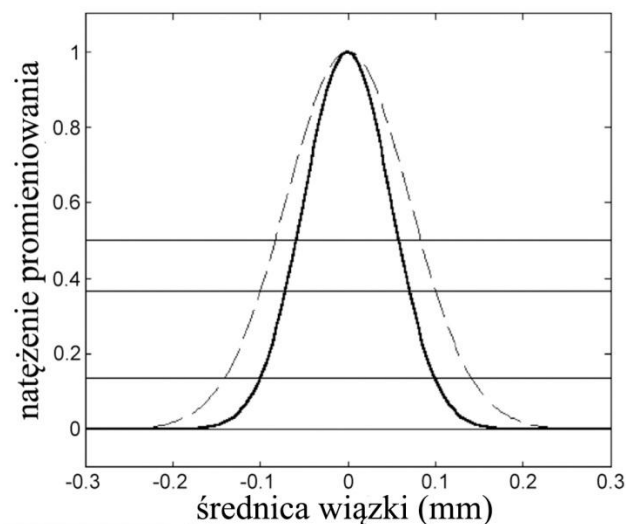
w którym :

ρ_r - odległość względna do punktu pomiarowego

r - promień wiązki lasera

r_0 - minimalny promień wiązki lasera

Średnica wiązki jest odległością mierzoną wzdłuż średnicy przekroju poprzecznego między punktami, w których intensywność wiązki jest e^2 razy mniejsza od intensywności w centrum przekroju. Przykładowy wykres mocy względnej, wiązki gaussowskiej (odniesionej do wartości maksymalnej) w przekroju poprzeczym, przedstawiono na rys. 2.1.




Rys. 2.1. Gaussowski przekrój poprzeczny wiązki lasera [36]

Przyrost średnicy wiązki dla dużych odległości można potraktować jako liniowy, więc zwykle dla urządzenia podaje się średnicę początkową. Dla laserów o wiązce różniącej się od gaussowskiej na ogół określa się średnicę wiązki jako średnicę koła, w którym mieści się określony procent mocy lub energii, czyli około 86% całkowitej mocy wiązki [24]. Skaner z którego korzystano podczas przeprowadzania badań posiadał średnicę wiązki:

- 2,3 mm dla 5 m,
- 16 mm dla 46 m.


Wpływ krawędzi obiektu

Wielkość średnicy wiązki jest istotnym parametrem, w szczególności w przypadku pomiaru krawędzi obiektu [25]. Podczas pomiaru krawędzi może wystąpić jedna z trzech możliwości przedstawionych na rys. 2.2. Można, więc założyć, że w przypadku pomiaru krawędzi zawsze nastąpi uśrednienie wartości pomiaru odległości na podstawie dwóch powierzchni.



Rys. 2.2. Możliwe przypadki pomiaru krawędzi obiektu

Efekt uśredniania jest zwykle bardzo dobrze widoczny w chmurze punktów i przypomina powielenie krawędzi obiektu z przyrostem odległości rys 2.3. Ilościowa reprezentacja szumu powstałego przy pomiarze krawędzi jest ściśle związana z wzrostem odległości, z jakiej badana jest dana krawędź i również wiąże się ze wzrostem średnicy wiązki, co z kolei wpływa na zwiększenie obszaru uśredniania. Przykład szumu powstałego na krawędzi przedstawiono na rys. 2.3.



Rys. 2.3. Szum powstały po skanowaniu krawędzi

Szum powstały po przeskanowaniu krawędzi można usunąć korzystając z jednej z metod bazującej na określaniu lokalnego sąsiedztwa dla zbioru punktów [41],[42].

Wpływ odległości

Aktualnie stosowane skanery korzystają z jednej z trzech dostępnych metod wyznaczania odległości. Wyróżniamy metody oparte o triangulację laserową, pomiar czasu odbicia i pomiar przesunięcia fazy. Zasada działania poszczególnych metod została opisana w rozdziale 3.1.2. W pracy wykorzystano ze skanera Trimble FX, który jest skanerem wykorzystujących pomiar przesunięcia fazy, dla którego dokładność pomiaru odległości można wyrazić równaniem (2.3),

$$\delta_z \approx \frac{\lambda_m}{4\pi\sqrt{SNR}} \quad (2.3)$$

w którym:

- λ_m – długość fali elektromagnetycznej,
- SNR – stosunek sygnału do szumu.

Wg danych dostarczonych przez producenta niepewności pomiaru odległości wynoszą:

- 0,6 mm dla 11 m,
- 0,8 mm dla 21 m.

2.3.2. Błędy związane z naturą badanego obiektu

Wpływ współczynnika odbicia wiązki

Podczas pomiaru skanerem laserowy pomiaru następuje odbicie wiązki laserowej od powierzchni obiektu. Dlatego też właściwości materiału, takie jak współczynnik pochłaniania światła czy jego odbicia, w istotnym stopniu wpływają na wynik pomiaru. Dla powierzchni matowych obowiązuje prawo Lamberta, zgodnie, z którym natężenie docierające z powierzchni elementarnej do obserwatora jest proporcjonalne do cosinusa kąta α pomiędzy wektorem normalnym do powierzchni a kierunkiem do obserwatora. Natężenie światła odbitego od detektora urządzenia, zależy zatem od jego współczynnika odbicia i wyraża się równaniem (2.4),

$$I = I_d k_d e^{-2\tau x} \cos \alpha \quad (2.4)$$

w którym:

- I_d – natężenie punktowego źródła światła,
- $k_d \in [0,1]$ – współczynnik odbicia,
- τ – współczynnik tłumienia atmosfery

Wynika z niego, że natężenie odbitego sygnału, który powróci do detektora urządzenia pomiarowego zależy od wielu czynników takich jak odległość, warunki atmosferyczne, kąt padania wiązki oraz właściwości refleksyjne samej powierzchni.

Stąd też powierzchnie pomiarowe nie mogą być zbyt ciemne oraz absorbujące światło, ponieważ wtedy sygnał powrotny jest zbyt słaby. W efekcie dane z takiej powierzchni mogą zostać pominięte ze względu na duże odchylenia lub obciążone znacznym zaszumieniem. Z drugiej strony w przypadku powierzchni, które nadmiernie odbijają światło pomiar również jest utrudniony ze względu na możliwość odbicia wiązki przez te powierzchnie w innych kierunkach i w efekcie pomiar zlokalizowany jest w innym miejscu.

2.3.3. Błędy powstałe poprzez wpływ otoczenia podczas wykonywania pomiaru

Wpływ warunków atmosferycznych (temperatury i ciśnienia)

Większość skanerów zostaje wstępnie skalibrowana pod kątem normy ISO 10360 dla warunków 20 °C oraz 1013.25 hPa. Podczas pracy w innych warunkach powinno się przeliczyć wskazania urządzenia. Ponadto wystąpienie losowych zdarzeń podczas wykonywania pomiaru takich jak mgła, deszcz czy śnieg skutecznie uniemożliwia wykonanie precyzyjnego pomiaru. Zmiana temperatury o 10 °C lub zmiana ciśnienia atmosferycznego o 35 hPa może doprowadzić do wystąpienia błędów pomiaru odległości na poziomie 1 mm / 100m. Jednakże dla skanerów krótkiego i średniego zasięgu (do 100 m) te zmiany nie wpływają istotnie na pomiar odległości.

Podczas wykonywania pomiaru temperatura wewnątrz urządzenia wzrasta wskutek nagrzewania się elementów elektronicznych. Dlatego też producenci niektórych skanerów proponują przed wykonaniem pomiaru uruchomić urządzenie i odczekać określony czas, aby temperatura wewnątrz urządzenia się ustabilizowała. Ponadto producenci podają zakres temperaturowy, w jakiej skaner może pracować. Dla skanera Trimble FX wynosi on od 5 °C do 45 °C.

Wpływ ruchu obiektu

Skanery TLS (alg. Terrestrial Laser Scanner) nadają się głównie do badania obiektów i scen statycznych. Zwykle wykonywane jest od 2 000 do ok 500 000 pomiarów na sekundę, co pozwala na dobre odtworzenie powierzchni obiektu. Aby zebrać tak dużą ilość informacji potrzebny jest jednak pewien czas. Dookólny skan w wysokiej rozdzielczości może trwać nawet około 1 h. Podczas tak długiego czasu często nie ma możliwości zachowania pełnej statyczności badanej sceny lub obiektu, co powoduje specyficzny rodzaj zakłóceń. Zakłócenia tego typu można łatwo odfiltrować wykonując cykliczny pomiar oraz wykonując operację wyznaczenia części wspólnej pomiędzy zbiorami danych pomiarowych.

Drugim typem zakłóceń mogą być zakłócenia wywołane wibracją samego skanera. Podczas pracy elementy mechaniczne wraz z wirującym zwierciadłem mogą generować drgania, które następnie przenoszone są na obudowę urządzenia. Dlatego podczas pomiaru należy zadbać o stabilne posadowienie statywu ze skanerem, wykorzystując podłoże, które nie dopuści do przemieszczania się skanera wskutek drgań.


2.3.4. Błędy metodologiczne

Błędy metodologiczne najczęściej wynikają z małego doświadczenia osoby wykonującej pomiar. Najczęściej jest to określenie złej metody pomiaru lub niezajomości samego urządzenia pomiarowego. Jako przykład można posłużyć się sytuacją, w której osoba wykonująca pomiar zada wyższą rozdzielność pomiaru niż możliwości techniczne urządzenia. W takim wypadku uzyskuje się skan nadmiarowy, obciążony dodatkowym szumem. Ponadto niepotrzebnie wzrasta czas wykonywania pomiaru.

2.4. Badanie skanera laserowego Trimble FX

2.4.1. Ogólna charakterystyka skanera

W realizowanych badaniach korzystano z naziemnego skanera laserowego, który cechuje się parametrami przedstawionymi w tabeli 2.1, zadeklarowanymi przez producenta. Skaner wykonuje pomiar w oparciu o wyznaczanie przesunięcia fazy. Zdjęcie skanera pokazano na rys. 2.4. Skaner może wykonać pomiary w jednym z dwóch trybów: tzw. skanu pojedynczego oraz skanu podwójnego. Przy skanie pojedynczym uzyskuje się zasięg skanera do 60 m, przy założeniu, że powierzchnia badania cechuje się 50% współczynnikiem odbicia światła. Niepewność pomiaru odległości dla odległości 11 m wynosi 0,6 mm. W przypadku skanu podwójnego zwiększa się zasięg pomiaru do 80 m, również przy założeniu 50% współczynnika odbicia. Wg. producenta, dla obiektów odległych o 11 m od skanera, niepewność pomiaru odległości wynosi 0,45 mm. Skan podwójny wykonuje dwa niezależne skany (najprawdopodobniej podczas dwóch kolejnych obrotów lustra skanera), a następnie algorytm zaszyty w oprogramowaniu skanera uśrednia wyniki dwóch pomiarów, lecz także odrzuca punkty, których różnica odległości jest wyższa niż założony próg. W efekcie skan podwójny zwykle cechuje się mniejszą ilością punktów pomiarowych w stosunku do skanu pojedynczego. Niestety producent testowanego urządzenia nie udostępnia żadnych danych na temat wykorzystywanego algorytmu oraz przyjętych wartości granicznych, będących podstawą do odrzucenia pomiaru.



Rys. 2.4. Zdjęcie skanera laserowego Trimble FX

Tab. 2.1. Parametry skanera Trimble FX wg danych producenta

Parametr	Wartość
Pole widzenia	360° x 270°,
Zasięg (pojedynczy skan)	60 m (refleksyjność 50%)
Zasięg (podwójny skan)	80 m (refleksyjność 50%)
Szybkość skanowania	216 000 punktów/s
Typowy czas skanowania	5 min
Niepewność pomiaru odległości	
pojedynczy skan	0,6 mm dla 11 m
podwójny skan	0,45 mm dla 11 m
Średnica wiązki	2,3 mm dla 5 m 16,0 mm dla 46 m

2.4.2. Powtarzalność pomiaru skanerem podczas pomiaru wielokrotnego płaskiej powierzchni


W związku z niepełną informacją dotyczącą pracy skanera w trybie skanu podwójnego oraz weryfikacji podanych przez producenta danych dotyczących niepewności pomiaru przeprowadzono własne badania. Ich celem była także ocena możliwości podniesienia dokładności pomiarów położenia obiektów poprzez zwiększenie liczby skanów (w trybie skanu pojedynczego) z jednej bazy w stosunku do skanu podwójnego. W szczególności interesująca było pytanie dotyczące powtarzalność pomiarów, rozumianych jako zgodność ze sobą dopasowanych obiektów dla kolejnych serii pomiarów tego samego obiektu, wykonanych w tych samych warunkach.

Dla celów testowych wykonano serię 10 pomiarów skanerem z jednej pozycji bazowej badanego fragmentu płaszczyzny. Z uzyskanych danych wydzielono pojedyncze linie skanu leżące w tej samej płaszczyźnie, składające się z około $N=570$ punktów dla każdej z kolejnych

10 linii. Korzystając z metody regresji liniowej wyznaczono równanie dopasowanej prostej do punktów pomiarowych, określonej równaniem (2.5)

$$y = ax + b \quad (2.5)$$

Współczynniki równania, dla pierwszej linii przyjmują wartości pokazane na rys. 2.5, na którym ponadto zaznaczono prostą aproksymującą opisaną równaniem. Jak widać płaszczyzna nie było idealnie prostopadła do osi Z układu współrzędnych skanera ($a \neq 0$).



Rys. 2.5. Rozkład punktów dla pojedynczej linii w płaszczyźnie XY

Dla każdej serii pomiarów obliczono odchylenia standardowe punktów od wyznaczonej prostej regresji (zakładając, że odwzorowuje jedną z linii płaszczyzny pionowej). Obliczone wartości parametrów linii zestawiono w tabeli 2.2. Odchylenia standardowe pojedynczego pomiaru kolejnych linii znajdowały się w przedziale (0,43-0,46) mm. Odchylenie standardowe pojedynczego punktu obliczone dla wszystkich punktów wynosiło 0,47 mm.


Tab. 2.2. Parametry linii dla kolejnych serii pomiarów: średnia współrzędna X_{sr} , jej odch. std. σ_x , odchylenie linii od pionu oraz skorygowana wsp. X_0

Nr linii	σ_x	X_{sr}	Odchylenie	X_0
	mm	mm	°	mm
1	0,457	0,0001	0,52	0,00
2	0,427	-0,1746	0,55	-0,06
3	0,442	0,0434	0,52	0,04
4	0,451	0,0069	0,51	-0,04
5	0,456	-0,233	0,53	-0,2
6	0,447	0,2139	0,51	0,19
7	0,452	0,0019	0,50	-0,06
8	0,451	0,0002	0,50	-0,07
9	0,447	0,1206	0,51	0,08
10	0,459	-0,2426	0,52	-0,23


Wyznaczone odchylenie płaszczyzny pionowej dla kolejnych linii znajdowało się w przedziale $(0,50-0,55)^\circ$, a różnice w odniesieniu do wartości średniej nie przekraczały $0,025^\circ$. Podobnie niewielkie różnice występują pomiędzy początkami kolejnych linii ($\pm 0,21$ mm).

Do dalszych obliczeń dane skorygowano tak, aby można je było potraktować jako reprezentujące linie pionowe i analizowano jedynie współrzędną X punktów, będącą ich odległością od analizowanej linii, a tym samym i płaszczyzny.

Wyznaczono rozkład gęstości prawdopodobieństwa wartości współrzędnych X i porównano go z rozkładem normalnym. Empiryczny rozkład gęstości prawdopodobieństwa wyznaczono dla $k=15$ przedziałów (spełniający kryterium $0,5\sqrt{N} \leq k \leq \sqrt{N}$), zarówno dla pojedynczej linii rys. 2.6 jak i całej serii linii rys. 2.7.



Rys. 2.6. Rozkład empiryczny odchyłek pomiaru odległości dla pojedynczej linii na tle krzywej rozkładu normalnego



Rys. 2.7. Rozkład empiryczny odchyłek pomiaru odległości dla 10 linii na tle krzywej rozkładu normalnego

Wykonane testy zgodności rozkładów χ^2 potwierdziły zgodność uzyskanych rozkładów z rozkładem normalnym.

W związku z uzyskanymi wynikami hipoteza, że poprzez wielokrotne wykonanie skanów z jednego punktu bazowego pozwoli zmniejszyć niepewność pomiarów zmian odległości wydaje się prawdziwa. Przed badaniami obawiano się, że zwiększanie liczby skanów będzie równocześnie zwiększać odchylenie standardowe i tym samym niepewność wyznaczania współrzędnych. W efekcie szacowania uzyskano niepewność typu A pomiarów odległości zbliżoną do zadeklarowanej przez producenta, przy pojedynczym skanie. Natomiast wykonanie

serii skanów pozwala na zmniejszenie niepewności pomiaru dotyczące wartości średniej wyniku. Niepewność wyznaczonej współrzędnej X_{sr} dla pojedynczego skanu 0,9 mm, natomiast dla 10 skanów zmniejszyła się do 0,3 mm. Odbywa się to oczywiście kosztem wydłużenia czasu wykonania pomiaru, ale w pewnych sytuacjach, pomiar skanerem pozwala na wykonanie bardzo precyzyjnych pomiarów [46].

2.4.3. Szacowanie niepewności wybranych typów pomiarów

Kolejne badania które przeprowadzono, polegały na wykonaniu serii prób dopasowania modelu bryłowego do danych w postaci chmury punktów. Obiekt dopasowano przy użyciu funkcji BestFit zaimplementowanym w oprogramowaniu dostarczonym ze skanerem oraz metodzie Random Sample Consensus (RANSAC) [43] [44], którą zrealizowano w środowisku Point Cloud Library (PCL). Wszystkie badania zostały zrealizowane w jednakowych warunkach laboratoryjnych, aby wykluczyć wpływ czynników zewnętrznych na przeprowadzane pomiary. Pomiar został wykonany w oparciu o niemiecką normę VDI/VDE 2634 dotyczącą badania dokładności skanerów laserowych [45].

Wytyczne normy VDI/VDE 2634 określają następujące parametry:

- błąd układu głowicy optycznej – wykonywany z użyciem pojedynczej kuli,
- błąd wskazania długości – wykonywany z użyciem wzorca tzw. ball bar, czyli dwóch oddalonych o znaną odległość kul,
- błąd płaskości – wykonywany z użyciem płaskiej płytki.


Na potrzeby weryfikacji błędu układu głowicy optycznej skorzystano z białej kuli dostarczonej ze skanerem, wykorzystywanej najczęściej jako punkt orientacyjny. Kula jest wykonana z białego tworzywa o dużym, zbliżonym do jedności, współczynniku odbicia światła. Dlatego też, pomimo jej niewielkiej średnicy, jest „widziana” przez skaner nawet z odległości 50 m.

Dla uniknięcia błędu dopasowania, wynikającego z punktów błędnie wyselekcjonowanych oraz punktów będących wynikiem uśrednieniem pomiędzy dwoma płaszczyznami pomiarowymi, kulę zamocowano na stalowym pręcie z podstawą, dzięki czemu precyzyjnie można wybrać punkty pomiaru, które zostaną wykonane na jej powierzchni. Wykorzystywaną kulę przedstawiono na rys. 2.8.

Przed wykonaniem pomiarów skanerem, średnicę kuli zmierzono przy użyciu suwmiarki cyfrowej wykonując serię 10 pomiarów. Średnia arytmetyczna średnicy badanej kuli wyniosła 99,035 mm. Następnie wykonano serie pomiarowe składające się z 10-krotnych pomiarów dla odległości: 1,3,5,10,30,50 metrów. Dla każdej z serii wyznaczono parametry:

- współrzędne środka kuli,
- odchylenia standardowe środka dla każdej z osi,
- średnicę dopasowanej kuli,
- odchylenie standardowe średnicy dopasowanej kuli.

Wyniki pomiarów przedstawiono w tab. 2.3. Można zauważyć, że dla odległości 50 m zarówno dopasowanie modelu jak i średnica wyznaczone zostały z dużym błędem. Takie wyniki mogą być spowodowane właściwościami powierzchni kuli.



Rys. 2.9. Model do wyznaczania błędu układu głowicy optycznej oraz chmura punktów z dopasowaną kulą

Tab. 2.3. Wyniki obliczeń odchyleń standardowych na podstawie pomiaru parametrów kuli


Odległość	Liczba punktów	Zmierzone współrzędne	Odchylenie σ_x	Odchylenie σ_y	Odchylenie σ_z	Średnica kuli R	Odchylenie σ_R dopasowania kuli
M	-	M	mm	mm	mm	mm	mm
1	13210	-323, 929, 102	0,02	0,03	0,02	97,0	0,7
3	3835	-2365, 1908, -425	0,02	0,02	0,04	99,1	0,2
5	1322	698, -5039, -536	0,01	0,03	0,11	99,0	0,2
10	318	-9960, -153, -471	0,13	0,03	0,22	98,3	0,2
30	150	11431, 27692, 284	0,25	0,53	0,31	97,3	0,7
50	213	24986, 43115, -3389	0,91	0,98	0,75	79,5	2,7

Zauważono także, że wykonując pomiar z odległości 1 m powierzchnia kuli częściowo "oślepiła" skaner, co spowodowało większy błąd dopasowania kuli. Dla 50 m natomiast średnia kuli wynosząca 99 mm jest obiektem zbyt małym, aby znalazło się na nim na tyle dużo punktów pomiarowych, aby można dokładnie wyznaczyć badaną powierzchnię.

Drugim weryfikowanym parametrem był błąd pomiaru długości, który określono przy pomocy testu „ball bar”. Test ten polegał na pomiarze odległości pomiędzy środkami dwóch kul o znanej i stałej odległości dla różnych ustawień kul względem skanera. Model wykorzystany do badania błędu wskazania długości przedstawiono na rys. 2.10.

Podobnie jak przy pomiarze z użyciem pojedynczej kuli, zastosowano te same kule o znanej średnicy (99 mm), zamocowane na pręcie o znanej długości (339 mm). Odległość

między środkami kul wyniosła 438 mm. Między pomiarami nieznacznie zmieniano ustawienie kul przy zachowaniu odległości do skanera, aby uzyskać reprezentatywny wynik pomiaru. Zasadniczą określaną wielkością była odległość pomiędzy środkami kul. Dla każdej z serii wyznaczono średnią odległość, średni błąd średniej pomiaru, maksymalny błąd pomiaru i odchylenie standardowe pomiaru odległości, dla przedstawienia zamienności wyników w obrębie serii. W tabeli 2.4 zestawiono uzyskane wyniki dla serii pomiarowych składających się z 10 pomiarów.



Rys. 2.10. Model do wyznaczania błędu wskazania długości

Tab. 2.4. Wyniki pomiaru testu „ball bar”

Odległość do kul od skanera	Średnia odległość pomiędzy kulami	Błąd średni pomiaru odległości środków kul skanerem	Wartość bezwzględnego maksymalnego błędu odległości pojedynczego pomiaru	Odchylenie standardowe pojedynczego pomiaru odległości pomiędzy kulami
m	mm	mm	mm	mm
1	442,3	-4,3	4,4	0,12
3	437,7	-0,3	1,9	1,1
5	439,2	1,2	1,2	0,02
10	438,9	0,9	1,0	0,05
30	438,1	0,1	3,1	1,2
50	437,9	-0,1	3,6	2,0

Można zauważyć, że odległość pomiędzy środkami kul dla pojedynczych pomiarów została wyznaczona z błędami ± 2 mm w zakresie odległości 3÷10 m. Błąd wyraźnie wzrósł dla odległości 1 m, dla której pojawił się problem z dokładnym dopasowaniem kuli ze względu na jej zbyt duży współczynnik odbicia powierzchni. Dla odległości powyżej 10 m, błędy przekraczały 3 mm. Wyraźnie mniejsze są błędy określania odległości środków kul wyznaczone dla wartości średnich (nie przekraczają 1,2 mm powyżej 1 m od skanera), chociaż odchylenie standardowe wyraźnie wzrasta wraz z odległością. Uzyskanie w wyniku uśredniania

zmniejszenia błędu pomiaru odległości test „ball bar” jest korzystną właściwością. Ponadto jak autor wykazał [46], że niepewność pomiaru odległości dla badanego skanera może zostać zmniejszona poprzez wykonanie serii pomiarów wykonywanych z jednego punktu bazowego. Lepszym podejściem, jeśli chodzi o uzyskanie mniejszej niepewności pomiaru, jest wykonanie serii skanów niezależnych niż wykorzystywanie skanów tzw. podwójnych, oferowanych w skanerze przez producenta.

2.5. Budowa systemu identyfikacji wizualnej

Kluczowym elementem procesu identyfikacji obiektu jest określenie sposobu jego reprezentacji. Jain i in. w publikacji [1] precyzują elementy kluczowe z punktu widzenia projektowania systemu identyfikacji obrazu. Są to:

- wybór reprezentacji obiektu,
- utworzenie bazy danych z obiektami,
- akwizycja danych,
- wyznaczanie cech szczególnych,
- wybór dopasowania danych do modelu,
- dobranie metody określającej dopasowanie danych do modelu z największym prawdopodobieństwem,
- określenie metody weryfikacji.

Identyfikacja obiektu może opierać się na kryteriach scharakteryzowanych przez Grimsona [2] zwracając uwagę na następujące czynniki:

- cel - jaki rodzaj obiektów ma być rozpoznawany,
- niezawodność - m. in. odporność na szum w sygnale wejściowym,
- wydajność - szybkość oraz zapotrzebowanie na pamięć i moc obliczeniową,
- poprawność - dokładność systemu rozpoznającego.

Sam proces identyfikacji bazuje na dwóch typach informacji. Pierwsza jest natury empirycznej i odnosząc ją do zagadnień identyfikacji systemów, informacja ta jest najczęściej wynikiem pomiarów w różnych częściach systemu, zwykle na jego wejściu i wyjściu. Drugim typem informacji jest ta, którą dysponuje się wcześniej przed wykonaniem jakiegokolwiek pomiaru. Nazywa się ją wiedzą wstępną lub aprioryczną. Prawidłowa identyfikacja polega na właściwym wykorzystaniu obydwu typów informacji o zupełnie różnym charakterze [18].

Zwykle system identyfikacji wizualnej budowany jest na potrzeby analizy określonego wycinka sceny trójwymiarowej (3D), wyodrębnianiu jej elementów a następnie poddaniu ich procesowi identyfikacji. Dlatego też na wstępie należy określić reprezentację obiektów, które podlegać będą identyfikacji oraz zapisać je w pamięci systemu. Proces samej identyfikacji wykonywany jest w kolejnym kroku. Określenie reprezentacji obiektów, czyli ich formalnego opisu, nie jest sprawą trywialną. Należy rozstrzygnąć m.in. jaki typ modelu należy wybrać. Najczęściej stosowanymi są dwa podejścia [19]:

- budowa formalnych modeli (reprezentacji) obiektów — konstruowanie pełnych dokładnych modeli obiektów oraz ewentualnie, budowa specjalnych modeli przeznaczonych do identyfikacji (aspektowych, widokowych, itp.) na podstawie (dokładnych) modeli pełnych,
- tworzenie przybliżonej reprezentacji obiektów na podstawie pozyskanych danych wizualnych o scenie, obrazów czy map głębi (map zasięgu).

Bazy danych modeli zbudowanych w oparciu o przedstawione podejścia różnią się zarówno rodzajem gromadzonej informacji jak i jej trwałością. Budowa formalnych modeli jest tworzona na podstawie opisu określonych obiektów. Informacje o tych obiektach są zapisywane w sposób stały w bazie danych. Tak skonstruowane modele można wykorzystać wielokrotnie i do różnych celów. Pierwszy etap działania takiego systemu polega na rozpoznawaniu wyglądu obiektu rzeczywistego oraz wyodrębnianiu jego elementów składowych. Na tym etapie system wypełnia strukturę danych analogiczną do tej, która została wykorzystana do opracowania modelu. Kolejnym krokiem jest porównanie struktury danych obiektu rzeczywistego z strukturą modelu. Niewątpliwą zaletą tak skonstruowanej bazy modeli jest możliwość jej rozszerzania. W przypadku, kiedy znany jest opis formalny obiektu rzeczywistego np. w postaci reprezentacji powłokowej możliwe jest dodawanie nowych obiektów bez ich obecności.

Drugie podejście można określić, jako bazę „uczącą się” modeli obiektów na podstawie danych z akwizycji. Zwykle jest to baza o charakterze tymczasowym, w której faza rozpoznawania jest wykonywana równolegle z fazą tworzenia modelu. Po wykonaniu zadania rozpoznania, obiekty sceny nie są już więcej wykorzystywane. Do tworzenia samych modeli potrzebny jest podsystem odpowiedzialny za rozpoznanie elementów charakterystycznych obiektu takich jak ściany, krawędzie, wierzchołki. Na ich podstawie odtwarzana jest reprezentacja 3D obiektu. Wykorzystując tego typu bazę należy zarezerwować pamięć w systemie na informacje o obiektach, które mogą się pojawić podczas wykonywania rozpoznawania.

2.6. Podsumowanie

W rozdziale poruszono podstawowe problemy związane z diagnostyką obiektu, przedstawiono trzy główne fazy diagnostyki, ze szczegółową interpretacją autora pod kątem realizowanej pracy. Następnie opisano proces inżynierii rekonstrukcyjnej, który ma na celu odtworzenie obiektu rzeczywistego do postaci cyfrowej. Jest to element bardzo istotny, z praktycznego punktu widzenia realizowanej pracy. Proces digitalizacji związany jest z niepewnością pomiarową urządzenia, której pewne aspekty również przedstawiono. Ponadto wskazano na podstawowe przyczyny oraz charakterystyki błędów pomiarowych, istotnych z punktu widzenia skaningu laserowego. Ze względu na bardzo ograniczoną informację dotyczącą wykorzystywanego urządzenia przeprowadzono szereg badań i pomiarów mających na celu określenie rzeczywistych możliwości wykorzystywanego skanera. Opisano podstawowe funkcjonalności urządzenia w odniesieniu do samego procesu skanowania

związane z wykorzystaniem skanów pojedynczych lub podwójnych oraz zaproponowano metodę pozwalającą zwiększyć dokładność pomiaru wykonując serie pomiarowe z jednego punktu. Następnym elementem rozdziału jest opis oraz określenie podstawowych parametrów istotnych z punktu widzenia budowy systemu identyfikacji wizualnej wykorzystywanego na potrzeby diagnostyki.

3. Możliwości rekonstrukcji obiektów do postaci trójwymiarowych modeli cyfrowych z wykorzystaniem metod przetwarzania obrazu

3.1. Realizowane funkcje

Wraz z rozwojem zarówno możliwości technicznych urządzeń obrazujących jak i rozwojem algorytmów przetwarzania obrazu, metody wizyjne odgrywają aktualnie ważną rolę w automatyzacji procesów produkcyjnych [20]. Z punktu widzenia realizowanej pracy najistotniejszymi funkcjami zastosowania widzenia maszynowego oraz metod przetwarzania obrazu są:

- **rozpoznawanie obiektów** – oznacza identyfikację obiektów na podstawie cech charakterystycznych takich jak: kształt (geometria), wymiary, kolor, struktura (topologia),
- **określanie pozycji** – oznacza określanie pozycji oraz orientacji obiektu – lub konkretnego punktu tego obiektu – we wcześniej zdefiniowanym układzie współrzędnych, korzystając z określonych cech obiektu oraz metod dopasowywania;
- **inspekcja (kontrola) powierzchni** – może być podzielona na ilościową mającą na celu określenie cech topograficznych takich jak chropowatość lub jakościową skupiającą się na rozpoznawaniu defektów powierzchni takich jak wgniecenia, zadrapania, zanieczyszczenia, czy odchylenia od pożądaných właściwości powierzchni (kolor, tekstura itp.)
- **sprawdzenie kształtu i wymiarów** – oznacza określenie geometrycznych wielkości z naciskiem położonym na precyzję i dokładność pomiarów; istotność tego czynnika rośnie wraz ze wzrostem standardów jakości; stosowane wszędzie gdzie elementy obrabiane lub narzędzia wymagają sprawdzenia zgodności z wymiarami nominalnymi;

W zależności od wyboru reprezentacji obiektu rzeczywistego do postaci cyfrowej oraz metody akwizycji poszczególne funkcje widzenia maszynowego przyjmują odmienną metodologię zarówno akwizycji danych jak i dostępnych metod przetwarzania obrazu. Klasyczne metody przetwarzania obrazu można najogólniej scharakteryzować, jako grupy następujących przekształceń:

- przekształcenia geometryczne

- przekształcenia punktowe
- przekształcenia kontekstowe
- przekształcenia widmowe
- przekształcenia morfologiczne

Przekształcenia geometryczne związane są z transformacją geometrii obrazu na którą najczęściej składają się obroty odbicia czy przesunięcia. Charakteryzują się tym iż nie zostaje zaburzona struktura punktów sąsiadujących w obrazie. Wykorzystywane są najczęściej do korygowania błędów będących najczęściej powodem ograniczeń optyki urządzenia rejestrującego takich jak zniekształcenia poduszkowe, beczkowate.

Przekształcenia punktowe realizowane są najczęściej na pojedynczych punktach obrazu źródłowego w efekcie uzyskiwane są również pojedyncze punkty obrazu wynikowego. Operacje te mają za zadanie lepsze uwidocznienie pewnych elementów w obrazie nie wprowadzając żadnych nowych informacji do obrazu. Relacje geometryczne pomiędzy punktami pozostają bez zmian, zmianie ulega tylko ich wartość. Najpopularniejszymi przykładowymi przekształceniami punktowymi są normalizacja, która polega na sprawdzeniu przedziału zmian wartości punktów do określonego zakresu. Drugą metodą jest modulacja mająca za zadanie redukcję nadmiernego kontrastu w obrazie wyjściowym. Kolejnym przykładem może być binaryzacja, której celem jest redukcja ilości informacji w obrazie, dzięki czemu bardzo często jest wykorzystywana jako metoda poprzedzająca analizę obrazu.

Przekształcenia widmowe polegają na tym, że pierwszym etapem jest wyznaczenie dwuwymiarowego widma obrazu najczęściej wykonuje się to wykorzystując transformację Fouriera. Kolejny etap przewiduje modyfikację widma np. usunięcie określonych składowych obrazu. Następnie wykonuje się rekonstrukcję obrazu z użyciem odwrotnej transformaty Fouriera. Metoda jest dosyć złożona obliczeniowo jednak pozwala na precyzyjne kontrolowanie skutków dokonywanych transformacji.

Przekształcenia morfologiczne zakładają, że element obrazu modyfikuje się w przypadku, gdy spełniony jest określony warunek logiczny. Przekształcenia morfologiczne są jednymi z najważniejszych operacji w komputerowej analizie obrazu, ponieważ można je łączyć w zestawy pozwalające na bardziej złożone operacje związane z analizą kształtu elementów obrazu i ich wzajemnego rozmieszczenia. Przekształcenia morfologiczne związane są z pojęciem elementu strukturalnego obrazu. Jest to pewien wycinek obrazu z wyróżnionym jednym punktem tzw. punktem centralnym. Ogólnie każde przekształcenie morfologiczne można opisać za pomocą trzech kroków [40].

1. Dla każdego punktu w obrazie wykonywana jest analiza koincydencji punktów obrazu i elementu strukturalnego zakładając, że dany punkt jest punktem centralnym elementu strukturalnego
2. Dla każdego punktu wykonuje się porównanie wzorcowego elementu strukturalnego z konfiguracją pikseli w otoczeniu badanego punktu
3. Jeśli wystąpi zgodność wzorca z obrazem wykonywana jest ustalona operacja na badanym punkcie

Przykładowymi przekształceniami morfologicznymi są: erozja, dylatacja, otwarcie, zamknięcie, detekcja ekstremów.

Kolejnym istotnym elementem związanym z analizą obrazu jest proces filtracji obrazu. Filtry używane do analizy obrazów zakładają, że operacje na obrazie będą kontekstowe. Czyli wyznaczenie wartości dla jednego punktu będzie wymagało informacji oraz wykonania obliczeń z wielu punktów obrazu źródłowego. Filtry wykorzystuje się do stłumienia w obrazie niepożądanego szumu. Wzmocnieniu w obrazie pewnych istotnych elementów zgodnych z określonym wzorcem. Podstawową klasyfikacją filtrów jest podział na filtry liniowe gdzie operacja filtracji wykonywana jest w oparciu o liniową kombinację wybranych pikseli oraz nieliniowe gdzie funkcja wybranych pikseli obrazu wejściowego jest nieliniowa. Przykładowe filtry liniowe to np. splot funkcji (konwolucja), splot dyskretny, dolnoprzepustowy, górnoprzepustowy. Przykładem najprostszej funkcji nieliniowej są filtry logiczne polegające na badaniu wartości wyrażenia logicznego, które opisuje związki między punktami z dowolnie wybranego sąsiedztwa w zależności od potrzeb. Kolejnym przykładem filtrów nieliniowych są filtry medianowe gdzie wartość wynikowa punktu jest medianą (wartością środkową) zbioru punktów z sąsiedztwa branych pod uwagę do filtracji. Filtr medianowy w przeciwieństwie do filtrów konwolucyjnych nie powoduje utraty informacji o krawędziach obiektów poprzez ich rozmywanie. Zaletą filtra jest to, że wszystkie wartości znacznie odbiegające od średniej są zupełnie pomijane przy wyznaczaniu nowej wartości punktu. Filtry medianowe bardzo często wykorzystuje się do usuwania szumu impulsowego [82], który jest zakłóceniem pojedynczych próbek sygnału. Przykładowym źródłem powstania takiego szumu jest matryca CCD aparatu cyfrowego, która może generować szum przy długich czasach ekspozycji.

Równie istotnym etapem jest proces klasteryzacji obrazu na segmenty spełniające określone kryteria podobieństwa. Najczęściej wykorzystywane techniki segmentacyjne to techniki k-średnich. Zasadniczą wadą najpopularniejszej techniki grupowania k-średnich (ang. K-means) jest zależność uzyskanego wyniku od inicjalizacji procesu grupowania, na którą składa się określenie liczby klastrów k , zadanie początkowych środków klastrów i kryterium stopu [12]. Przykładem informacji na bazie, których wykorzystuje się techniki k-średnich może być intensywność lub barwa poszczególnych pikseli w obrazie [83].

3.2. Metody akwizycji danych reprezentujących obiekty 3D

3.2.1. Klasyfikacja stosowanych układów

Najbardziej naturalnym podziałem określającym zarazem dalsze możliwości zarówno identyfikacji jak i rekonstrukcji na podstawie danych jest sposób ich akwizycji. Najczęściej spotykanym i zarazem najtańszym rozwiązaniem jest skorzystanie z metod fotogrametrycznych, bazujących na co najmniej dwóch zdjęciach metrycznych lub niometrycznych, pozyskiwanych z kamer fotograficznych. Podejście takie pozwala na zarejestrowanie całych scen, w których każdy z pikseli odpowiadać będzie określonemu

fragmentowi przestrzeni. W tym przypadku struktura oraz współczynnik odbicia powierzchni obiektu nie ma wpływu na ciągłość danych pomiarowych. Innym podejściem cechują się metody skaningowe, które bazują na pomiarze odległości do określonego punktu w przestrzeni. Niewątpliwą zaletą tego typu podejścia jest to, że przy pojedynczym pomiarze uzyskuje się reprezentację przestrzeni opisujących obiekty znajdujące się w zasięgu skanera. Głównym ograniczeniem tej metody jest problem pomiaru odległości do powierzchni, które nadmiernie odbijają czy też pochłaniają laserową wiązkę pomiarową. W takich miejscach punkty pomiarowe zostają pominięte lub cechują się wyższym niż przewidywany błędem pomiaru.

Drugim typem podziału technik skaningu laserowego może być podział ze względu na typ zastosowanego skanera. Główne trzy metody pomiaru odległości skanerem laserowym można podzielić na trzy grupy:


- laserowy skaner czasu odbicia
- skaner przesunięcia fazy
- triangulacja laserowa

3.2.2. Metody fotogrametryczne

Metody fotogrametryczne mają na celu uzyskanie informacji przestrzennej drogą pomiaru, przetwarzania oraz interpretacji obrazów fotogrametrycznych. Istnieje wiele kryteriów podziału fotogrametrii np. ze względu na miejsce wykonywania pomiaru: naziemną, lotniczą, satelitarną [98].

W celu odtworzenia wzajemnego położenia obiektów na podstawie zdjęć konieczna jest wiedza pozwalająca określić orientację wewnętrzną aparatu. Elementy orientacji zewnętrznej zdjęć można podzielić na dwie grupy. Jedną z nich jest określenie położenia osi kamery oraz płaszczyzny rzutów w przestrzeni przy pomocy trzech kątów; kąta nachylenia ω , skręcenia κ oraz zwrotu φ .

W celu określenia orientacji zewnętrznej wykorzystać można znane wzorce umieszczone w fotografowanej scenie. Do wyznaczenia pozycji poszczególnych wzorców wykorzystuje się metodę równań kolinearności. Jest to metoda bardzo często stosowana w fotogrametrii lotniczej pozwalająca na obliczenie współrzędnych terenowych sfotografowanych punktów oraz określenie orientacji zewnętrznej zdjęcia. Graficzną prezentację metody kolinearności wektorów przedstawiono na rys 3.1.



Rys. 3.1. Graficzna prezentacja zagadnienia kolinearności wektorów

Dla oznaczeń jak na rys. 3.1 obowiązują zależności geometryczne opisane równaniami (3.1) oraz (3.2). Współrzędne wektora r w układzie tłowym (na zdjęciach) opisuje się równaniem (3.1). Zaś w układzie terenowym, wektor R ma współrzędne opisane równaniem (3.2).

$$r = \begin{bmatrix} x \\ y \\ -c_k \end{bmatrix} \quad (3.1)$$

$$R = \begin{bmatrix} X - X_0 \\ Y - Y_0 \\ Z - Z_0 \end{bmatrix} \quad (3.2)$$

Wektory R i r są współliniowe i ich początki zaczepione są w tym samym punkcie (O) i różnią się jedynie długością, co można to wyrazić równaniem (3.3).

$$\frac{|R|}{|r|} = \lambda \quad (3.3)$$

Układy współrzędnych - tłowy (zdjęcia) i terenowy są różnie zorientowane w przestrzeni. Orientacja ta najczęściej opisywana jest w formie uwikłanej postaci macierzy A (równanie. 3.5).

$$A = \begin{bmatrix} \cos \varphi \cos \kappa & -\cos \varphi \sin \kappa & \sin \varphi \\ \cos \omega \sin \kappa + \sin \omega \sin \varphi \cos \kappa & \cos \omega \cos \kappa - \sin \omega \sin \varphi \sin \kappa & -\sin \omega \cos \varphi \\ \sin \omega \sin \kappa + \cos \omega \sin \varphi \cos \kappa & \sin \omega \cos \kappa + \cos \omega \sin \varphi \sin \kappa & \cos \omega \cos \varphi \end{bmatrix} \quad (3.4)$$

Warunek kolinearności wektorów R i r można zapisać równaniem (3.6).

$$R = \lambda * A * r \quad (3.5)$$

W celu wyznaczenia współrzędnych terenowych punktów znajdujących się na zdjęciach należy znać wartości kątów ω , φ i κ oraz współrzędne terenowe środka rzutów. Mnożąc macierze i wektory występujące w równaniu (3.6) otrzymuje się układ równań (3.7).

$$\begin{aligned} X &= \lambda * (a_{11} * x + a_{12} * y - a_{13} * c_k) + X_0 \\ Y &= \lambda * (a_{21} * x + a_{22} * y - a_{23} * c_k) + Y_0 \\ Z &= \lambda * (a_{31} * x + a_{32} * y - a_{33} * c_k) + Z_0 \end{aligned} \quad (3.6)$$

W celu wyznaczenia położenia punktu należy skorzystać z co najmniej dwóch zdjęć na których widoczne są te same punkty. Uzyskuje się w ten sposób sześć równań, w których występuje pięć niewiadomych (współrzędne X, Y, Z punktu oraz λ zdjęcia lewego i λ zdjęcia prawego). Następnie w celu utworzenia modelu 3D można skorzystać z dwóch metod geometrycznej oraz DSM (ang. Dense Surface Modeling). Metodę geometryczną stosuje się do dokumentowania obiektów architektonicznych. Metoda DSM korzysta z korelacyjnej metody lokalizacji bazującej na tych samych elementach zdjęcia. Powierzchnie modelowane w ten sposób wymagają określonej tekstury, która można uzyskać korzystając z oświetlenia strukturalnego.

3.2.3. Metody skaningowe

Skaning laserowy jest techniką pomiarową, która bardzo szybko pozyskuje nowe obszary potencjalnych zastosowań. Same techniki skaningowe można podzielić na trzy główne grupy:

- lotniczy skaning laserowy (ang. ALS – Airborne Laser Scanning),
- mobilny skaning laserowy (ang. MLS – Mobile Airborne Laser Scanning),
- naziemny skaning laserowy (ang. TLS – Terrestrial Laser Scanning).

Lotniczy skaning laserowy, Light Detection And Ranging (LIDAR) jest metodą pozyskiwania danych 3D na bardzo dużych obszarach. Samo skanowanie wykonywane jest z samolotu. Wynikiem skanowania są chmury punktów najczęściej reprezentujące mapy wysokości. Dokładność pomiaru lotniczego w płaszczyźnie horyzontalnej wynosi (20–100) cm. Typowa dokładność wertykalna przyjmuje wartości z zakresu (9–18) cm dla awionetki, a (1–3) cm przy wykorzystaniu platform pomiarowych pracujących na helikopterach [14]. System lotniczy często wykorzystywany jest do weryfikacji położenia rozległych obiektów, dlatego też często wykorzystywany jest do weryfikacji położenia np. linii energetycznej w terenie leśnym i zurbanizowanym [15].


Skaning mobilny cechuje się tym, że skaner zintegrowany jest z na poruszającą się platformą taką jak łódzie, pociągi czy samochody. System korzysta dodatkowo z urządzeń lokalizacyjnych GPS, co pozwala na bardzo szybką inwentaryzację dużych obszarów. Systemy mobilne najczęściej wykorzystywane są do inwentaryzacji całej przestrzeni w obrębie danego zakładu.

Naziemny skanowanie laserowe cechuje się tym, że pomiar wykonywany jest z jednego punktu, a do skanera przypisany wcześniej lokalny układ współrzędnych XYZ, w którym zorientowane zostają dane z pomiaru. Skanery takie są w stanie pozyskać współrzędne milionów punktów oraz parametr w postaci intensywności odbicia wiązki, która zależy od odległości do punktu obiektu i współczynnika jego odbicia. Pozyskana chmura punktów może później zostać wyświetlona z uwzględnieniem intensywności poszczególnych punktów, co w efekcie przypomina zdjęcie w odcieniach szarości (rys. 3.2).



Rys. 3.2. Przykład wizualizacji chmury punktów ze skanera naziemnego

Skanowanie naziemne wykorzystywane jest głównie do inwentaryzacji pomieszczeń [16] lub wyszukiwania deformacji na określonych płaszczyznach [17]. Na rys. 3.3 przedstawiono przykład skanowania wewnątrz pomieszczenia, na którym można zauważyć różnice gęstości punktów w poszczególnych obszarach, jest to spowodowane tym, iż chmura punktów została utworzona poprzez zarejestrowanie (scalenie) ze sobą kilku skanów.



Rys. 3.3. Przykład złożenia kilku skanów


Podejście takie pozwala na wykonanie szybkiego skanu dookólnego o rzadkiej siatce, a co za tym idzie informacji o niskiej jakości dotyczącej powierzchni. Następnie wykonuje się skan precyzyjny o dużej gęstości mający na cel pomiaru istotnych elementów, które następnie można zorientować w skanie rzadkim.

W skanerze impulsowym wiązka lasera jest wysyłana z określoną częstotliwością w kierunku badanego obiektu, a następnie po odbiciu od obiektu odbierana przez detektor. Na podstawie pomiaru czasu przebycia drogi od odbiornika do obiektu i z powrotem obliczana jest odległość od skanowanego obiektu. Zasada działania znana jest dobrze z tachimetrów i dalmierzy elektronicznych dużego zasięgu (do 10 km).

Drugą grupą są skanery wykorzystujące pomiar przesunięcia fazy modulowanej wiązki laserowej. Zasada działania znana z dalmierzy laserowych małego zasięgu (do 200 m). W tym przypadku wiązka modulowana jest ciągłą falą harmoniczną, a odległość obliczana jest na podstawie różnicy faz pomiędzy falą wysłaną, a falą otrzymaną po odbiciu od obiektu. W praktyce pomiar wymaga porównania różnic kątów fazowych wyznaczonych dla kilku częstotliwości modulujących. Odległość jest funkcją różnicy faz, prędkości propagacji fali, ilości całkowitych (2π) długości fali modulującej.


3.2.4. Metody triangulacyjne jedno i dwuobrazowe

Metody triangulacyjne można podzielić na kilka grup, pierwszą z nich są systemy z zastosowaniem wiązki laserowej. System składa się z lasera, który oświetla obiekt linią pomiarową oraz detektora, który rejestruje jej położenie zasadę działania takiego systemu przedstawiono na rys. 3.4.



Rys. 3.4. Zasada działania systemu z zastosowaniem wiązki laserowej [84]


Istnieje również osobna grupa metod wykorzystująca wzorce świetlne, które rzutowane są na badaną powierzchnię. Znając kierunek promieni: od źródła wzorca i od kamery do punktu obrazu wzorca rzutowanego na powierzchnię ciała pozwalają drogą triangulacji na wyznaczenie przestrzennych współrzędnych. Metody te znalazły szerokie zastosowanie w medycynie pozwalając ocenić stan zdrowia pacjenta czy też zastosowanie w badaniach dotyczących budowy anatomicznej [13]. Szeroko rozpowszechnioną metodą jest metoda prążków Moire'a. Polega ona na projekcji prążków jasnych i ciemnych na przemian na obiekcie zasadę przedstawiono na rys. 3.5.



Rys. 3.5. Zasada działania systemu z wykorzystaniem wzorca świetlnego [84]

Rozwinięciem powyższej metody jest zastosowanie dwóch lub większej ilości kamer śledzących punkty kluczowe w scenie. Dla przyspieszenia identyfikacji punktów kluczowych

na obiekcie najczęściej oświetla się go rastrem. Zasadę działania takiego systemu przedstawiono na rys. 3.6.



Rys. 3.6. Zasada działania systemu z wykorzystaniem wzorca świetlnego oraz dwóch kamer [84]

3.3. Metody reprezentacji obiektu

Wyróżniamy trzy główne podejścia, jeśli chodzi o reprezentację obiektu trójwymiarowego. Pierwszym z nich są reprezentacje punktowe, które opisują obiekt przy użyciu punktów na jego powierzchni. Drugim podejściem są metody objętościowe gdzie obiekt opisany zostaje przy pomocy określonego zbioru w 3D. Ostatnią metodą przytaczaną w pracy są reprezentacje opisujące powierzchnię obiektu przy pomocy siatek o określonej strukturze.

Reprezentacje punktowe są to reprezentacje brył, które mogą przyjmować dwa typy struktury pierwszym z nich jest niestrukturalny format danych (punkty nie posiadają określonej struktury). Dane w takim formacie można uzyskać metodami pasywnymi np. kamer stereowizyjnych, które rejestrują punkty kluczowe sceny z dwóch różnych punktów w efekcie generując niestrukturalną chmurę punktów kluczowych sceny [21][22]. Drugim typem jest uporządkowana struktura danych, która najczęściej pozyskiwana jest z wykorzystaniem metod aktywnych np. pozyskując dane ze skanerów tzw. zasięgu i przechowywanych w strukturach zwanych obrazami zasięgu (ang. range images) lub mapami głębi (ang. depth maps). Dokładność współcześnie używanych urządzeń wynosi 0,5 mm [4]. Format przechowywanych danych może przybrać postać macierzy gdzie odpowiednio wiersze i kolumny reprezentują kąty pomiaru dla poszczególnych punktów. Kolejną możliwością jest uzyskanie surowych danych tak, że poszczególne współrzędne XYZ zapisywane są w kolejnych liniach pliku.

Pierwszą z reprezentacji objętościowych jest reprezentacja wykorzystująca do opisu kształtu bryły proste takie jak (sześcian, stożek, walec, sfera) oraz operacje boolowskie wykonywane na nich takie jak (suma, różnica, część wspólna) zdefiniowane w [7]. Takie podejście, zwane również konstruktywnym CSG (ang. Constructive Solid Geometry)

najczęściej wykorzystywane jest w środowiskach CAD (ang. Computer Aided Design) pozwala opisywać duże zbiory obiektów ze względu na parametryczny opis ich elementów. Całość zbioru zbudowana zostaje w oparciu o drzewo z operatorami na kolejnych węzłach którymi oprócz typowych operacji boolowskich mogą być jeszcze przesunięcie, obrót i skalowanie obiektu, zaś liśćmi w tym przypadku są bryły proste. Niewątpliwą wadą tej metody jest fakt, iż nie przechowuje ona informacji o lokalnych deformacjach obiektu a jedynie ogólną topologię powierzchni obiektu.

Drugim typem reprezentacji objętościowych są reprezentacje dekompozycyjne bazujące na podziale przestrzeni na jednakowe mniejsze podprzestrzenie (woksle). Siatka uzyskana w ten sposób zależy od dobranego algorytmu generowania poszczególnych woksli i może przyjmować strukturę regularną lub nieregularną. Struktura tej reprezentacji również najczęściej jest hierarchiczna, ponieważ do podziału przestrzeni wykorzystuje się metodę drzew ósemkowych [8]. Proces tworzenia drzewa ósemkowego rozpoczyna się od otoczenia całego obiektu sześcianem a następnie podziału przestrzeni wewnątrz na 8 jednakowych komórek. Proces ten powtarza się rekurencyjnie aż spełnienia zadanego kryterium końcowego. Kolejną reprezentacją objętościową są reprezentacje z przesunięciem (ang. sweep representation). Metoda ta bazuje na wyznaczeniu przekroju bryły a następnie przesuwania go wzdłuż zadanej ścieżki w ten sposób uzyskuje się powierzchnię bryły. Wykorzystuje się ją do generowania brył obrotowych, zastępując przesunięcie obrotem. Metoda uogólnionych walców (ang. generalized cylinders) została wykorzystana w procesie identyfikacji m. in. w systemie rozpoznawania ACRONYM [9] opracowanym przez Brooksa. Jest ona modyfikacją poprzedniej metody z tą różnicą, że przekrój bryły podczas przesuwania można parametrycznie modyfikować.

Kolejną reprezentacją są reprezentacje powierzchniowe, które opisują obiekt przy pomocy ścian, wierzchołków oraz krawędzi wraz z określeniem zależności pomiędzy nimi. Reprezentację tę nazywamy również B_{rep} (ang. boundary representation) jej pierwsze podstawy opracował Braid [6]. Powierzchnie w tym przypadku reprezentowane są poprzez siatki trójkątów. Pojedynczy trójkąt jest fragmentem powierzchni ograniczonej krawędziami rozpostartych na najbliższych wierzchołkach. W porównaniu do reprezentacji objętościowych CSG posiada znacznie szersze możliwości opisywania deformacji powierzchni obiektu. Modele powierzchniowe można ponadto podzielić w zależności od rozmieszczenia i kształtu podstawowych elementów na modele regularne i nieregularne. Szczególnym przykładem modeli powierzchniowych są teselacje, które definiowane są, jako podział sceny na elementarne obiekty będące figurami o ustalonym kształcie. Pierwsze badania dotyczące tej metody prowadził Kepler [11]. Kolejny znaczny wkład w rozwój tej metody wniósł Fyodorov [10] definiując m. in. grupy przestrzenne. Teselekcja w przestrzeni dwuwymiarowej przypomina mozaikę, której elementy pokrywają całkowicie dany obszar, nie nakładając się na siebie. Wszystkie techniki bazujące na rekonstrukcji w oparciu o metody powierzchniowe bazują na informacji o wzajemnych powiązaniach oraz w większości przypadków wyznaczaniu wektorów normalnych do poszczególnych fragmentów siatki. Niestety najczęściej urządzenia współrzędnościowe nie generują danych w postaci siatek a raczej nieregularnej chmury

punktów. Zastosowanie siatek wielokątów wizualnie poprawia wygląd obiektu jednak negatywnie wpływa na dokładność wyznaczania wymiaru [21].

3.4. Podsumowanie rozdziału

Rozdział prezentuje aktualne możliwości oraz ograniczenia związane z metodami akwizycji i przetwarzania danych wizyjnych. Przedstawiono podstawową klasyfikację modeli reprezentujących obiekty 3D oraz korzyściami i problemami związanymi z każdym z nich. Szczegółowo opisano możliwości oraz techniki związane z akwizycją danych na podstawie, których można utworzyć trójwymiarowy model obiektu. Podstawowymi metodami, które są aktualnie wykorzystywane do rejestracji geometrii obiektu jest skanowanie laserowe i metody fotogrametryczne. Rozdział ma na celu porównanie różnych typów danych oraz metod akwizycji, które mogą zostać wykorzystane podczas budowy diagnostycznego systemu identyfikacji wizualnej.

4. Metody filtracji chmur punktów


4.1. Problem szumu w pomiarach

Dane uzyskane ze skaningu laserowego zawsze obarczone są szumem powstałym podczas pomiarów. Możliwe źródła wpływające na występowanie szumu opisano szerzej w rozdziale 2.2 pt. Ocena dokładności rekonstrukcji. Niezależnie od zastosowanej metody skaningu laserowego zakłócenia są elementem nieuniknionym. Bardzo skuteczną metodą wykrywania błędów grubych jest analiza wykresu przebiegu [65]. Chmury punktów są danymi przestrzennymi, co komplikuje takie podejście jednak poprzez odpowiednią segmentację danych zaproponowaną w rozdziale 6 można ją w ten sposób zinterpretować. Podejście takie pozwala na automatyczne sygnalizowanie nieprawidłowości w danych, np. sygnalizując niezgodność zadanej liczby danych z rzeczywistą liczbą lub wskazując pomiary różniące się od średniej o więcej niż dwa lub trzy odchylenia standardowe. Ponadto istnieje kilka dobrze znanych literaturowych podejść pozwalających na częściową filtrację zakłóceń występujących w chmurach punktów. Metody te mogą być stosowane niezależnie lub łączone w grupy filtrów mające na celu odfiltrowanie szumu o ściśle określonej naturze [27].


4.2. Metody bazujące na wartości współczynnika intensywności oraz barwie powierzchni

Każdy z punktów, w zależności od możliwości skanera, określony jest przez 3 współrzędne przestrzenne względne, w układzie kartezyjskim związanym ze skanerem, przeliczone z układu sferycznego oraz względną wartość intensywności odbitej wiązki. Intensywność jest parametrem określającym współczynnik odbicia wiązki od powierzchni

szerzej opisany w rozdziale 2.3.2 pt. Błędy związane z naturą badanego obiektu. Każdy materiał cechuje się określonym współczynnikiem intensywności [28],[29] dzięki czemu szum powstały po odbiciu wiązki również najczęściej posiada ściśle określoną wartość współczynnika intensywności. Skaner przy użyciu którego wykonywano badania zapisuje wartość intensywności obiektu w postaci wartości numerycznej z zakresu 0-255. Intensywność poszczególnych powierzchni zależy głównie od materiału z którego dana powierzchnia jest wykonana. Równie istotna jest barwa materiału, im jaśniejszy kolor tym intensywność wyższa. Oprogramowanie korzysta z intensywności punktów jako kryterium przynależności danego punktu. Klasyfikuje punkty o tej samej wartości intensywności do jednej grupy. Wynikiem działania programu jest grupa plików zawierających punkty o tej samej intensywności. Na tej podstawie można odszukać segment zawierający relatywnie największą wartość szumu oraz usunąć go z przetwarzanej chmury. Przykład działania programu przedstawiono na rys. 4.1, na którym pokazano dane nieprzetworzone a na rys. 4.2 segment odpowiedzialny za szum został usunięty. Punkt A zaznaczony na rysunkach odpowiada pozycji skanera. Segment zawierający największą wartość szumu posiadał 5% wszystkich punktów znajdujących się w chmurze. Zaletą opracowanego podejścia jest szybkość z jaką oprogramowanie przyporządkowuje grupy punktów. Szybkość ta wynika z faktu, że dla każdego punktu jego intensywność sprawdzana jest tylko raz dzięki czemu już po sprawdzeniu wszystkich punktów uzyskuje się gotowy wynik. Niestety ze względu na wąski zakres wartości intensywności generowany przez skaner następuje automatyczne uśrednienie wartości intensywności dla obiektów posiadających zbliżone parametry współczynnika odbicia powierzchni. W związku z czym intensywność przypisana do szumu również może występować na elementach obiektu co również można zaobserwować na rys. 4.2 jako braki w górnych fragmentach słupa.



Rys. 4.1. Stacja bez wykonanej segmentacji



Rys. 4.2. Stacja po wykonaniu segmentacji oraz usunięciu segmentu odpowiadającego za szum

Istnieje możliwość wzbogacenia informacji pojedynczego punktu o wartości dodatkowe np. koloru RGB odpowiadającą odwzorowywanemu punktowi. Informację o barwie pozyskuje się z kamer bądź aparatów cyfrowych sprzężonych ze skanerem bądź pracujących niezależnie. Analogicznie do podejścia przedstawionego dla intensywności można przeprowadzić filtracje

w oparciu o wartość współczynnika RGB, który zdecydowanie rozszerza wychwytywanie oraz klasyfikowanie punktów, nawet o bardzo zbliżonej barwie, w sposób poprawny.

4.3. Filtracja na bazie odległości od skanera

Proces filtracji chmury punktów najczęściej ma na celu odfiltrowanie szumu powstałego podczas pomiaru. Można ją również wykorzystać, jako metodę do ograniczenia ilości punktów do przetwarzania. Bardzo często badając jakiś obiekt, pomimo iż zależy nam tylko na jego powierzchni musimy przeskanować również część sceny wokół niego, co uwarunkowane jest specyfiką działania samego skanera. Zwykle uzyskuje się, więc znaczą ilość punktów nadmiarowych znajdujących się zarówno przed jak i za obiektem. W tym celu stosuje się filtry pozwalające na określenie odległości minimalnej jak i maksymalnej od skanera, aby jak najdokładniej wyznaczyć przestrzeń istotną z punktu widzenia pomiaru. Filtry tego typu najczęściej zaimplementowane są już w samym oprogramowaniu do urządzenia. Przy ich użyciu nie ma możliwości określenia na tyle precyzyjnego zakresu odległości minimalnej i maksymalnej, aby pozostał sam obiekt, dlatego też filtry te wykorzystywane są, jako pierwszy element przygotowania danych.

4.4. Filtracja na bazie lokalnego sąsiedztwa

Kolejną grupą filtrów są filtry analizujące lokalne sąsiedztwo punktów w chmurze punktów. Filtry te można podzielić na 3 grupy scharakteryzowane ze względu na ilość operacji wykonywanych w jednej chwili czasu. Poniżej wyróżniono najczęściej spotykane możliwości wzajemnej relacji [47]:

Punkt – Punkt – te algorytmy [48],[49] operują tylko na dwóch punktach w jednym kroku, funkcja dyskryminacyjna bazuje na odległościach obu punktów. W przypadku, jeśli na wyjściu funkcji dyskryminującej pojawi się wartość wyższa niż założony próg, wtedy jeden z punktów zostaje zakwalifikowany, jako obiekt znajdujący się na obiekcie.

Punkt – Punkty – te metody [50],[51] operują na jednym punkcie, który aktualnie jest badany oraz grupie punktów z najbliższego sąsiedztwa. Na bazie wyników funkcji dyskryminującej następuje klasyfikacja punktów.

Punkty – Punkty – w tych metodach [52],[53] do rozwiązania funkcji dyskryminującej wykorzystuje się grupy punktów. Algorytmy te różnią się od dwóch poprzednich tym, iż w jednym kroku następuje klasyfikacja większej ilości punktów.

Chmury punktów nie są danymi o jednolitej strukturze, co wynika z skomplikowanej geometrii badanych scen oraz właściwości materiałów, z których te sceny się składają. Dlatego

na podstawie algorytmów bazujących na określaniu lokalnego sąsiedztwa można wydzielić obszary o zdecydowanie rzadszej i nieregularnej strukturze, która bardzo często cechuje szum.

Podejście to wykorzystano również w opracowanym oprogramowaniu, aby zmniejszyć rozmiar zbioru do przetwarzania skorzystano w tym przypadku z implementacji algorytmu kNN (ang. k Nearest Neighbor) [42]. Przykład wykonania algorytmu przedstawiono na rys. 4.3. Algorytm można zakwalifikować do grupy Punkt – Punkty, dlatego, że dla każdego z punktów zostaje zliczona określona liczba sąsiadów znajdujących się w sferze o zdefiniowanym promieniu. W przypadku, gdy liczba sąsiadów w obrębie sfery nie spełni wcześniej założonego kryterium o minimalnej ilości sąsiadów punkt zostaje zakwalifikowany, jako szum. Algorytm wykonuje się iteracyjnie do czasu aż wszystkie punkty zostaną sprawdzone. Takie rozwiązanie można zastosować w przypadku scen, w których różnica odległości obiektów w scenie jest niewielka tj. obiekty skanowane są blisko siebie lub w tej samej odległości od skanera. Wiąże się to ze wzrostem odległości pomiędzy punktami pomiarowymi wraz ze wzrostem odległości badanego obiektu. Punkty sklasyfikowane jako szum zostają odpowiednio sklasyfikowane, do niezależnej struktury o określonej barwie. Operator ma możliwość testowania różnych wartości parametrów przed końcowym zaakceptowaniem zmian.



Rys. 4.3. Przykład wykorzystania filtracji na bazie wykrywania zagęszczenia punktów

4.5. Podsumowanie rozdziału

W rozdziale skupiono się na metodach filtracji danych pod kątem przetwarzania chmur punktów. Przedstawiono problem szumu w danych skaningowych oraz różne podejścia stosowane w zależności od specyfiki szumu. Zaproponowano własną metodę pozwalającą na filtrację chmur punktów w oparciu o pomiar współczynnika intensywności odbicia wiązki laserowej dla każdego z punktów. Metoda w oparciu o informację na temat intensywności wiązki odbitej od punktów tworzy klasy niezależnych obiektów. Po ustaleniu wartości intensywności, która w danym przypadku odpowiada za szum pozwala usunąć tę klasę z danych. Dane odpowiadające za szum cechują się granicznymi wartościami intensywności, dlatego bardzo łatwo można je wyszukać. W rozdziale zaprezentowano wynik filtracji dla słupa energetycznego. Kolejna metoda pozwala usunąć losowe błędy pomiarowe powstałe w skutek błędnego pomiaru odległości. Metoda została oparta na algorytmie kNN (k Nearest Neighbor). Wyniki działania metody również przedstawiono na przykładowych danych rzeczywistych.

5. Metody segmentacji chmur punktów

5.1. Cel segmentacji i klasyfikacja stosowanych metod

Proces segmentacji chmury punktów jest niezbędnym krokiem ze względu na objętość danych skaningowych. Możliwość łączenia (rejestracji) kilku skanów ze sobą skutkuje uzyskaniem bardzo obszernych zbiorów danych liczonych w milionach punktów. Jedynym ograniczeniem w zwiększaniu objętości danych są możliwości sprzętowe i programowe urządzeń wykorzystywanych do ich analizy. Dlatego też problem grupowania i podziału danych na mniejsze elementy jest problemem bardzo aktualnym [87], [93]. Systemy doradcze bazujące na danych skaningowych wymagają odpowiedniej reprezentacji właściwości i własności badanego obiektu. Jedną z form takiej reprezentacji jest trójka: obiekt, atrybut, wartość atrybutu, gdzie wartości atrybutu przyjmują postać ilościową bądź jakościową [67].

Celem zastosowania systemów doradczych w procesie wnioskowania o stanie technicznym obiektu jest prowadzenie jakościowej oceny stanu na podstawie wartości obserwowanych cech sygnałów diagnostycznych [68]. Jednym ze sposobów oceny jakościowej ilości cech sygnałów może być zastosowanie algorytmów grupowania i klasyfikacji. Niestety żaden z obecnie dostępnych algorytmów nie jest w stanie sprawdzić się w każdych warunkach, które silnie zależą zarówno od warunków pomiaru jak i specyfiki skanowanego obiektu czy sceny.

Można wyróżnić wiele algorytmów grupowania i klasyfikacji elementów zarówno w przestrzeni dwu- jak i wielowymiarowej. Do najpopularniejszych można zaliczyć:

- algorytmy hierarchicznego podziału i grupowania,
- algorytmy grupowania k-średnich,
- algorytmy łączenia dwuwymiarowego,

- algorytmy grupowania iteracyjnego.

Algorytmy te najczęściej przeprowadzają grupowanie elementów w oparciu o kryteria uwzględniające:

- miary podobieństwa,
- odległość Mahalanobisa,
- odległość Minkowskiego,
- odległość Euklidesowa,
- odległość Manhattan.

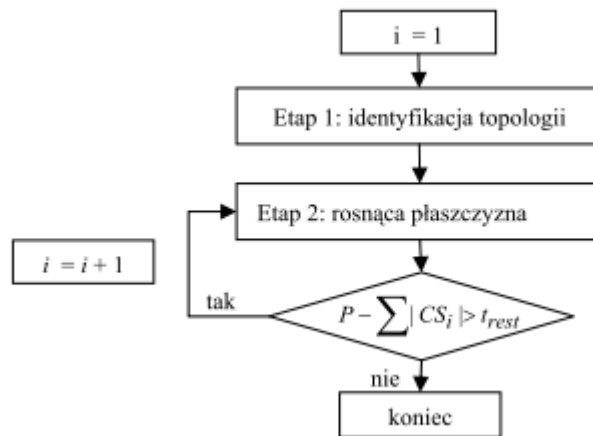
W przypadku danych skaningowych bardzo często stosuje się również metody klasyfikujące dane w oparciu o dokładne wzorce klas obiektów takich jak np. podstawowe bryły lub wcześniej przygotowane deskryptory obiektów [97],[99]. W celu minimalizacji objętości chmury punktów najczęściej stosowaną klasą obiektów są płaszczyzny. Jest to uwarunkowane stosunkowo prostą implementacją i weryfikacją algorytmu. Ponadto płaszczyzny zawierają relatywnie dużo punktów pomiarowych, dlatego też celem jest ich segmentacja już na wczesnym etapie przetwarzania. W przypadku danych z skaningu lotniczego pierwszym etapem przetwarzania jest wydzielenie płaszczyzny reprezentującej topologię terenu [81].

5.2. Metoda rosnących płaszczyzn

Metoda rosnących płaszczyzn jest uogólnieniem, na przestrzeń R^3 , algorytmu rosnących regionów powszechnie wykorzystywanego w cyfrowym przetwarzaniu obrazów w R^2 [53]. Algorytm ma za zadanie wyznaczenie równania płaszczyzny oraz punktów, które zostały do niej sklasyfikowane. Algorytm obejmuje dwa podstawowe etapy:


- przygotowanie danych polegające na ustaleniu ich topologii oraz
- proces identyfikacji i ekspansji płaszczyzn.

Proces określania topologii bazuje na wykorzystaniu modyfikacji algorytmu kNN. Do podziału przestrzeni wykorzystuje się najczęściej drzewa binarne, które dzielą przestrzeń trójwymiarową na hierarchiczną strukturę danych [56]. Diagram aktywności algorytmu rosnących płaszczyzn przedstawiono na rys. 5.1.



Rys. 5.1. Algorytm rosnących płaszczyzn. Diagram aktywności [55]

Proces identyfikacji poprzedzony zostaje przygotowaniem danych na podstawie wyodrębnionego zbioru punktów sąsiednich. Dla każdego z punktów dopasowuje się lokalną płaszczyznę w oparciu o metodę estymacji odpornej w celu uniknięcia sąsiadów nienależących do płaszczyzny. Kolejnym krokiem jest wyznaczenie średniej odległości pomiędzy punktami użytymi do estymacji płaszczyzny lokalnej oraz samą płaszczyznę lokalną. Proces rozpinania płaszczyzny przedstawiono na rys. 5.2.




Rys. 5.2. Graficzne przedstawienie kolejnych kroków identyfikacji płaszczyzny

Proces identyfikacji płaszczyzny rozpoczyna się od wyboru jednego punktu należącego do obiektu (zwykle punkt, którego odległość pomiędzy punktami sąsiednimi jest najmniejsza). Początkowe parametry identyfikowanej płaszczyzny równe są parametrom płaszczyzny wpasowanej lokalnie. Następnie następuje rozrost płaszczyzny w oparciu o punkty zaklasyfikowane, jako najbliższe. Sprawdzane jest kryterium odległości od rosnącej płaszczyzny oraz różnica pomiędzy wektorami normalnymi płaszczyzny rosnącej i płaszczyzn lokalnych. Można również wykorzystać kryteria dodatkowe bazujące np. na wartościach koloru RGB poszczególnych punktów [58].

5.3. Wykrywanie obszarów o zwiększonej gęstości

Jak już wielokrotnie wspomiano chmura punktów nie jest zbiorem danych jednorodnych o ciągłej strukturze. Wynika to najczęściej skomplikowanej geometrii obiektu skanowanego oraz niejednorodnych materiałów w skanowanej scenie. Efektem tego jest zwiększona gęstość w jednym miejscu oraz brak punktów w innym. Najczęściej obiekt, interesujący z punktu widzenia pomiaru, posiada strukturę powierzchni pozwalającą na przeprowadzenie pomiaru, jednak obiekty znajdujące się w jego sąsiedztwie mogą generować zakłócenia w postaci szumu w otoczeniu badanego obiektu.

Algorytm bazuje na określaniu lokalnego sąsiedztwa punktów jednak nie dopasowuje żadnego sparametryzowanego obiektu jak to miało miejsce w algorytmie rosnących płaszczyzn. Algorytm rozpoczyna wyszukiwanie od grupy losowych punktów, spośród danych pomiarowych, a następnie w oparciu o dwa kryteria odległości stara się wydzielić grupy punktów, które znajdują się w określonym sąsiedztwie. Pierwszym kryterium jest odległość pomiędzy punktami, w której wyszukuje się sąsiadów. Drugie kryterium określa maksymalną dopuszczalną odległość pomiędzy klastrami. Parametr ten ma kluczowy wpływ na liczbę uzyskanych klastrów. Im wyższa jest jego wartość, tym odległość pomiędzy kolejnymi klastrami może być wyższa, a co za tym idzie, ilość klastrów w scenie zmaleje. Przykład implementacji algorytmu w autorskim oprogramowaniu przedstawiono na rys. 5.3. W rzeczywistości obiekty testowe znajdowały się na regale koloru czarnego. Co poskutkowało brakiem punktów na jego powierzchni. W efekcie działania programu uzyskano 14 niezależnych segmentów, które następnie zapisano w odrębnych plikach reprezentujących obszary, w których można przeprowadzić próby identyfikacji obiektu dla zdecydowanie mniejszego zbioru danych. Punkty niesklasyfikowane do żadnego z segmentów zapisano, jako segment reprezentujący szum.



Rys. 5.3. Segmentacja na bazie gęstości chmury

5.4. Metoda RANSAC

Algorytm RANSAC (ang. RANdom SAmple Consensus) został opracowany i opublikowany po raz pierwszy w 1981 przez M. Fischler'a i R. Bolles'a [43] do celów widzenia komputerowego. Jest to iteracyjna metoda estymacji parametrów modelu matematycznego na podstawie zbioru zaobserwowanych danych. Algorytm został zaprojektowany do radzenia sobie z dużym udziałem wartości skrajnych w danych wejściowych [59],[60]. Warto dodać, że procentowy udział wartości skrajnych może być równy nawet 50% całej próbki danych [61].

Podstawową zasadą opisywanej metody jest założenie, że wejściowa próbka składa się z danych, których rozmieszczenie można opisać podanym zestawem parametrów oraz takich danych, które nie pasują do opisywanego modelu. Przykładem może być linia prosta w przypadku obrazów dwuwymiarowych lub płaszczyzna dla chmury punktów. Z kolei błędami grubymi są punkty nienależące do modelowanej powierzchni. Algorytm składa się z dwóch iteracyjnie wykonywanych kroków hipotezy oraz testu.

Na etapie hipotezy należy określić liczbę k najmniejszych zbiorów, która określa ilość danych potrzebnych do jednoznacznego opisu modelu geometrycznego. Dla płaszczyzny są to np. trzy punkty. Parametrem wejściowym metody jest parametr T_{iter} , który określa wstępną liczbę minimalnych zbiorów s_t (5.1) do wylosowania. Liczba ta w trakcie działania algorytmu jest modyfikowana

$$s_t \in \{S \subset P, |S| = k\} \rightarrow M_t \quad (5.1)$$

W następnym kroku wyznaczone zostają parametry modelu M_t . W przypadku płaszczyzny jest to wyznaczenie równania płaszczyzny przechodzącej przez trzy punkty. Następnie tak uzyskana hipoteza podlega kolejnemu krokowi, jakim jest test.


Etap testu wymaga określenia najczęściej dodatkowego parametru w przypadku płaszczyzny jest to maksymalna dopuszczalna odległość punktu od płaszczyzny.

Ogólna postać algorytmu RANSAC przedstawia się następująco [62]:

- 1: Wybierz losowo minimalną liczbę punktów wymaganą do określenia parametrów modelu.
 - 2: Oblicz parametry modelu.
 - 3: Określ, ile punktów z całego zestawu danych pasuje do ustalonego modelu.
 - 4: Jeśli liczebność znalezionej zbioru punktów jest możliwie największa dla opisywanego modelu to zakończ działanie algorytmu.
 - 5: W przeciwnym wypadku, powtórz kroki 1-4 (maksymalnie N razy).
- Na rys. 5.4 i 5.5 zaprezentowano przykład działania opisywanej metody.



Rys. 5.4. Wejściowa próbka danych [63]



Rys. 5.5. Prezentacja wyniku działania algorytmu RANSAC [63]

Na rys. 5.4 przedstawiono wizualizację przykładowego zestawu danych na podstawie, którego sprawdzono działanie algorytmu RANSAC. Rysunek 5.5 prezentuje wynik działania algorytmu, gdzie poszukiwanym wzorcem jest linia. Punkty oraz linia zaznaczone na rysunku kolorem niebieskim są rezultatem działania algorytmu i reprezentują dane przynależne do modelowanego wzorca. Z kolei kolor czerwony oznacza te dane, które nie pasowały do przyjętego modelu, czyli tzw. „błędy grube”.

Podsumowując rozważania na temat wykrywania płaszczyzn z wykorzystaniem algorytmu RANSAC można stwierdzić, że metoda ta charakteryzuje się [64]:

- algorytmem stosunkowo łatwym do implementacji,
- możliwością przetwarzania dużych próbek danych,
- odpornością na szum lub przypadkowe odbicia od powierzchni,
- wysoką wydajność,
- dane wejściowe mogą zawierać do 50% punktów nie przynależnych do modelowanej powierzchni.

Niestety RANSAC w swej bazowej postaci jest przystosowany do wykrywania obiektu, który reprezentowany jest przez największą liczbę punktów. Uzyskujemy, więc rozwiązanie najbardziej prawdopodobne. W przypadku danych rzeczywistych bardzo często pojawia się potrzeba wyszukania większej ilości obiektów, co z punktu widzenia automatyzacji procesu komplikuje sprawę. Pojawia się problem określenia kryterium kończącego wyszukiwanie. Zwykle dla danych symulacyjnych określa się procent punktów, które mogą pozostać nieprzypisane do żadnego obiektu, algorytm wykonuje się dopóki określony próg nie zostanie osiągnięty. Podejście takie nie ma jednak zastosowania podczas pracy na danych rzeczywistych. Osoba przetwarzająca dane nie musi być ekspertem znającym specyfikę oraz budowę poszczególnych elementów instalacji, aby móc określić z ilu obiektów i jakiego typu się ona składa. Początkowo problem rozwiązywano iteracyjnie w oparciu o dialog z operatorem. Algorytm wyszukiwał obiekt np. walec reprezentowany przez

największą liczbę punktów w scenie, a następnie usuwał jego punkty i prosił operatora o ponowne wyszukiwanie. Cykl wykonywał się do czasu aż wyszukano wszystkie obiekty w chmurze. Proces dialogowy jednak znacznie spowalniał przetwarzanie, dlatego szukano nowych rozwiązań.

Drugim podejściem była identyfikacja obiektów w obrębie wyznaczonych klastrów na bazie metody wyszukiującej zagęszczenia punktów w chmurze. To rozwiązanie jest zdecydowanie szybsze ze względu na znaczne ograniczenie zbioru do wyszukiwania, co przekłada się na zmniejszenie liczby iteracji. Wykorzystanie metody bazującej na klastrach jest jednak ograniczone specyfiką badanej sceny. Można ją wykorzystać w przypadku, kiedy klastry reprezentują obiekty różnych typów. Kolejnym ograniczeniem jest ograniczona zdolność identyfikacji modelu w obrębie danych, w których punkty nieprzypisane do modelu stanowią więcej niż 50% ogółu danych. W przypadku danych rzeczywistych 50% próg punktów poza obiektem jest osiągniany bardzo szybko, dlatego też wykorzystanie metody RANSAC jest znacznie ograniczone.

5.5. Transformata Hougha

5.5.1. Ogólny zarys metody

W roku 1905 W. Radon udowodnił następujące twierdzenie: „Obraz obiektu dwuwymiarowego można zrekonstruować na podstawie nieskończonej ilości rzutów jednowymiarowych”, rzutowanie to odpowiada wykonywaniu na obiekcie pewnej transformacji, nazywanej Transformacją Radona [71]. Transformata Radona zamienia funkcję z przestrzeni dwuwymiarowej, opisaną współrzędnymi przestrzennymi, na przestrzeń Radona. W metodach rozpoznawania obrazów transformata Radona jest stosowana do wykrywania przede wszystkim linii, a na ich podstawie kształtów obiektów. Transformacja Radona obrazu $f(x,y)$ jest zdefiniowana równaniem (5.2) [70].

$$Rf(\theta, t) = \int f(x, y) \delta(x \cdot \cos(\theta) + y \cdot \sin(\theta) - t) dx dy \quad (5.2)$$

W którym :

δ – dystrybucja Diraca

Z równania (5.2) wynika, że transformacja ta jest całką obrazu wzdłuż linii prostej danej równaniem (5.3)

$$x \cos(\theta) + y \sin(\theta) - t = 0 \quad (5.3)$$

Transformacja jest ściśle powiązana z transformacją Fouriera [72]. Związek ten wynika z właściwości transformacji Fouriera znanej, jako Fourier Slice Theorem a mówiącej, że transformacja Fouriera rzutu obrazu na oś pionową jest równa poziomemu profilowi

dwuwymiarowej transformacji Fouriera tego obrazu [73]. W roku 1981 spostrzeżono [74], że opracowana przez Hougha metoda jest szczególnym przypadkiem transformaty Radona.

5.5.2. Metoda transformaty Hougha dla obrazów dwuwymiarowych

Transformata Hougha jest narzędziem pozwalającym na wykrywanie określonych wzorców na obrazach binarnych. Jej podstawowym założeniem jest możliwość wyznaczenia zbioru parametrów opisujących szukany wzorec [95]. Początkowo służyła tylko do wykrywania linii prostych, jednak wkrótce została uogólniona do wykrywania innych wzorców regularnych w tym okręgów i elips. Transformata Hougha zdobyła z czasem wielką popularność i do dzisiaj jest jedną z wiodących metod wykrywania kształtów na obrazach, w związku z czym znalazła szerokie zastosowanie m.in. w widzeniu komputerowym. Jest metoda bardzo często wykorzystywana w segmentacji obrazu [92].

Rozważania poruszane w tym podrozdziale dotyczą wyznaczania prostych na płaszczyźnie, jako iż analogiczne postępowanie należy przyjąć w przypadku wyszukiwania płaszczyzn w przestrzeni trójwymiarowej. Transformata Hougha bazuje na kilku podstawowych założeniach:

- **prostej** w przestrzeni kartezjańskiej odpowiada **punkt** (r, α) w przestrzeni Hougha
- **punktowi** w przestrzeni kartezjańskiej odpowiada sinusoidalna **krzywa** w przestrzeni Hougha
- transformacja przeprowadzana jest na **obrazach binarnych**
- przestrzeń Hougha jest **przestrzenią akumulacyjną** można ją sobie wyobrazić, jako tablicę dwuwymiarową
- punkty leżące na tej samej prostej korespondują z sinusoidami przechodzącymi przez **wspólny punkt w przestrzeni Hougha**

Prostą o równaniu $y = ax + b$ można zapisać w postaci równania (5.3)

$$y = \left(-\frac{\cos \alpha}{\sin \alpha}\right)x + \left(\frac{r}{\sin \alpha}\right) \quad (5.3)$$


w którym:

(r, α) – współrzędne biegunowe punktu (x, y) względem punktu $(0, 0)$.

Zatem $r = x \cos \alpha + y \sin \alpha$ (x oraz y są stałe). Przestrzeń, którą tworzą pary (r, α) gdzie $r \in \mathbb{R}^+ \cup \{0\}$ i $\alpha \in [0, \pi]$ nazywamy przestrzenią Hougha przedstawioną na rys. 5.6.B oraz 5.6.C. Gdy ustalony zostanie punkt (x_0, y_0) przykładem może być punkt p4 przedstawiony na rys. 5.6.A, przez który przechodzą badane proste otrzymamy równanie (5.4):

$$r(\alpha) = |x_0 \cos \alpha + y_0 \sin \alpha| \quad (5.4)$$

Korzystając z równania (5.4) zapisywane są kolejne proste w przestrzeni Hougha rys 5.6B. Na rys. 5.6 przedstawiono przykład kolejnych etapów wykrywania pojedynczej linii w obrazie płaskim.



Rys. 5.6. Przykład wyszukiwania prostej z wykorzystaniem Transformaty Hougha

Samą procedurę wykonywania algorytmu dla rozpatrywanego przypadku można podzielić na kilka etapów. Pierwszym etapem jest przeprowadzenie pęku prostych przez każdy punkt obrazu, a następnie dla każdej z tych prostych wykreślenie promienia wodzącego. Wyznaczenie długości oraz wartości kąta pomiędzy promieniem, a osią OX pozwala na otrzymanie dwóch parametrów, które odpowiadają współrzędnym punktu, który reprezentuje rozpatrywaną prostą w przestrzeni Hougha. W ten sposób każdy punkt obrazu pierwotnego jest odwzorowany sinusoidalną krzywą w przestrzeni Hougha. Każda krzywa odpowiada jednemu z punktów widocznych na rys. 5.6.A. Punkt przecięcia sinusoid przedstawionych na rys.5.6.C odpowiada prostej, na której znajdują się wszystkie rozpatrywane punkty. Współrzędne tego punktu (kąt nachylenia oraz długość wektora normalnego) umożliwiają ponowne transformowanie prostej do przestrzeni XY. Metoda znalazła również zastosowanie przy wykrywaniu innych kształtów takich jak okręgi, elipsy, parabole.

Przestrzeń Hougha jest przestrzenią akumulacyjną tzn.: „punkty sinusoidalnych krzywych, wygenerowanych dla różnych punktów obrazu pierwotnego dodają się w miejscach, w których krzywe te przecinają się. Powstałe w ten sposób maksima odpowiadają zbiorom punktów, należących do jednej prostej. Wartość maksimum odpowiada ilości współliniowych punktów. Współrzędne r, α tego maksimum jednoznacznie określają położenie prostej na obrazie pierwotnym” [75].

5.5.3. Metoda transformaty Hougha dla obrazów trójwymiarowych

Transformata Hougha w przestrzeni sprowadza się do rozszerzenia przestrzeni Hougha o dodatkowy parametr, jakim jest kąt odchylenia wektora normalnego od osi Z. Poniżej przedstawiono algorytm wykonywania głosowania, które należy wykonać dla każdego z punktów [76]. Można zauważyć, że jest to najbardziej czasochłonny etap metody.

Algorytm:

```

1: for wszystkie punkty  $P_i$  in zbiór  $X$  do
2:   for wszystkie komórki  $(\alpha, \beta, r)$  in akumulator  $A$  do
3:     if punkt  $p_i$  leży na płaszczyźnie zdefiniowanej przez  $(\theta, \varphi, \rho)$ 
         then
4:       increment komórka  $A(\theta, \varphi, \rho)$ 
5:     end if
6:   end for
7: end for
8: Wyszukaj komórki z najwyższą wartością akumulacji

```

Własności transformaty Hougha w przestrzeni trójwymiarowej [3]:

- każdy **punkt** przecięcia w przestrzeni Hougha odpowiada szukanej **płaszczyźnie** w przestrzeni R^3 ,
- **punktowi** w przestrzeni R^3 odpowiada **sinusoidea 3D** w przestrzeni Hougha,
- **punkt** w przestrzeni Hougha opisany jest **trzema parametrami** (φ, θ, ρ)

Długość wektora normalnego określającego odległość płaszczyzny od początku układu współrzędnych wyznaczono korzystając z równania (8)

$$r = p_x \cdot \cos \theta \cdot \sin \varphi + p_y \cdot \sin \varphi \cdot \cos \theta + p_z \cdot \cos \varphi \quad (8)$$

w którym:

- φ – kąt pomiędzy płaszczyzną XY a wektorem normalnym w kierunku osi Z ,
- θ – kąt pomiędzy wektorem normalnym a płaszczyzną XY ,
- r – odległość punktu od początku układu współrzędnych,
- p – punkt na płaszczyźnie.

Algorytm odnoszący się do omawianej metody można zapisać następująco:

Algorytm:

```


1: for wszystkie punkty  $P_i$  in zbiór  $P$  do
2:   for wszystkie komórki  $(\theta, \varphi, \rho)$  in akumulator  $A$  do
3:     if punkt  $P_i$  leży na płaszczyźnie opisanej przez parametry  $(\theta, \varphi, \rho)$ 
         then
4:       increment komórka  $A(\theta, \varphi, \rho)$ 
5:     end if
6:   end for
7: end for
8: znajdź komórki z najwyższą wartością w akumulatorze, co definiuje wykrytą płaszczyznę
   w zbiorze  $P$ .

```

Zasadę działania algorytmu można określić procesem głosowania, czyli inkrementacji wartości w danej komórce akumulatora. Każdy punkt głosuje na zestaw parametrów reprezentujących płaszczyznę, na której dany punkt może leżeć. Komórka, w której wartość jest największa wskazuje na płaszczyznę obejmującą najwięcej punktów z całej chmury. Jest to najbardziej czasochłonny etap, gdyż należy przeprowadzić głosowanie dla każdego punktu ze zbioru danych. Z tego powodu powstało kilka modyfikacji algorytmu, które mają na celu zmniejszenie ilości potrzebnych iteracji. Najpopularniejszymi z nich są:


- RHT (ang. Randomized Hough Transform) – obliczenia wykonywane są dla losowo wybranych trójek punktów, licznik zwiększany jest tylko w tej komórce, która zawiera wszystkie wybrane punkty, dzięki takiej procedurze otrzymywane są bardziej stabilne wyniki,
- SHT (ang. Standardized Hough Transform) – rozpatrywane są wszystkie punkty z zadanej próbki danych, co bezpośrednio wpływa na czas wykonywanych obliczeń, który w przypadku tej metody jest najdłuższy,
- PHT (ang. Probabilistic Hough Transform) – transformata Hougha wyznaczana jest dla procentowego wycinka danych, który określany jest na podstawie oczekiwanego poziomu szumu,
- PPHT (ang. Progressive Probabilistic Hough Transform) – badane punkty są losowo wybierane z wejściowego zestawu danych, dodatkowo algorytm charakteryzuje się mniejszą wrażliwością na szum.

Struktura danych, w której przechowywane są wszystkie komórki i ich wartości nazywana jest akumulatorem. Rodzaj wybranej struktury może wpływać na szybkość oraz jakość wykrywania płaszczyzn w chmurach punktów. Mniejsza liczba komórek w akumulatorze zmniejsza czas wykonywania się metody, jednak może wpłynąć na poprawne wyszukiwanie płaszczyzn. Na rys. 5.7 zaprezentowane różne rodzaje akumulatorów [76]: 1 – tablica 3D, 2 – sześciąt, 3 – ośmiościan, 4 - kula.




Rys. 5.7. Typy akumulatorów [76]

Wygenerowano programowo płaszczyznę jak na rys. 5.8. Płaszczyzna została wyświetlona w przestrzeni kartezjańskiej. Na jej powierzchni zaznaczono punkty, dla których zostało wykonane przetwarzanie. Poprzez przetworzenie punktu rozumie się obliczenie wektorów normalnych do poszczególnych płaszczyzn. Łącznie testowa płaszczyzna zawierała 50 punktów pomiarowych.




Rys. 5.8. Płaszczyzna weryfikacji możliwości transformaty Hougha 3D

Kwantyzacja przestrzeni dla obojga kątów φ i θ została ustalona na 1° . Tak gęsty podział przestrzeni pozwala na precyzyjne odtworzenie kształtu sinusoidy 3D (rys.5.9), co w rezultacie przekłada się na dokładność odtworzenia wyszukiwanej płaszczyzny [77].



Rys. 5.9. Reprezentacja pojedynczego punktu w przestrzeni Hougha, jako sinusoida 3D

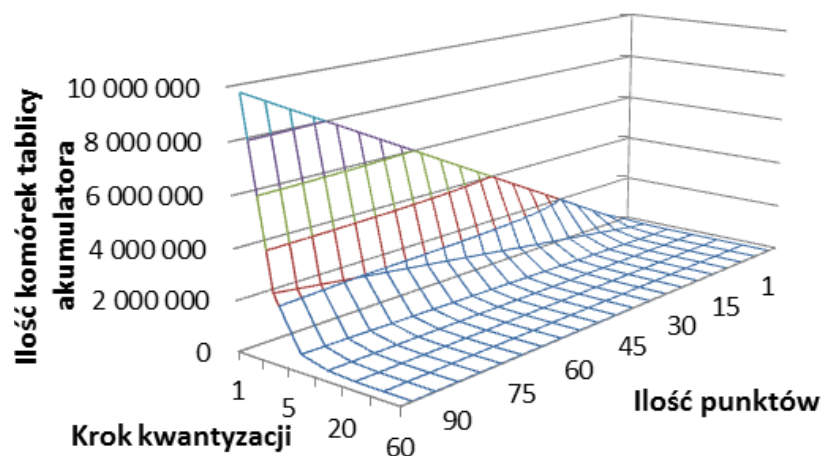
Na rys. 5.10 przedstawiono przykład trzech punktów, które leżą w jednej płaszczyźnie. Płaszczyźnie w trójwymiarowej przestrzeni Hougha odpowiada punkt przecięcia trzech sinusoid 3D. Punkt odpowiadający wyszukiwanej płaszczyźnie zaznaczono na rys. 5.10 zieloną kropką.



Rys. 5.10. Punkt przecięcia sinusoid 3D reprezentuje parametry szukanej płaszczyzny

W przypadku, jeśli uzyska się przecięcie tylko dwóch sinusoid 3D punkt przecięcia wskaże prostą pomiędzy dwoma punktami, których sinusoidy się przecięły. W przypadku danych o niewielkiej liczbie punktów wejściowych takich jak na rys. 5.8 można pozwolić sobie na próbę precyzyjnego odtworzenia powierzchni. Rysunek 5.9 pokazuje jednak jak dużo wartości należało obliczyć, aby wyznaczyć powierzchnię tylko pomiędzy 3 punktami. Dlatego też należy rozważyć dobierać stopień kwantyzacji do ilości danych przetwarzanych [78].

Główną wadą metody jest jej wysoki koszt obliczeniowy oraz w przypadku przestrzeni 3D problem organizacji akumulatora, który dla rozległych chmur punktów zajmuje znaczny obszar pamięci. Wykres na rys. 5.11 przedstawia przyrost tablicy akumulatora w zależności od ilości punktów oraz przyjętego kroku kwantyzacji.



Rys. 5.11. Zależność ilości punktów oraz kroku kwantyzacji do wielkości tablicy akumulacji

Można zauważyć, że dobór kroku kwantyzacji musi być kompromisem pomiędzy dokładnością wyznaczenia płaszczyzny a wielkością tablicy akumulatora.

Oprócz wyboru odpowiedniego akumulatora, podczas implementacji należy mieć też na uwadze szereg parametrów, które wpływają na szybkość działania algorytmu oraz otrzymane wyniki. Poniżej zebrano najważniejsze z nich [79]:

- Parametry zakończenia działania algorytmu:
 - minimalna ilość punktów, które mogą nie zostać przypisane do żadnej z płaszczyzn,
 - maksymalna ilość wykrytych płaszczyzn.
- Parametry decydujące o wydajności algorytmu:
 - kwantyzacja przestrzeni, bezpośrednio wpływa na czas wykonywania algorytmu, ale też na dokładniejsze wyznaczenie kształtu sinusoidy 3D, co z kolei przekłada się na dokładniejsze odwzorowanie położenia rzeczywistej płaszczyzny
- Parametry wpływające na wykrywanie szumu:
 - dopuszczalna odległość punktu od płaszczyzny, czyli wskazanie na punkty, które są traktowane, jako szum,
 - minimalna ilość punktów, które muszą być przypisane do pojedynczej płaszczyzny.

5.6. Podsumowanie rozdziału

W rozdziale przedstawiono istotę stosowania segmentacji danych oraz rozwiązanie problemu segmentacji danych. Wyróżniono podstawowe algorytmy oraz kryteria wykorzystywane do segmentacji i klasyfikacji elementów w zbiorze danych. Szczegółowo opisano zasadę działania możliwości oraz wady metod istotnych z punktu widzenia pracy wykorzystywanych do przetwarzania chmur punktów. Główny nacisk położono na metody pozwalające na segmentację płaszczyzn z tego względu, że są to elementy, które najczęściej przypisane są do znacznego procentu danych. W celu szybkiej redukcji wielkości zbioru kluczowe jest wyznaczenie segmentów reprezentujących płaszczyzny oraz wyłączenie ich z procesu dalszego przetwarzania. Klasycznym podejściem w tym przypadku są metody: rosnących płaszczyzn, RANSAC oraz transformata Hougha dla chmur punktów. W rozdziale zaproponowano metodę segmentacji bazującą na wyznaczaniu różnic gęstości chmury punktów. Metoda pozwala na wyznaczenie zagęszczeń punktów, które najczęściej reprezentują badany obiekt, a następnie tworzy segment odpowiadający temu zagęszczeniu. W rozdziale zaprezentowano również przykład wykorzystania metody oraz wynik jej działania. Rozdział w znacznej objętości dotyczy metody transformaty Hougha, ze względu na jej wykorzystanie podczas praktycznej realizacji tez postawionych w pracy. Poza opisem oraz różnicami związanymi z wykorzystaniem metody dla obrazów 2D oraz 3D przedstawiono również podstawowe ograniczenia wynikające przyrostu tablicy akumulatora wraz z wzrostem liczby punktów. Wykazano, że zastosowanie metody transformaty Hougha w przetwarzaniu rzeczywistych danych, które często liczą wiele mln punktów przestrzennych jest nieefektywne. Szczegółowo opisano również metodę transformaty Hougha dla obrazów 2D, dlatego że jest ona jednym z kluczowych etapów segmentujących dane w zaproponowanej metodzie.

6. Metoda identyfikacji obiektu wykorzystująca przetwarzanie pojedynczych linii

6.1. Problemy implementacji algorytmów

Większość problemów związanych z problemem przetwarzania danych skaningowych wynika z faktu, iż są to dane o znacznej objętości i braku jakiegokolwiek struktury danych, która pozwalałaby przyspieszyć nawet wstępne procesy przetwarzania. Dlatego też celowym jest narzucenie odgórnej struktury danych, która będzie mogła być wykorzystywana do wszystkich danych z określonego typu urządzenia, a jednocześnie pozwoli na przyspieszenie przetwarzania danych poprzez ich częściową segmentację. Aby takie przyspieszenie mogło zostać zrealizowane należało opracować algorytmy oraz struktury na potrzeby segmentacji oraz zaimplementować je w oprogramowaniu, które docelowo będzie wykorzystywane do przetwarzania chmur punktów.

Podstawowym problemem na wczesnym etapie opracowywania koncepcji rozwiązania jest dobranie środowiska oraz języka programowania najlepiej nadającego się do rozwiązania danego problemu.

6.2. Środowisko programistyczne

Oprogramowanie wykonano w środowisku Microsoft Visual Studio 2008 głównie ze względu na fakt, że oprogramowanie jest darmowe w ramach licencji MSDNAA oraz oferuje możliwość pisania oprogramowania w jednym z kilku najpopularniejszych języków programowania. Pierwszą wersję oprogramowania napisano z wykorzystaniem języka C# jednak wraz ze wzrostem ilości danych do przetwarzania niektóre funkcje i struktury zaimplementowane w tym języku działały niewystarczająco szybko, dlatego też na pewnym etapie zdecydowano się na przepisanie całości kodu na język C++. Język ten umożliwia obstrukcję danych oraz charakteryzuje się wysoką wydajnością kodu wynikowego oraz bezpośrednim dostępem do zasobów sprzętowych. Kolejnym powodem, dla którego zdecydowano się na język C++ jest koncepcja zrównoleglenia obliczeń przy użyciu karty graficznej, którą będzie można przeprowadzić znacznie łatwiej z języka C++, który również wykorzystywany jest do programowania układów graficznych.

Drugim bardzo istotnym elementem oprogramowania jest biblioteka PLC (ang. Point Cloud Library). Jest to otwarto-źródłowa biblioteka programistyczna, którą skonstruowano pod kątem przetwarzania chmur punktów. W bibliotece tej można przetwarzać chmury punktów wygenerowane z kamer stereowizyjnych, skanerów laserowych, czy też symulacyjnie wygenerowanych danych. Biblioteka PCL jest obecnie największym zbiorem procedur i funkcji dotyczącym przetwarzania chmur punktów na świecie. Posiada również wsparcie wielu koncernów międzynarodowych m. in.: Toyota, Velodyne, Trimble, Nvidia, Leica oraz wielu uniwersytetów i szkół wyższych na świecie.

Biblioteka PCL posiada strukturę modułową, aby ułatwić developerom wyszukanie elementów istotnych z punktu widzenia ich badań. I tak można wyróżnić m. in. moduły

skupiające się na filtrowaniu, segmentacji, operacjach wejścia wyjścia, strukturach drzew KD. Biblioteka jest stosunkowo młodym projektem, bo rozpoczętym w maju 2011 roku. Jest sukcesywnie rozwijana i aktualnie najnowsza dostępna wersja bibliotek ma nr 1.7.1. Oprogramowanie autora zostało zbudowane częściowo o wersję 1.5.1 oraz 1.6.0, które były najbardziej aktualne podczas etapu rozwoju oprogramowania.

Dodatkowym atutem zastosowania biblioteki PCL jest ujednolicenie standardu pliku danych. Jest to niezakodowany format danych alfanumerycznych ASCII lub format binarny, w którym w każdym wierszu występują informacje dotyczące pojedynczego punktu. Plik rozpoczyna się ściśle określonym nagłówkiem, który definiuje, jakie informacje można przechowywać w liniach odpowiadających poszczególnym punktom. Poszczególne pola nagłówka, przedstawione z krótkim opisem, są następujące:


- VERSION – definiuje wersję pliku
- FIELDS – definiuje ilość wymiarów dla każdego z punktów
Przykładowo może to być:
 - FIELDS x y z
 - FIELDS x y z rgb
 - FIELDS x y z normal_x normal_y normal_z
- SIZE – określa rozmiar każdego z wymiarów w bajtach
- TYPE – określa typ danych każdego z wymiarów
- COUNT – określa ile elementów ma każdy z wymiarów
- WIDTH – określa “szerokość” danych może mieć dwa znaczenia
 - określa ilość punktów w rzędzie
 - określa ilość wszystkich punktów w chmurze punktów
- HEIGHT – określa “wysokość” danych może mieć dwa znaczenia
 - określa ilość punktów w kolumnie
 - określa ilość wszystkich punktów w chmurze punktów (w przypadku chmur o nieorganizowanej strukturze przyjmuje wartość 1)
- VIEWPOINT – określa punkt obserwatora
- POINTS - określa ilość punktów w zbiorze
- DATA - określa format danych (ascii / binarny)

Kolejność w strukturze nagłówka jest ściśle określona i nie może być w żaden sposób modyfikowana. Dane uzyskane bezpośrednio ze skanera mają postać X, Y, Z, Intensywność, dzięki czemu przekonwertowanie ich do formatu PCD jest szybkie i bezstratne.

6.3. Ekstrakcja pojedynczej linii z chmury

Podstawowym założeniem projektowym było opracowanie takiej metody segmentacji, którą można było by wykorzystać wprost na danych nieprzetworzonych pochodzących ze skanera laserowego. Skaner laserowy umieszczony na statywie podczas pomiaru wykonuje ruch obrotowy wokół osi Z dzięki silnikowi umieszczonemu w jego podstawie. Dodatkowo

zwierciadło skanera obraca się z bardzo dużą prędkością wokół osi Y, co pozwala na wykonanie skanów dookólnych. Poszczególne obroty przedstawiono orientacyjnie na rys. 6.1.



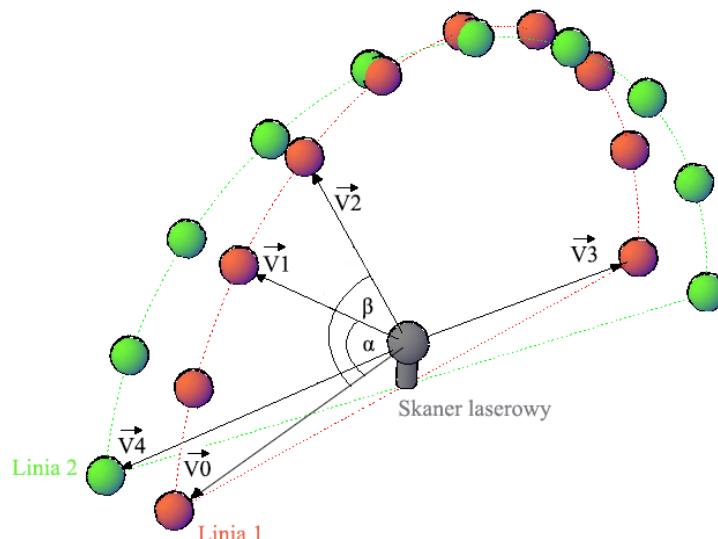
Rys. 6.1. Zasada obrotu lustra skanera laserowego podczas wykonywania pomiaru

Wynikiem opisanej metody określania pozycji wiązki laserowej uzyskuje się zbiór niezależnych linii pomiarowych, z których każda składa się ze zbioru punktów odpowiadających odpowiedniemu ustawieniu lasera w osi Z. Wydaje się, że najlepszym podejściem do segmentacji poszczególnych linii jest sprawdzanie kąta w płaszczyźnie XY. Porównując kąt pomiędzy dwoma kolejnymi punktami pomiarowymi można wyszukiwać odpowiednio duży skok sugerujący przejście do kolejnej linii. Jednak podejście to w praktyce się nie sprawdza ze względu na dosyć duży rozrzut punktów w płaszczyźnie pomiaru, co utrudnia precyzyjne wyznaczenie punktu początkowego następnej linii. Dodatkowo punkty pomiarowe padające na krawędź obiektu w efekcie uśredniania mogą wygenerować kąt zbliżony do tego sygnalizującego przejście do nowej linii.

Dlatego też zdecydowano się na sprawdzanie kąta pomiędzy wektorami rozpiętymi pomiędzy pierwszym punktem pomiarowym będącym jednocześnie pierwszym punktem nowej linii oraz punktami kolejnymi. Kąt pomiędzy dwoma wektorami wyznaczano z równania (6.1)

$$\alpha = \arccos\left(\frac{V_1 \cdot V_2}{|V_1| \cdot |V_2|}\right) \quad (6.1)$$

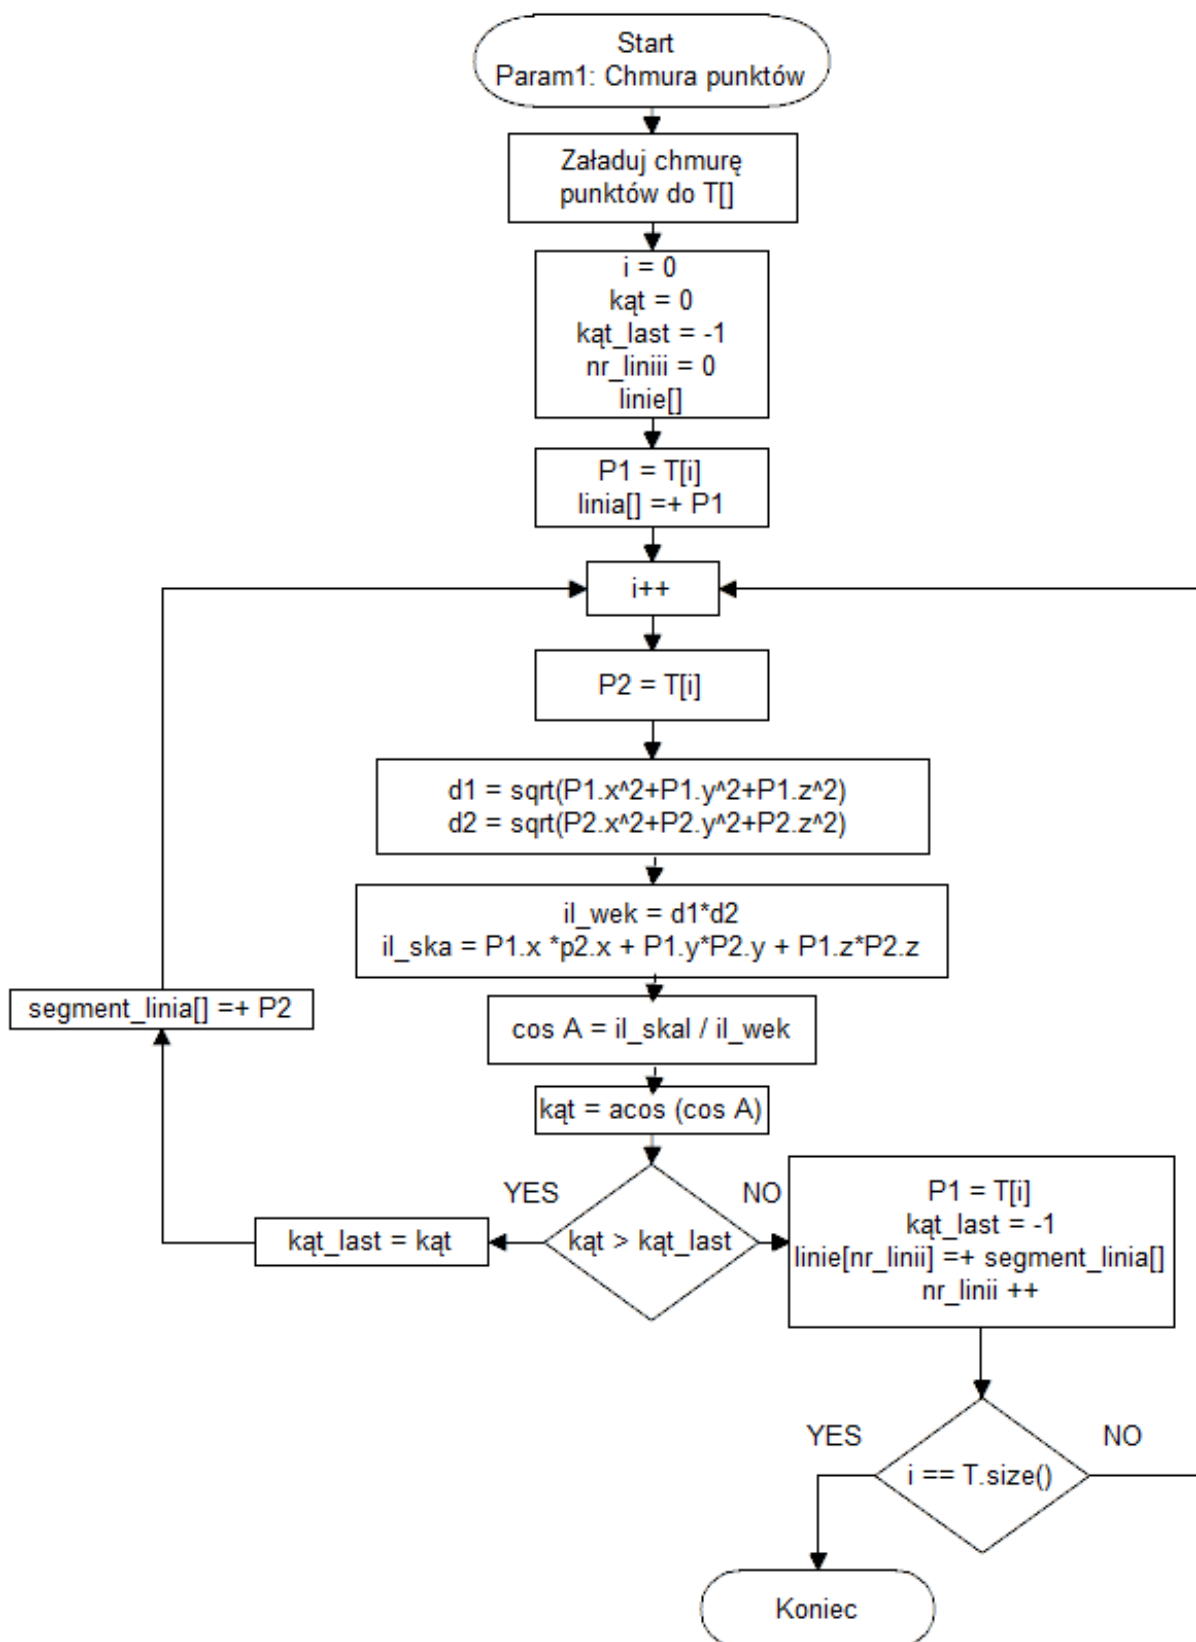
Na rys. 6.2 przedstawiono poglądową sytuację segmentacji dwóch linii. Pierwszym punktem orientacyjnym jest tam zaznaczony wektor V_0 , względem którego liczone są kolejne kąty do czasu aż kąt zacznie się zmniejszać. Sytuacja taka wystąpi dopiero dla wektora V_4 , który automatycznie staje się kolejnym punktem orientacyjnym dla nowej linii.




Rys. 6.2. Orientacyjna zasada segmentacji pojedynczej linii na zasadzie rachunku wektorowego

Algorytm jest wykonywany iteracyjnie do czasu aż wszystkie punkty nie zostaną sklasyfikowane do odpowiednich linii. W efekcie końcowym uzyskuje się strukturę, której elementami są poszczególne linie. Podejście takie jest bardzo wygodne z punktu widzenia dalszego przetwarzania gdyż można wybrać pewien zakres linii do przetwarzania i nie ma potrzeby przetwarzać całości danych. Ponadto ilość punktów w linii jest automatycznie sumowana, a przy tym uzyskiwana jest informacja na temat czasu generacji danej linii. Na podstawie czasu przetwarzania każdej z linii można orientacyjnie wyznaczyć zaszumienie w obrębie linii. Im czas przetwarzania obarczony jest wyższą odchyłką od wartości średniej tym większe zaszumienie. Poglądowy schemat działania całego algorytmu segmentacji kolejnych linii przedstawiono na rys. 6.3. Funkcja segmentująca przyjmuje tylko jeden parametr w postaci chmury punktów w dowolnym formacie dostępnym dla środowiska PCL. Wewnątrz funkcji następuje konwersja umożliwiająca prawidłowe przetwarzanie. Wynik działania funkcji segmentującej dla pełnego skanu dookólnego jest mało czytelny, dlatego na potrzeby prezentacji przedstawiono wycinek mniejszej sceny. Punktom przypisanej do każdej z linii nadano określoną barwę, aby łatwiej było wizualnie odseparować kolejne linie.


Przykład na danych rzeczywistych nieprzetworzonych przedstawiono na rys. 6.4. Rysunek 6.5 prezentuje dane posegmentowane na poszczególne linie.



Rys. 6.3. Algorytm segmentacji linii



Rys. 6.4. Przykład nieposegmentowanej sceny



Rys. 6.5. Przykład sceny z wykonaną segmentacją linii

Jednym z podstawowych założeń w pracy było wykorzystanie metod przetwarzania 2D na potrzeby segmentacji chmury punktów. Po segmentacji linii uzyskano zbiór obiektów przestrzennych, które dzięki prostej transformacji można potraktować, jako obiekty dwuwymiarowe. W tym celu każdą z linii należało przetransformować w taki sposób, aby jedna ze współrzędnych osi wynosiła 0. Efekt taki uzyskano w trzech krokach. Pierwszym z nich było wyznaczenie punktu $P_{sr}(X_{sr}, Z_{sr})$ punkt ten uśredniał wszystkie punkty w obrębie pojedynczej linii do jednego punktu, zgodnie z układem równań (6.2).

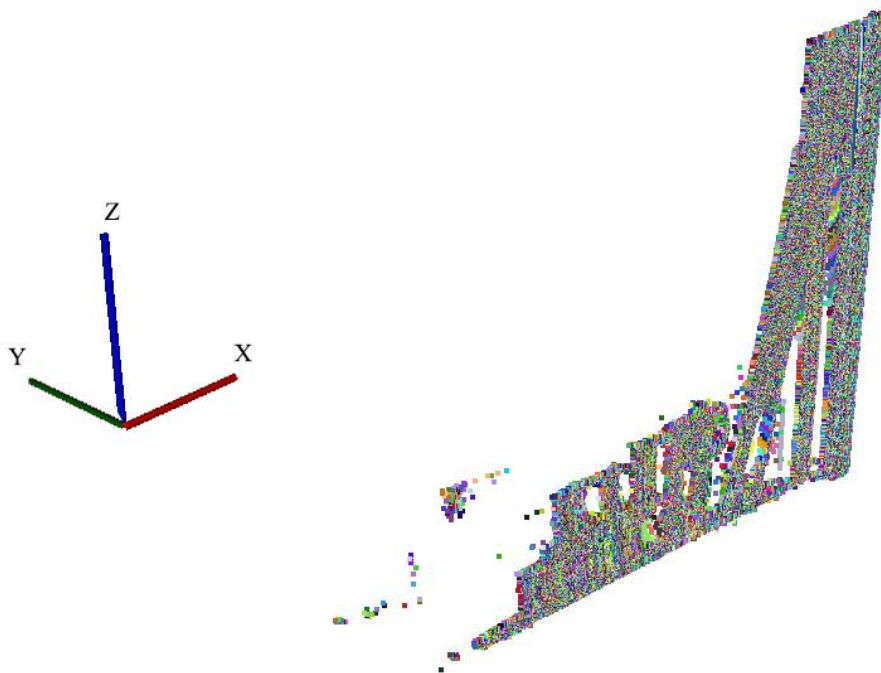
$$X_{sr} = \frac{\sum_{i=1}^N x_i}{N} \quad (6.2)$$

$$Z_{sr} = \frac{\sum_{i=1}^N z_i}{N}$$

Następnie wyznaczano długość wektora rozpiętego pomiędzy punktem (0,0,0) oraz punktem P_{sr} w układzie XYZ oraz jego kąta α względem osi X. Ostatnim elementem był obrót w układzie XYZ o wyznaczony kąt θ wszystkich punktów w obrębie linii korzystając z macierzy obrotu (6.3)

$$R_z(\theta) = \begin{bmatrix} \cos \theta & -\sin \theta & 0 \\ \sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (6.3)$$

Po przekształceniu współrzędna Y ulega wyzerowaniu, dzięki czemu uzyskuje się zbiór obrazów 2D w układzie XZ, dla których można zastosować metody przetwarzania obrazu 2D. Przykład danych po wykonaniu obrotu przedstawiono na rys. 6.6. Tak przygotowane dane mogą zostać praktycznie użyte w obliczeniach, jako dane niezależne np. w obliczeniach równoległych, przy czym należy zapamiętać nr linii oraz kąt jej obrotu, po to aby można było dokonać powrotnej transformacji wyników do układu przestrzennego 3D.



Rys. 6.6. Wynik obrotu wszystkich linii do układu XZ

6.4. Segmentacja i poziom w obrębie jednej linii


Kolejnym etapem przetwarzania jest segmentacja w obrębie pojedynczej linii. Najczęściej na wcześniejszym etapie przygotowania danych stosuje się filtrację pozwalającą wyeliminować błędy grube uzyskane z pomiarów. W przypadku, gdyby jednak filtracja nie została przeprowadzona, a dane są obciążone dużym szumem, to segmentacja spowoduje utworzenie dodatkowego segmentu zawierającego punkty, które nie zostały zakwalifikowane do żadnego z klastrów.

Realizacja funkcji segmentującej ma na celu, na tym etapie, utworzyć segmenty danych składających się z punktów leżących w obrębie promienia zdefiniowanego przez operatora. W algorytmie wykorzystano miarę odległości Euklidesowej (6.4).

$$D(x, z)^2 = \sum_{i=1}^n (x_i - z_i)^2 \quad (6.4)$$

Dodatkowym parametrem, który należy zdefiniować, jest minimalna ilość punktów konieczna, aby sklasyfikować nowoutworzony obiekt, jako poprawny. Wszystkie punkty, które nie zostają sklasyfikowane w żadnym klastrze na tym etapie, są wyłączone z jakiegokolwiek dalszego przetwarzania. Nie są natomiast fizycznie usuwane z danych jak ma to miejsce w przypadku filtracji. Algorytm wykonywany jest iteracyjnie do momentu aż przeanalizowane zostaną wszystkie punkty. Istotną cechą segmentacji jest to, że występuje

grupowanie danych, a poszczególne grupy elementów tworzone są na bieżąco, a nie do z góry zdefiniowanych wcześniej i utworzonych klas obiektów. Na rys. 6.5 przedstawiono wynik działania algorytmu segmentacji na bazie odległości dla pojedynczej linii. Obiekt po lewej posłużył, jako dane wejściowe zaś obiekt po prawej stronie jest wynikiem działania funkcji grupującej.




Rys. 6.7. Wynik działania segmentacji na bazie odległości, z lewej obiekt przed a z prawej po segmentacji

Na rys. 6.7 można zaobserwować utworzone segmenty. Każdemu z nich automatycznie zostaje nadana unikalna barwa. Dekompozycja danych do tak niskiego poziomu pozwala na szczegółową analizę nawet małych elementów w obrębie chmury punktów. Na przykładzie wykorzystanych danych można bardzo szybko wyznaczyć zarówno elementy będące odcinkami jak i fragmentami łuków i nic nie stoi na przeszkodzie, aby wyszukiwać kształty bardziej złożone.


Ze względu na przyjęte kryterium odległości funkcja grupująca może zwrócić kilka możliwych konfiguracji utworzonych segmentów, które następnie należy odpowiednio zinterpretować oraz obsłużyć. W pracy zaprezentowano grupę najczęściej występujących możliwości, z krótkim opisem ich interpretacji oraz dalszego przetwarzania. Należy zaznaczyć, że funkcja grupująca nie pełni w tym przypadku roli mechanizmu identyfikującego obiekty, a jedynie zgrubnie określa klasę obiektu. Na rysunkach przedstawiających najczęstsze konfiguracje kolor oraz linia ciągła pomiędzy punktami sygnalizuje, że jest to pojedynczy segment utworzony przez funkcję grupującą.

W przykładzie przedstawionym na rys. 6.8, który pokazuje klasę zdecydowanie najbardziej złożonych obliczeniowo obiektów i zakłada się, że cała krzywa została zgrupowana jako jeden segment. Jest to zatem sytuacja, w której nie występują nieciągłości pomiarów i nie występują błędy powodowane szumem.




Rys. 6.8. Wynik działania segmentacji na bazie odległości

Przyjęto maksymalną odległość pomiędzy kolejnymi segmentami na podstawie średniej odległości pomiędzy pięcioma kolejnymi punktami, a maksymalną odległość pomiędzy segmentami domyślnie ustawiono na trzykrotną wartość pomiędzy punktami Odl_{sr} . Przyjęcie takich założeń pozwala na automatyczne dopasowywanie się algorytmu do odległości, czyli operator w przypadku dużych odległości punktów pomiarowych od skanera nie musi wykonywać żadnych dodatkowych korekt. Wartość parametru mnożnika Odl_{sr} można oczywiście zmienić, jednak podczas jego weryfikacji dokonywanych podstawie dla rzeczywistych pomiarów, przyjmowanie wartości mnożnika mniejszego niż 3 powoduje zdecydowany wzrost ilości segmentów, które w większości przypadków są nadmiarowe i ich przetworzenie wymaga dodatkowych czynności. Sytuacja przedstawiona na rys. 6.6 w rzeczywistości praktycznie nie występuje, ze względu na często duże zaszumienie danych oraz złożoność geometrii badanych obiektów. Rysunek 6.9 przedstawia sytuację, w której wynikiem funkcji grupującej są segmenty złożone, czyli takie, w obrębie których można wyróżnić wiele obiektów tego samego lub różnych typów. W tym przypadku następuje segmentacja II poziomu w obrębie każdego z segmentów. Algorytm realizuje się do czasu aż każdy z segmentów nie zostanie rozbity na segmenty proste, czyli segmenty należące do jednego ze ściśle określonego katalogu, w tym przypadku łuku lub odcinka.




Rys. 6.9. Wynik działania segmentacji na bazie odległości

Kolejną możliwością jest sytuacją przedstawiona na rys. 6.10, w której również występują segmenty złożone jednak w tym przypadku elementy wchodzące w skład segmentu są tego samego typu, co znacznie skraca proces przetwarzania.




Rys. 6.10. Wynik działania segmentacji na bazie odległości z jedną klasą obiektów w ramach segmentu

Następnym możliwym wynikiem działania segmentacji jest sytuacja, w której ilość segmentów odpowiada faktycznej ilości obiektów. Jest to sytuacja najbardziej pożądana, gdyż wystarczy jednokrotna realizacja procedury wyszukiwania w obrębie każdego z segmentów, aby uzyskać pełną informację o strukturze obiektu. Do formy przedstawionej na rys. 6.11 doprowadzane są ostatecznie wszystkie segmenty. Oczywiście przedstawione przypadki zakładają brak szumu oraz przy spełnieniu założenia, że wszystkie punkty w obrębie segmentu zostaną poprawnie przypisane. Dla rzeczywistych danych uzyskuje się dodatkowy segment zawierający wszystkie punkty nieprzypisane zarówno przez funkcję grupującą jak i dalsze przetwarzanie z użyciem transformaty Hougha.



Rys. 6.11. Ostateczny pożądaný wynik działania segmentacji

Sytuacja przedstawiona na rys. 6.12, z punktu widzenia przetwarzania jest tym samym etapem przetwarzania jak rys. 6.11. Tu również uzyskuje się segmenty proste, pomimo iż w przypadku fragmentu łuku nastąpiła nadmierna dekompozycja.



Rys. 6.12. Alternatywny ostateczny wynik działania segmentacji

Z punktu widzenia lokalizacji wszystkich prostych segmentów składowych elementu (tu dla obiektu walcowego), podział łuku na mniejsze segmenty nie ma wpływu na działanie całego algorytmu, gdyż funkcja wyższego poziomu odpowiedzialna za łączenie wyników cząstkowych zinterpretuje taki obiekt poprawnie.

6.5. Segmentacja II poziomu w obrębie pojedynczego klastra

Kolejnym etapem przetwarzania jest interpretacja wyników zwróconych przez funkcję grupującą. Tak jak przedstawiono w poprzednim podrozdziale na tym etapie może wystąpić kilka przypadków, które należy odpowiednio obsłużyć i zinterpretować. Kryterium zakończenia iteracji na etapie segmentacji w obrębie klastra związane jest z ilością punktów pozostałych i nieprzypisanych w klastrze. Istnieje możliwość wprowadzenia dowolnej wartości określającej zakończenie przetwarzania, jednak domyślnie obligatoryjnie przyjęto, że przetwarzanie wykonywane jest do momentu aż ilość nieprzypisanych punktów nie będzie mniejsza niż 5% ilości wszystkich punktów w danym segmencie. Określono dodatkowo drugie

kryterium na wypadek, gdyby dane zawierały dużą liczbę błędnych pomiarów, a ilość nieprzypisanych punktów przekracza zadaną wartość. Określa ono liczbę prób (np. dwie), które kończą się niepowodzeniem wyszukiwania obiektu przy zadanym pierwszym kryterium.

Początkowo dla każdego z obiektów następuje wyszukanie odcinków z użyciem transformaty Hougha. Kluczowym elementem w implementacji metody Transformaty Hougha jest sposób implementacji tablicy akumulacji. Tablica akumulacji jest dwuwymiarową tabelę, w której jednym z wymiarów jest ilość punktów zaś drugim ilość kroków kwantyzacji. Opracowaną implementację algorytmu oparto na dwóch tablicach. Jedna, w której przechowywane będą wyniki odległości punktów od początku układów współrzędnych wyznaczone z równania (5.4). Przykład organizacji takiej tablicy przedstawia tabela 6.1. oraz druga przechowująca wyniki głosowania tabela 6.2.

Tabela 6.1. Organizacja tablicy przechowującej wartości odległości

	Kąt α_1	Kąt α_2	Kąt α_3	...	Kąt α_n
P₁	13.24	13.50	13.16	...	14.20
P₂	14.30	14.14	14.20	...	15.20
P₃	14.20	14.14	14.30		14.40
...
P_n	15.30	15.40	15.45	..	14.30

Tablicę zaimplementowano na wskaźnikach odwołujących się do pamięci, co jest aktualnie najszybszym możliwym sposobem dostępu do danych. Rozmiary tablicy są automatycznie wyznaczone na podstawie ilości punktów w obrębie klastra oraz parametrze kwantyzacji określanym przez operatora. Największym problemem podczas korzystania z Transformaty Hougha jest rozmiar tablicy akumulacji, problem ten rozwiązano dzięki wieloetapowej segmentacji w efekcie, czego obiekty, dla których wykonywane jest przetwarzanie mają niewielkie rozmiary sięgające zwykle maksymalnie do kilkuset punktów. Dodatkowo w tablicy przechowywane są wartości zmiennoprzecinkowe co dodatkowo rozszerza zapotrzebowanie na pamięć. Istotnym faktem jest, że na samej tablicy nie są wykonywane żadne operacje arytmetyczno logiczne a jedynie przypisanie wartości do komórki, dlatego też zastosowane rozwiązanie jest najszybszym z możliwych.


Drugim elementem, który również rzutuje na szybkość działania algorytmu jest tablica głosowania zgodnie z zasadami przedstawionymi w rozdziale 5.4 Transformata Hougha, przestrzeń akumulacyjna dla odcinków również przyjmuje postać tablicy dwuwymiarowej. W tym przypadku zdecydowano się na zmianę struktury tablicy na tablicę jednowymiarową, w której każdy element jest wektorem reprezentującym dany kąt kwantyzacji zaś kolejne elementy tego wektora odpowiadają kolejnym punktom. Ostatecznie można sobie taką strukturę wyobrazić, jako tablicę dwuwymiarową, jednak z formalnego punktu widzenia jest to niepoprawne. Przykład tablicy akumulacji Hougha przedstawia tabela 6.2.

Tabela 6.2. Organizacja tablicy głosowania

	P_1	P_2	P_3	...	P_n
Kąt α_1	1	2	3	...	1
Kąt α_2	1	1	2	...	1
Kąt α_3	1	1	1		1
...
Kąt α_n	1	2	1	..	1

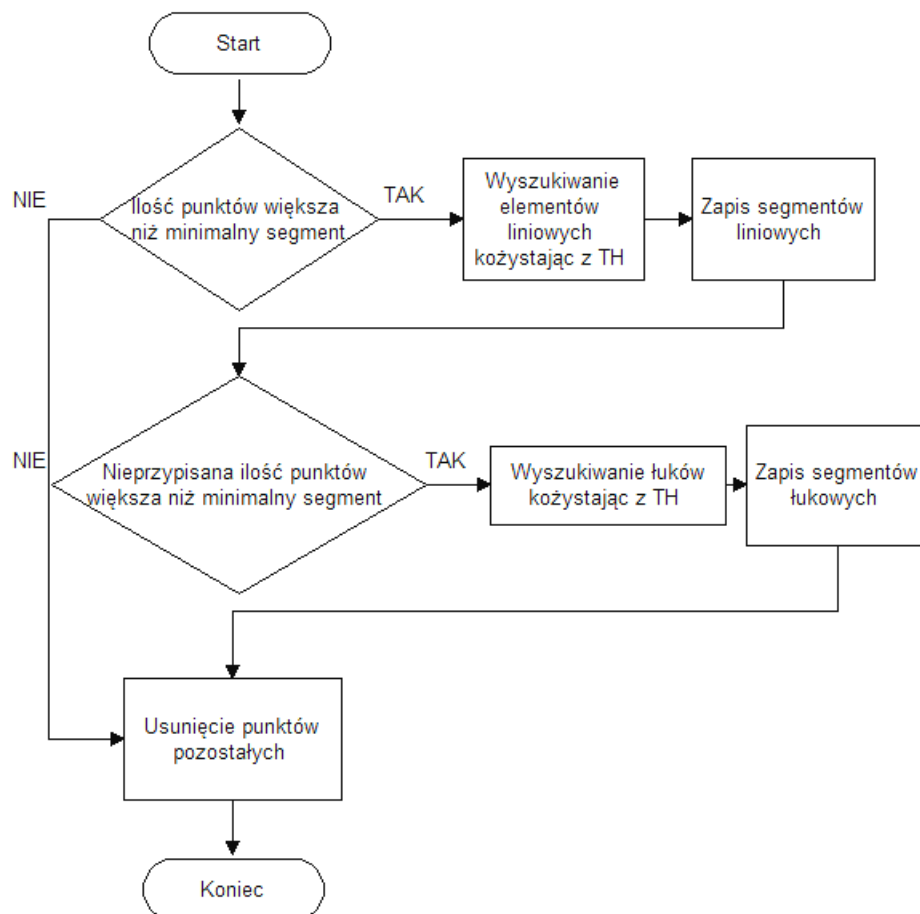
Podejście takie podyktowane jest kilkoma czynnikami. Przede wszystkim niezmodyfikowana Transformata Hougha zwraca tylko jedno rozwiązanie, które najlepiej odwzorowuje szukany wzorzec. W przypadku segmentów prostych rozwiązanie takie byłoby satysfakcjonujące, jednak w przypadku segmentów złożonych część rozwiązań zostałaby pominięta. Wyszukiwanie większej ilości rozwiązań wiąże się z wielokrotnym wykonywaniem operacji wyszukiwania kolejnych maksimów oraz sortowania w celu przyspieszenia przetwarzania. Do tego celu bardzo dobrze nadają się struktury wektorowe, które posiadają zoptymalizowane funkcje pozwalające pracować na ich zawartości.

Analitycznie problem wyszukania odcinka w przestrzeni Hougha sprowadza się do wyszukania maksimum w przestrzeni akumulacyjnej. Na etapie głosowania, czyli wyszukiwania punktów, dla których odległość od początku układu współrzędnych oraz danego kąta jest jednakowa, należy uwzględnić odchyłkę dla pomiaru odległości na poziomie $\pm 0,01$ % wartości. Odchyłka na tym poziomie pozwala odfiltrować przypadkowe błędy pomiarowe. Wartość ta wynika z odchylenia standardowego odległości punktu od mierzonego obiektu dla najczęściej badanych typów powierzchni. Wartość maksymalna w tablicy głosowania określa ilość punktów leżących na wyszukiwanej prostej. Na chwilę obecną w opracowanym algorytmie nie zaimplementowano metody automatycznie dopasowującej minimalną ilość punktów, aby zakwalifikować grupę punktów, jako odcinek. Przyjęto założenie, że odcinek musi się składać z minimum 25 punktów leżących na jednej prostej. Wartość tę wyznaczono przy założeniu, że minimalna odległość skanera od badanego obiektu wynosi 5 m dla tej odległości 25 punktów generuje odcinek o długości około 1 cm. Skany wykonane z bliższej odległości dla większości powierzchni obarczone są znacznym szumem. W celu ograniczenia segmentów nadmiarowych jest to najmniejsza możliwa długość wyszukiwanego elementu. Problem wyszukiwania maksimów można również rozwiązać w sposób graficzny. Odwzorowując odległość od początku układu współrzędnego dla zadanego kąta wg zasady zaprezentowanej w rozdziale 5.5.2 „Transformata Hougha dla obrazów dwuwymiarowych” uzyskuje się wykres jak na rys. 6.13, na którym punkty wzajemnego przecinania się kolejnych sinusoid reprezentują poszczególne maksima.



Rys. 6.13. Graficzna reprezentacja przestrzeni Hougha

Po etapie wyszukiwania odcinków liniowych zgodnie z algorytmem przedstawionym na rys. 6.14 sprawdzana jest ilość punktów, która pozostała w segmencie.



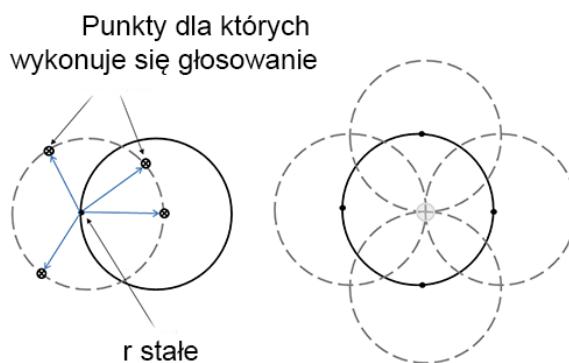
Rys. 6.14. Iteracyjny algorytm identyfikowania obiektów w obrębie segmentu

W przypadku, gdy ilość punktów jest większa niż minimalna ilość punktów wymaganych do utworzenia segmentu. Wyszukując fragmenty łuków należy rozważyć dwa przypadki. W pierwszym z nich znany jest promień obiektu, który należy wyszukać. Jeśli promień nie jest znany operuje się zakresem wartości, wewnątrz którego taki element najprawdopodobniej się znajduje.

Transformata Hougha dla obrazów dwuwymiarowych wymaga wcześniejszego procesu binaryzacji obrazu. Następnie sprawdzane są wszystkie punkty (piksele) reprezentujące krawędzie obiektów w poszukiwaniu określonego wzorca. W przypadku chmur punktów cały ten proces można pominąć, dlatego że punkty zrzutowane na płaszczyznę XZ reprezentują krawędź obiektu. W przypadku wyszukiwania elementów walcowych, które zwykle reprezentują fragment instalacji najczęściej zamontowanej na wspornikach lub na ścianie, pozyskanie informacji o ich całej powierzchni jest bardzo trudne lub często niemożliwe. Elementy walcowe najczęściej reprezentowane są przez wycinki łuków, które wyznacza się korzystając z równania okręgu (6.5) oraz faktu, że punkty są elementami okręgu i znane są ich współrzędne (x,y) . Zakłada się jednocześnie, że środek okręgu może się znajdować w dowolnym miejscu na płaszczyźnie.


$$r^2 = (x - x_c)^2 + (y - y_c)^2 \quad (6.5)$$

Dla stałego promienia r , dla każdego z punktów w obrazie pierwotnym tworzy się okrąg oraz akumuluje wartości na jego krawędzi przy przyjętym kroku kwantyzacji. Przykład procesu tworzenia tablicy akumulacji dla przykładowego okręgu, na którym znajdują się cztery punkty, przedstawiono na rys. 6.15.




Rys. 6.15. Zasada wyszukiwania okręgu o znanym promieniu r przy użyciu Transformaty Hougha

Punkt będący przecięciem największej ilości okręgów tworzonych podczas generowania tablicy akumulacji wyznacza środek szukanego okręgu (rys. 6.16). Gęstszy krok kwantyzacji pozwala na większą precyzję, jednak należy mieć na uwadze zwiększenie rozmiarów tablicy akumulacji.



Rys. 6.16. Zasada wyszukiwania okręgu o znanym r przy użyciu Transformaty Hougha


W sytuacji, w której promień r nie jest znany, konwencjonalna dwuwymiarowa tablica akumulacji będzie niewystarczająca. Należy zwiększyć jej wymiar o trzeci wymiar, którym będzie znajdował się zmienny promień obiektu. Przyrost tablicy w przypadku zmiennego promienia jest bardzo duży, dlatego też należy podawać możliwie wąski zakres przeszukiwania. Przykład tablicy akumulacji z zmiennym promieniem r przedstawiono na rys. 6.17.



Rys. 6.17. Tablica akumulacji dla okręgu o zmiennym promieniu

Jak wykazano wcześniej w danych rzeczywistych bardzo rzadko spotyka się pełne okręgi raczej występują ich fragmenty w postaci łuków. W algorytmie założono minimalną liczbę punktów, aby zbiór punktów sklasyfikować, jako łuk i wynosi ona 5. Pozornie może się to wydawać niewielką liczbą, jednak obiekty rurowe zwykle charakteryzują się występowaniem większego szumu pomiarowego niż płaszczyzny, co spowodowane jest właściwościami materiału, z którego są wykonane. Dlatego lepszą strategią jest wybranie mniejszej grupy punktów lepiej odwzorowujących łuk niż większej liczby punktów obarczonych zdecydowanie większą odchyłką od rzeczywistej wartości. Na rys. 6.18 przedstawiono tablicę akumulacji z

wyznaczonym środkiem łuku. Punkty białe na wykresie są punktami, dla których wykonano wyszukiwanie.



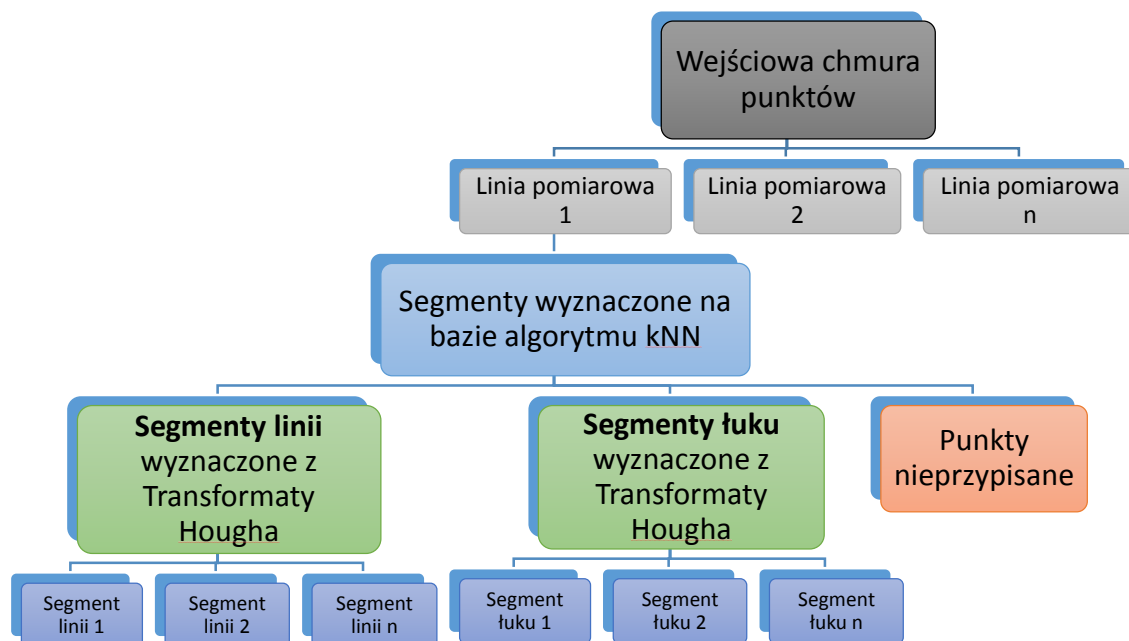
Rys. 6.18. Tablica akumulacji dla łuku z wyznaczonym środkiem

Punkty czarne to punkty, w których przeprowadzono przynajmniej jedno głosowanie. Punkt czerwony reprezentuje maksimum będące środkiem łuku. W rzeczywistości pokazana struktura generowana jest w przestrzeni trójwymiarowej, dlatego też orientacja środka łuku względem punktów badanych może wydawać się niepoprawnie wyznaczona.

Etap przetwarzania łuków jest zdecydowanie bardziej złożony obliczeniowo, dlatego też jest wykonywany, jako ostatni, gdy ilość danych jest już znacznie ograniczona.

6.6. Proponowana struktura danych

W wyniku wielopoziomowej segmentacji zostaje utworzona struktura danych, którą można porównać do struktury odwróconego drzewa. Na pierwszym poziomie znajdują się wszystkie dane. Nie jest tu istotne czy dane są w formacie XYZ, XYZ + Intensywność, XYZ + RGB, ponieważ z punktu widzenia segmentacji istotne są tylko wartości współrzędnych XYZ. Warto też zauważyć, że struktura pliku wejściowego i dane w nim zawarte pozostają nienaruszone. Cały mechanizm segmentacji jest strukturą abstrakcyjną tworzoną wewnątrz programu. Graficzny przykład pozwalający na określenie poszczególnych poziomów danych przedstawiono na rys. 6.19.



Rys. 6.19. Struktura danych utworzona w procesie segmentacji


Oprogramowanie opracowane na podstawie zaproponowanego algorytmu umożliwia również eksport danych do pliku zewnętrznego określonego segmentu lub fragmentu struktury. Należy przy tym pamiętać, że na poziomie linii pomiarowych następuje transformacja układu współrzędnych z układu XYZ do układu XZ, dlatego też wszystkie eksportowane elementy poniżej tego poziomu posiadają zmodyfikowany układ współrzędnych. W strukturze znajduje się również element przechowujący punkty nieprzypisane, na wypadek dodania nowych wzorców wyszukiwania. Element ten przechowuje zarówno punkty nieprzypisane podczas segmentacji z użyciem algorytmu kNN, jak i punkty pozostałe po procesie wyszukiwania odcinków i łuków.

Proces ponownego grupowania również można podzielić na kilka etapów. Bazuje on jednak głównie na wynikach uzyskanych na najniższym poziomie segmentacji, czyli fragmentach łuków oraz odcinków, przy zachowaniu kolejności linii. Również ten etap nie ma za zadanie identyfikacji dokładnych parametrów wyszukiwanych elementów, a jedynie utworzenie klas grup o podobnych własnościach. Proces ponownego grupowania przebiega odmiennie dla odcinków oraz łuków ze względu na informacje uzyskane na temat tych obiektów po wykonaniu transformaty Hougha.

Proces rozpoczyna się od pierwszej linii w obrębie, której uzyskano grupę odcinków, a następnie dla każdego z odcinków wyznaczany jest wektor normalny wynikający bezpośrednio z przekształceń związanych z transformata Hougha, służący jako miara podobieństwa elementów. Drugim elementem, za pomocą którego badane jest podobieństwo elementów, była ich wzajemna odległość. Linie sprawdzane są kolejno zgodnie z kierunkiem obrotu skanera podczas pomiaru. Dynamicznie budowane są przy tym struktury przechowujące informacje o aktualnych grupach. Proces ten rozpoczyna się dla pierwszej linii po określeniu zakresów wektorów normalnych. Następnie dla segmentów, dla których wektory normalne spełniają kryterium podobieństwa wykonywana jest weryfikacja położenia segmentów

względem siebie. Pomiar odległości wykonywany jest w trzech punktach segmentu na jego krańcach oraz w środku każdego z hipotetycznie bliskich segmentów. Aby segmenty zostały sklasyfikowane, jako elementy tego samego elementu przynajmniej dla jednego punktu pomiarowego powinna pojawić się część wspólna obu segmentów. Oprogramowanie ma wbudowany algorytm dopasowujący kryterium odległości wraz ze wzrostem odległości punktów od skanera, obliczając przy tym średnią odległość punktów w segmencie. Maksymalna odległość punktów w segmencie wynosi 5-krotną wartość średniej odległości w segmencie po to, aby segmenty zostały poprawnie sklasyfikowane w jednym z nich. Celowo zastosowano tak szeroki parametr kryterium. W wielu przypadkach generowane są wyniki z nadmiarem punktów, z tego względu, że jest to etap agregacji danych wejściowych do dalszego przetwarzania metodą RANSAC, która potrafi bardzo szybko odfiltrować dane nadmiarowe. Jednak przy ograniczeniu zbioru danych wejściowych, które wyselekcjonowano by w oparciu o bardzo ostre kryteria, metodą tą nie można było by uzyskać informacji o geometrii na granicach obszaru wyszukiwania. W takim przypadku uzyskany wynik mógłby być nieprawidłowy.

Przykład mechanizmu grupowania dla dwóch elementów płaskościanowych (żółty i czerwony) przedstawiono na rys 6.20. Duże sfery orientacyjnie wskazują punkty, w których wykonywano pomiar wyszukiwania sąsiednich klastrów. Belki na poszczególnych liniach reprezentują wektory normalne dla każdej z linii.



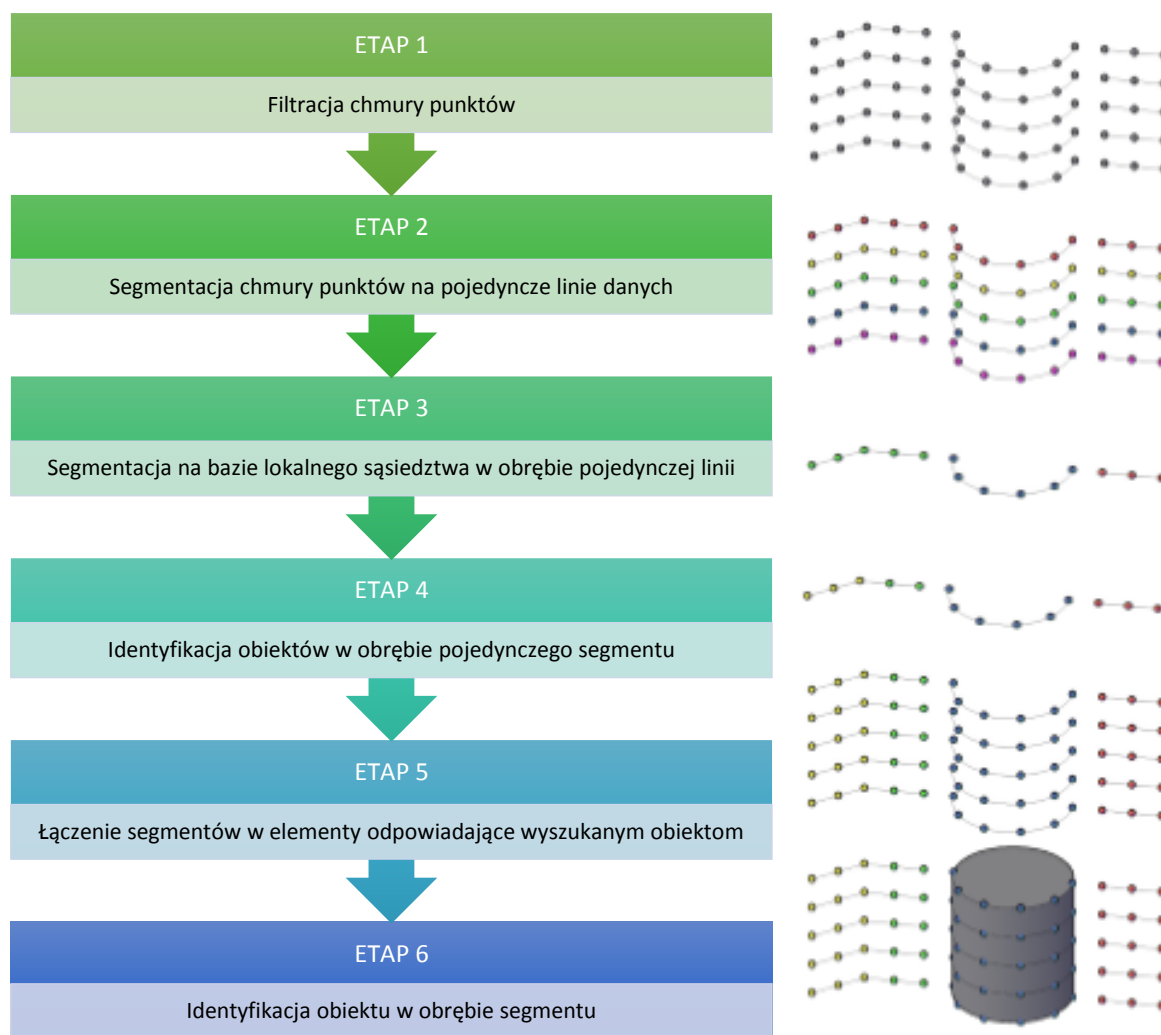
Rys. 6.20. Graficzna prezentacja mechanizmu grupowania

Proces wyszukiwania łuków przebiega wg podobnego schematu, jednak pominięty jest proces wstępnego grupowania w oparciu o wektory normalne. Na wczesnym etapie rozwoju algorytmu rozważano możliwość grupowania łuków na bazie uzyskanych promieni, jednak tak jak opisano to w przypadku odcinków rozwiązanie takie generowało zbyt wąską grupę rozwiązań, co powodowało problem niejednoznacznych wyników na dalszym etapie przetwarzania.

Kolejnym problemem, który należało rozwiązać jest określenie kąta, pod jakim skanowany jest element walcowy. W większości przypadków elementy skanowane są pod kątem i będą lokalizowane w obrębie linii, jako fragmenty elipsy. Zgodnie z [8] tablica akumulacji dla elipsy wymaga akumulacji aż 5 parametrów, co znacznie komplikuje proces przetwarzania. W efekcie przyjętego podejścia elipsa reprezentowana będzie przez grupę

niezależnych łuków, co jest zgodne z dalszą metodologią przetwarzania. Drugim elementem przemawiającym za przyjętym rozwiązaniem jest fakt, że także obiekty walcowe, nawet skanowane pod kątem prostym do ich osi podłużnej, najczęściej charakteryzują się brakiem punktów pomiarowych w środkowej części elementu spowodowane zbyt dużym współczynnikiem odbicia powierzchni.

Proces grupowania kończy się po iteracyjnym przejściu przez wszystkie dostępne linie. W efekcie tego procesu uzyskuje się grupy punktów zlokalizowanych na obiektach takich jak płaszczyzny oraz obiekty walcowe. Jednak, aby określić ich dokładne parametry należy przeprowadzić kolejny etap przetwarzania z użyciem metody RANSAC. Diagram przedstawiony na rys. 6.21 przedstawia kolejne kroki, które zostają wykonane w podanej kolejności. Obok każdego etapu przedstawiono poglądową grafikę reprezentującą fragment chmury punktów składający się z elementu walcowego i kilku odcinków.



Rys. 6.21. Diagram prezentujący kolejne etapy przetwarzania danych w zaproponowanej metodzie

6.7. Podsumowanie rozdziału

Rozdział poświęcony jest opisowi procesu modyfikacji danych trójwymiarowych w taki sposób, aby można wykorzystać metody przetwarzania 2D stosowane dla obrazów płaskich. Zaproponowana metoda wykorzystuje specyfikę skanera laserowego, generującego dane w postaci niezależnych linii pomiarowych. Każdą z linii transformuje się do układu 2D, zerując jedną ze współrzędnych. Następnie wyszukiwane są grupy punktów leżące blisko siebie i na ich podstawie tworzony jest podstawowy segment. Kolejnym etapem jest identyfikacja elementów w obrębie segmentu. Metoda pozwala na wyszukiwanie odcinków oraz łuków dzięki zaimplementowanej metodzie transformaty Hougha. Po analogicznej analizie wszystkich linii następuje grupowanie elementów począwszy od pierwszej linii. Uzyskuje się w ten sposób grupy segmentów jednego typu np. odcinki lub łuki leżące w sąsiednich liniach. Rozdział zawiera szczegółowe opisy poszczególnych etapów wraz z przykładami graficznymi prezentującymi wyniki poszczególnych etapów. Przedstawiono również schemat uzyskanej struktury, która pozwala na określenie celowości poszczególnych kroków. Na zakończenie rozdziału przedstawiono diagram przedstawiający kolejne etapy przetwarzania, który pozwala na dokładniejsze zrozumienie działania proponowanej segmentacji danych.


7. Rekonstrukcja obiektu w oparciu o jego model parametryczny

7.1. Dopasowanie płaszczyzn

Wyznaczenie parametrów obiektów, które są istotne z punktu widzenia procesu inwentaryzacyjnego wykonano stosując metodę RANSAC, której zasada działania została opisana w rozdziale 5.3. Głównym problemem podczas wykorzystania metody podczas pracy na danych rzeczywistych jest fakt, że potrafi ona wyszukać poprawne rozwiązanie dla danych, w których maksymalnie 50% punktów znajduje się poza wyszukiwanym wzorcem. Grupy obiektów utworzone na podstawie przetwarzania opisanego w rozdziale 6, reprezentują dany obiekt z bardzo dużą dokładnością z ilością punktów poza obiektem nieprzekraczających zwykle 10%. Takie przygotowanie danych pozwala na dokładne wyznaczenie parametrów modelu oraz znaczne skrócenie ilości iteracji, które rzutują na czas przetwarzania w metodzie RANSAC.


Kluczowym parametrem podczas wyszukiwania płaszczyzn metodą RANSAC jest określenie maksymalnej odległości punktu od płaszczyzny, aby ten został zakwalifikowany, jako element tej płaszczyzny. Dla przykładu na rysunku 7.1 przedstawiono chmurę punktów reprezentującą kartkę papieru leżącą na płaskim stole. Elementy stołu odfiltrowano, aby

powierzchnia kartki była lepiej widoczna. Można zauważyć, że na powierzchni kartki występują zniekształcenia.



Rys. 7.1. Chmura punktów uzyskana po przeskanowaniu kartki papieru

W celu weryfikacji działania metody wykonano pomiary płaszczyzny w odległości: 1, 3, 5, 10, 30, 50 m. Pomiar w takiej skali narzucał zmianę gęstości pomiaru tak, aby na badanej płaszczyźnie uzyskać zbliżoną ilość punktów, która ostatecznie wyniosła około 1400 punktów. Na wykresie pokazanym na rys.7.2 przedstawiono zależność pomiędzy liczbą punktów sklasyfikowanych przez metodę RANSAC jako punkty zlokalizowane na płaszczyźnie do maksymalnej dopuszczalnej odległości o jaką punkt może być oddalony od płaszczyzny. Niestety podczas pomiaru nie ma możliwości zagwarantowania ażeby zarówno skaner jak i płaszczyzna były nieruchome, aby zachować te same kąty pomiaru płaszczyzny. Płaszczyzny skanowane pod kątem cechuje wyższe odchylenie standardowe wyników pomiarów, przez co ilość punktów przypisanych do płaszczyzny może być mniejsza. Na rysunku 7.2 można zauważyć, że dla odległości powyżej 10 m procent punktów przypisanych do płaszczyzny jest relatywnie niski.

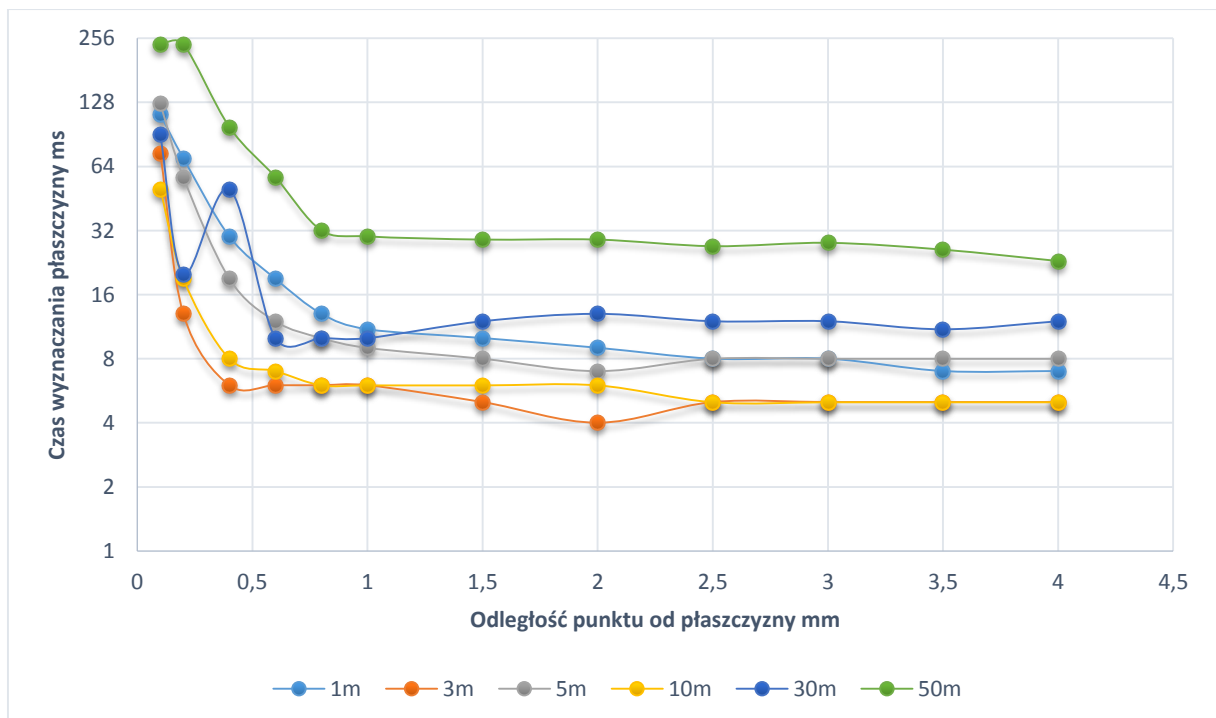


Rys. 7.2. Wykres zależności pomiędzy ilością punktów przypisanych do płaszczyzny a odległością


Wiąże się to ze wzrostem odchylenia standardowego, zatem należałoby przyjmować jej większą wartość jako graniczną. Producent badanego urządzenia deklaruje zalecaną odległość

pomiaru dla skanu pojedynczego do 35m, przy obiekcie posiadającym 30% współczynnik odbicia. Nie podaje natomiast informacji na temat niepewności pomiaru odległości dla 30% współczynnika odbicia. Informacje na temat odchylenia standardowego pomiaru odległości wynoszące odpowiednio 0,6 mm dla 11 m oraz 2.4 mm dla 50 m podano dla obiektu o współczynniku odbicia sięgającym 90%. Na podstawie uzyskanych wyników można założyć, że dla obiektów o niższym współczynniku odbicia niż proponowany przez producenta odchylenie standardowe znacznie wzrasta co utrudnia prawidłowe określenie parametrów obiektu dla odległości powyżej 30m. Dla odległości powyżej 40 m producent zaleca się wykonywanie skanu podwójnego co częściowo może rozwiązać problem.


Drugim parametrem, jaki zweryfikowano w pracy jest czas wyznaczania płaszczyzny zawierającej najwięcej punktów spełniających warunek maksymalnej odległości od płaszczyzny. Proces doboru punktów na bazie, której budowany jest pierwszy krok metody RANSAC, czyli hipoteza, jest losowy. Powoduje to czasem wydłużenie czasu obliczeń w przypadku wyboru nieprawidłowych punktów. Na rysunku 7.3 przedstawiono porównanie czasów wyszukiwania płaszczyzny dla określonych odległości. Różnice w poszczególnych poziomach wynikają z różnic występujących w danych, na podstawie których przygotowano zestawienie. Rysunki 7.4 oraz 7.5 przedstawiają wyniki przypisania punktów do płaszczyzny. Punkty przypisane do płaszczyzny wizualizowane są poprzez określoną barwę zaś punkty nieprzypisane pozostają szare. Rysunek 7.4 prezentuje wynik wyszukiwania dla odległości punktu od płaszczyzny wynoszącej 0.1 mm. Rysunek 7.5 prezentuje wynik dla wartości maksymalnej odległości wynoszącej 1 mm



Rys. 7.3. Wykres zależności pomiędzy czasem wyznaczania najlepiej dopasowanej płaszczyzny




Rys. 7.4. Punkty przypisane do płaszczyzny zaznaczono kolorem brązowym dla kryterium odległości wynoszącego 0.1 mm



Rys. 7.5. Punkty przypisane do płaszczyzny zaznaczono kolorem niebieskim dla kryterium odległości wynoszącego 1 mm


7.2. Dopasowanie walca

W przypadku wyszukiwania obiektów walcowych przed rozpoczęciem wyszukiwania należy określić grupę parametrów cechujących wyszukiwany walec. Pierwszym parametrem jest minimalna ilość punktów, jaką należy dopasować do obiektu, aby wynik uznać za prawidłowy. Następnym parametrem jest określenie maksymalnych dopuszczalnych różnic wektorów normalnych dla poszczególnych punktów. Funkcja wyznaczająca wektory normalne w punkcie bazuje na grupie najbliższych punktów sąsiednich, a następnie wyznacza wektor normalny płaszczyzny do nich dopasowanej. Jak pokazano na rys. 7.6 dla dużych odległości, w tym przypadku 50 m, odchylenie standardowe dla dopasowanego walca wynosi 2,81 mm.




Rys. 7.6. Rozrzut punktów na powierzchni walca dla odległości 50 m

Kolejnym parametrem jest określenie maksymalnej liczby iteracji przewidzianej na wyszukiwanie. Ostatnimi dwoma parametrami są promienie: minimalny i maksymalny wyszukiwanego walca. Parametr określający długość walca jest wyznaczany na podstawie punktów sklasyfikowanych na walcu, dlatego nie jest wcześniej wymagany. Na rys. 7.7 przedstawiono wyznaczone promienia walca dla różnych odległości. Rzeczywisty walec zmierzono metodą klasyczną a jego promień wynosił 62,5 mm. Analizując uzyskane wyniki można stwierdzić, że pomiar obiektu do odległości 10 m daje bardzo dobre efekty uzyskując dużą zbieżność z pomiarem klasycznym. Należy zaznaczyć, że chmura punktów reprezentująca walec zawierała niewielki szum oraz łączną liczbę punktów około 1400 punktów dla każdego z pomiarów.




Rys. 7.7. Wyznaczanie wartości promienia w zależności od odchyłek wektorów normalnych

Pomiary w odległości 30 m wykazują zbieżność dopiero dla odchyłki wektorów normalnych wynoszącej 0,6. Ponieważ większość punktów w chmurze znajdowała się na walcu przy odpowiednio dużej odchyłce uzyskano prawidłowy wynik promienia. Pomiar w odległości 50 m obarczony jest niestety zbyt dużym rozrzutem punktów, co ostatecznie spowodowało błędne dopasowanie parametrów walca. Na rys. 7.8 przedstawiono ilościowe rozkłady w zależności od zmiany odchyłki wektora normalnego. Analizując dane stwierdzono, że w pewnym momencie występuje znaczny procentowy wzrost punktów przypisanych do klastra, co zwykle oznaczało dodanie błędnych punktów uwzględnianych w obliczeniach, w efekcie czego wynik pomiaru był błędny. Zjawisko takie można dobrze zaobserwować dla pomiaru 50 m gdzie znaczny skok można zaobserwować dwukrotnie i wiąże się to z dużym szumem danych i problemem dopasowania właściwego walca. Na rysunkach 7.9 oraz 7.10 przedstawiono wizualny rozkład punktów przypisanych do walca dla wartości odchyłki wynoszącej 0,1 oraz 0,6 mm.




Rys. 7.8. Przyrost liczby punktów wraz ze zmianą odchyłek wektorów normalnych

W przypadku, gdy większość punktów w chmurze punktów znajduje się na walcu nawet niewielka liczba punktów pozwala na prawidłowe wyznaczenie jego promienia.




Rys. 7.9. Punkty przypisane do walca zaznaczono kolorem brązowym dla 0,1 wartości odchyłki wektora normalnego



Rys. 7.10. Punkty przypisane do walca zaznaczono kolorem niebieskim dla 0,6 wartości odchyłki wektora normalnego

W wyniku działania metody RANSAC uzyskuje się dodatkową informację na temat orientacji osi wyszukanego walca, co pozwala na dopasowanie walca do chmury punktów. Początek i koniec elementu wyznaczany jest na podstawie punktów granicznych przypisanych wcześniej do walca. Na rysunku 7.11 przedstawiono przykład bryły dopasowanej do badanej chmury punktów.



Rys. 7.11. Przykład bryły dopasowanej do chmury punktów

7.3. Podsumowanie rozdziału

W rozdziale skupiono się na elemencie rekonstrukcji obiektu w oparciu o zadane parametry z użyciem metody RANSAC. Przedstawiono podstawowe zalety oraz ograniczenia metody. Podstawowym ograniczeniem metody jest fakt, że w przypadku, gdy liczba punktów leżących poza modelem wynosi więcej niż 50% często generuje błędne wyniki. W rozdziale przedstawiono problem doboru parametrów wejściowych metody. Wykonano szereg pomiarów dla różnych odległości w celu weryfikacji możliwości metody dla danych różnej jakości. Można zaobserwować, że dla odległości (1-10) m metoda uzyskuje dobra zbieżność z stanem faktycznym obiektu. Badania wykonano pod kątem wyszukiwania płaszczyzn oraz walców. Przedstawiono przykładowe rozkłady punktów na powierzchniach obiektu w zależności od najistotniejszych parametrów wejściowych. Niestety wyniki wyszukiwania dla odległości (30-50) m zakończyły się niepowodzeniem lub błędnym wyznaczeniem parametrów szukanego obiektu, co sugeruje że wiarygodność stosowania metody dla tych odległości jest wątpliwa. Rozwiązaniem może być zastosowanie skanu podwójnego lub zaproponowanej metody podnoszenia dokładności z wykorzystaniem serii pomiarowych, gdyż sam producent sugeruje, że dla odległości 45 m powinno się wykorzystywać skan podwójny. Podejście takie pozwoli na zmniejszenie odchylenia standardowego dopasowanej powierzchni elementu, co powinno zaowocować lepszym dopasowaniem metodą RANSAC.

8. Analiza wyników działania opracowanej metody


8.1. Realizacja na danych rzeczywistych

Opracowana metoda miała na celu umożliwienie przetwarzania danych rzeczywistych w postaci chmury punktów. W przypadku danych rzeczywistych zawsze pojawia się problem

zaszumienia, dlatego metoda zakłada, że przed przystąpieniem do przetwarzania dane zostaną odfiltrowane pod kątem losowych błędów pomiarowych. Aby utworzyć jednolity segment reprezentujący element instalacji rzeczywistej przyjęto kilka założeń:


- obiekt nie jest przezroczysty,
- szukany obiekt nie jest przesłonięty przez inne obiekty,
- powierzchnia obiektu nie pochłania światła.

Jako obiekt badawczy wybrano fragment instalacji węzła cieplnego. Chmura punktów „widziana” z punktu widzenia skanera przedstawiono na rys.8.1. Pierwotna chmura składała się z 1 969 619 punktów. Zdecydowano się jednak na częściowe rozrzedzenie danych, aby można było przedstawić elementy istotne z punktu widzenia prowadzonych badań. W efekcie chmurę zredukowano do 213 913 punktów. Pomiar wykonano z odległości 5 m, co jak wykazano w wcześniejszych rozdziałach jest optymalną odległością zarówno z punktu widzenia metody RANSAC jak i możliwości technicznych urządzenia.



Rys. 8.1. Fragment instalacji w postaci chmury punktów


Aby uzyskać wszystkie możliwe punkty pomiarowe w scenie zdecydowano się na wyłączenie filtrów zaszytych w oprogramowaniu producenta. Głównym powodem jest fakt, że algorytmy w oparciu o które realizowane jest filtrowanie nie są jawne co utrudniałoby interpretację wyników dla różnych scen pomiarowych. Podejście takie spowodowało wystąpieniem szumu na krawędziach obiektów. Do odfiltrowania szumu wykorzystano metodę opisaną w rozdziale 4 wykorzystującą algorytm kNN. Wynik filtracji badanej sceny przedstawiono na rys 8.2.




Rys. 8.2. Filtracja sceny pomiarowej

Punkty oznaczone na czerwono zakwalifikowano jako szum, w efekcie chmura po filtracji zawierała 211 942 punkty. W tym przypadku zastosowanie metody filtracji bazującej na intensywności nie jest dobrym rozwiązaniem gdyż punkty pomiarowe znajdujące się na elementach połyskliwych zakwalifikowane zostały jako szum co było zjawiskiem niepożądanym.

Następnie zgodnie z algorytmem przedstawionym w rozdziale 6, w kolejnym kroku podzielono chmury na niezależne linie pomiarowe. Wykonanie tego kroku, dla podanej sceny, przedstawiono na rys. 8.3. W wyniku działania tego etapu uzyskano 1669 niezależnych segmentów reprezentujących kolejne obroty zwierciadła skanera. Rysunek 8.4 przedstawia całą scenę pomiarową przetransformowaną do układu XZ w celu wykorzystania Transformaty Hougha do segmentacji łuków i odcinków. W rzeczywistości oprogramowanie nie obraca całej sceny do jednej płaszczyzny, ale pracuje na kolejnych liniach.




Rys. 8.3. Podział sceny na niezależne linie



Rys. 8.4. Scena przetransformowana do układu XZ

Wynik segmentacji pojedynczej linii skanu przedstawiono na rys. 8.5. Tworzone są segmenty o określonej klasie łuk lub odcinek. Proces ten powtarzany jest dla kolejnych linii.



Rys. 8.5. Segmentacja pojedynczej linii

Przykład fragmentu kilku linii z podziałem na segmenty wyznaczone przy użyciu transformaty Hougha pokazano na rys. 8.6. Każdy z segmentów na potrzeby lepszej wizualizacji oraz weryfikacji poszczególnych klastrów oznaczony jest losową barwą. Wybrano fragment na sceny składający się z trzech linii, na których widoczny jest fragment ściany w postaci segmentów odcinkowych oraz rury w postaci trzech niezależnych elementów łukowych.



Rys. 8.6. Segmentacja kolejnych linii sceny

Kolejnym etapem jest proces ponownego grupowania danych w obrębie sąsiednich linii. Proces grupowania został szczegółowo opisany w rozdziale 6. Zaproponowana metoda na chwilę obecną nie radzi sobie w pełni z wałcami zorientowanymi wzdłuż osi Z skanera. W związku z tym walce takie poprzez transformatę Hougha klasyfikowane są jako hipotetyczne płaszczyzny. Efekt ten można zaobserwować na rys. 8.7, jako grupę wielobarwnych pasów w prawym dolnym rogu skanu.



Rys. 8.7. Grupowanie utworzonych segmentów metodą RANSAC

Problem ten można rozwiązać próbując dane do regularnej siatki, co pozwoliłoby zweryfikować część problematycznych elementów. Podejście takie jednak w znacznym stopniu obniży dokładność danych pomijając część punktów. Rysunek 8.8 prezentuje rezultat końcowy sceny podzielonej na segmenty. Każdy z segmentów zapisywany jest do osobnego pliku, co ułatwia dalsze przetwarzanie.



Rys. 8.8. Istotne elementy sceny pomiarowej

W wyniku przetwarzania uzyskano 43 niezależne segmenty opisujące elementy sceny oraz jeden segment zawierający punkty nieprzypisane oznaczone kolorem szarym na rys. 8.8. Łączny czas przetwarzania wyniósł 15 min. Proces ten ulega wielokrotnemu skróceniu poprzez zrównoleglenie etapu odpowiadającego za wyszukiwanie obiektów przy użyciu transformaty Hougha. Wyniki z kolejnych linii na tym etapie są niezależne zaś każda z linii przyjmuje cechuje się zbliżoną liczbą danych.

8.2. Podsumowanie rozdziału i uzyskanych rezultatów

Rozdział prezentuje wyniki działania poszczególnych etapów przetwarzania dla danych rzeczywistych. Dane uzyskano skanując elementy węzła ciepłego. Aby uzyskać jak najwierniejszą informację dotyczącą skanowanej sceny zdecydowano się wyłączyć metody filtracji zaszyte w oprogramowania producenta. Do odfiltrowania danych wykorzystano metodę zaproponowaną w rozdziale 4 bazującą na algorytmie kNN. Metoda bazująca na intensywności nie znalazła tutaj zastosowania, gdyż skanowane obiekty posiadały miejsca silnie refleksyjne, co rodziło niebezpieczeństwo utraty części punktów pomiarowych na obiekcie poprzez sklasyfikowanie ich jako szum. W wyniku segmentacji na pojedyncze linie uzyskano ponad 1,5 tys elementów, a w obrębie pojedynczych linii, w wyniku procedur grupowania, uzyskano kilkadziesiąt niezależnych segmentów. Zaproponowana metoda pozwala znacząco skrócić czas wykonywania obliczeń, poprzez ich zrównoleglenie, dzięki zaproponowanej strukturze danych.

9. Podsumowanie i wnioski

Techniki skaningu laserowego są dziedziną nauki rozwijającą się bardzo dynamicznie. Nowe typy skanerów oferują coraz wyższą dokładność oraz precyzję, jednocześnie zwiększając zasięg działania. Przy tak szybkim rozwoju technologicznym, w którym nowe dziedziny potencjalnych zastosowań wciąż są odkrywane problemem staje się ogromna, liczona w GB, ilość danych, które należy przetworzyć. Dane nieprzetworzone mogą posłużyć jedynie, jako scena wykorzystywana do wykonywania prostych manualnych pomiarów obiektów. Scena reprezentuje statykę obiektu w danej chwili czasu. Bezpośrednie przeniesienie metod identyfikacji obiektów (choćby tych najprostszych jak płaszczyzna, sfera czy walec) stosowanych dla obrazów (w których ich odpowiednikami są odcinki i łuki), jest nieefektywne a dodatkowo wymaga interakcji z operatorem obsługującym program. Od jego wiedzy i doświadczenia często zależą uzyskane rezultaty.

Celem niniejszej pracy było opracowanie metody pozwalającej na przetwarzanie danych rzeczywistych pozyskanych ze skaningu laserowego na potrzeby inwentaryzacji instalacjach przemysłowych, głównie pod kątem identyfikacji w nich elementów rurowych. Funkcjonalność tę osiągnięto dzięki opracowanej metodzie filtracji oraz strukturze danych pozwalającej na szybkie identyfikowanie wybranych elementów sceny pomiarowej.

Proponowana metoda wykorzystuje wieloetapową segmentację danych pozwalającą na dekompozycję danych z trójwymiarowego układu współrzędnych do układu dwuwymiarowego, w którym następnie wykorzystano metody przetwarzania obrazu dwuwymiarowego. Opracowane narzędzie zweryfikowano w oparciu o dane rzeczywiste ze skanera laserowego.

W wyniku realizacji pracy rozwiązano pewne problemy oraz uzyskano następujące rezultaty:

- Dane uzyskane w wyniku skanowania laserowego zawsze obciążone są szumem wynikającym z ograniczeń urządzenia związanym z różnorodnością badanych powierzchni, oraz możliwościami technicznymi samego urządzenia. Uzyskany szum całkowicie utrudnia lub wydłuża proces dopasowywania elementu. Parametr intensywności uzyskiwany podczas pomiaru powierzchni może posłużyć, jako informacja o jakości pomiaru w danym punkcie.

Opracowano algorytmy oraz implementację dwóch metod pozwalających odfiltrować dane: na bazie wzajemnej odległości pomiędzy punktami w chmurze oraz filtracji bazującej na wyszukiwaniu punktów o określonej intensywności, którą wcześniej sklasyfikowano jako szum. Obie metody dały oczekiwane efekty, ale wymagały od operatora doświadczenia w określaniu ich parametrów wejściowych.

- Metoda iteracyjna RANSAC wykorzystywana do wyszukiwania określonych wzorców w obrazie uzyskuje prawidłowe wyniki w przypadku, gdy przynajmniej 50% próbek pomiarowych znajduje się na wyszukiwanym wzorcu. W przypadku danych rzeczywistych, w których obszar pomiaru niejednokrotnie wynosi kilkadziesiąt m², przy zarejestrowaniu wszystkich elementów znajdujących się w scenie metoda RANSAC zwykle generuje błędne wyniki.

Opracowano metodologię pozwalającą na wykorzystanie metody RANSAC do pracy na danych rzeczywistych. Możliwość taką uzyskano poprzez odpowiednie przygotowanie próbek danych poprzez ich wcześniejszą filtrację, segmentację a następnie klasyfikację, jako punkty przypisane do płaszczyzny lub walca. Podejście takie nie tylko pozwoliło wykorzystać metodę RANSAC, której warunkiem wykorzystania jest maksymalna ilość danych poza obiektem wynosząca 50%, ale jednocześnie pozwoliło znacznie skrócić ilość wykonywanych iteracji, które jednocześnie przekładają się na szybkość metody.

- Transformata Hougha jest narzędziem do wykrywania wcześniej określonych wzorców zarówno w obrazach 2D jak i 3D. Jest to metoda kosztowna obliczeniowo ze względu na dużą ilość operacji, które należy wykonać oraz pamięciowo, co z kolei jest uwarunkowane koniecznością akumulacji wyników. Wraz ze wzrostem ilości danych przyrost tablicy akumulacji ma charakter wykładniczy. Dlatego też w przypadku chmur punktów, dla

których dane często liczone są w mln punktów, kluczowa jest wcześniejsza segmentacja danych.

Zaadaptowano algorytm transformaty Hougha dla efektywnego przetwarzania danych zawierających współrzędne trójwymiarowe, na potrzeby przetwarzania chmur punktów, wykorzystującego transformatę Hougha używaną dla danych dwuwymiarowych.

- Nieprzetworzona chmura punktów może służyć głównie na potrzeby prezentacji ze względu na swoją złożoność. Operator chcąc wykonać jakieś operacje na fragmencie chmury reprezentującej np. fragment instalacji musi wcześniej manualnie go wydzielić, co w przypadku rozległych scen jest czasochłonne i często niejednoznaczne poprzez przypadkowo wskazane błędnie punkty chmury.

Opracowano unikalną strukturę danych pozwalającą na szybkie identyfikowanie wybranych elementów sceny pomiarowej. Struktura jest obiektem wirtualnym, do której zostają zaimportowane dane. Dzięki temu pliki wejściowe zawsze pozostają nienaruszone. Istnieje możliwość zapisu do plików zewnętrznych zarówno pojedynczych linii pomiarowych jak i grup punktów sklasyfikowanych, jako punkty leżące na płaszczyznach i walcach.

Podczas realizacji pracy występowały pewne problemy techniczne, których rozwiązanie zliczyć można do efektów praktycznych zrealizowanej pracy:

- Przetwarzanie chmury punktów pozyskanej w wyniku pomiaru obiektu rzeczywistego wymaga znacznej mocy obliczeniowej. Możliwość łączenia kilku skanów ze sobą sprawia, że ograniczenia dotyczące wielkości chmury wynikają tylko i wyłącznie z ilości pamięci jednostki wykorzystywanej do ich przetwarzania. Dlatego tak istotna jest segmentacja chmury punktów w oparciu o różne kryteria.

Wykonano komputerową implementację transformaty Hougha tak, aby można było ją wykorzystać na potrzeby przetwarzania chmur punktów. Implementację napisano w języku C++ i może zostać ona wykorzystana, jako niezależny moduł wykorzystywany przy współpracy z bibliotekami PCL służącymi do przetwarzania chmur punktów. Metoda została opracowana w taki sposób, że można w łatwy sposób wykonać obliczenia równoległe.

- Chmura punktów jest obiektem trudnym do interpretacji, gdyż nie daje jednoznacznej informacji na temat geometrii całego obiektu a jedynie serii niezależnych pomiarów punktowych. Określenie położenia obiektu przy pomocy chmury punktów wymaga opisu matematycznej relacji pomiędzy poszczególnymi punktami.

Zrealizowano oprogramowanie pozwalające na weryfikację oraz prezentację wyników opracowanej metody. Oprogramowanie pracuje na chmurach punktów, jako danych wejściowych oraz pozwala na określenie pozycji wybranych obiektów w przestrzeni trójwymiarowej. W wyniku działania programu operator uzyskuje informację o parametrach obiektu, położenie osi oraz promień elementu rurowego oraz informację o punktach reprezentujących dany obiekt.

- Dane producenta dotyczące wykorzystywanego urządzenia pomiarowego były bardzo ograniczone i przeprowadzane dla ściśle określonych warunków często znacznie odbiegających od warunków panujących podczas rzeczywistego pomiaru. Dodatkowo na wynik pomiaru ma wpływ wiele czynników zarówno wewnętrznych (np. drgania własne) jak i zewnętrznych (np. temperatura), które dodatkowo utrudniają określenie rzeczywistych możliwości urządzenia.

Oceniono rzeczywiste możliwości skanera, zweryfikowane w oparciu niemiecką normę VDI/VDE 2634 dotyczącą badania dokładności skanerów laserowych. Zweryfikowano parametry takie jak błąd układu głowicy optycznej, błąd wskazania długości, błąd płaskości. Wykazano również ograniczenia związane z współczynnikiem odbicia materiału oraz jego wpływem na pomiar.

- Wykorzystywany skaner oferuje niepewność pomiaru dokładności na poziomie 0,6 mm dla pojedynczego skanu oraz 0,45 dla skanu podwójnego dla odległości 11m (wg producenta). Nieznana była zmiana niepewności pomiaru wraz ze zmianą odległości. Zbyt duża jej wartość, w przypadku obiektów położonych w znacznej odległości od skanera, często może dyskwalifikować pomiary jako dokładne.

Dokonano pomiarów dla szeregu wybranych odległości określając zakres zmian niepewności pomiaru współrzędnych i wzajemnego położenia. Potwierdzono możliwość zmniejszenia niepewności pomiaru współrzędnych poprzez wykonanie serii pomiarów wykonanych z jednego punktu bazowego. Podejście takie cechuje się lepszymi wynikami niż skorzystanie z metody skanu podwójnego zaimplementowanej w oprogramowaniu skanera.


Wobec powyżej przedstawionych efektów, uzyskanych na podstawie wyników uzyskanych dzięki oprogramowaniu autorskiemu teza pracy: „Na podstawie pomiarów uzyskanych ze skanowania laserowego powierzchni geometrii obiektu, w skład, którego wchodzi elementy rurowe oraz znajomości modeli elementów składowych obiektu, zbudowanych w oparciu o dokumentację techniczną, możliwe jest określenie parametrów określających geometrię i położenie wyszukiwanych elementów” została udowodniona.

Weryfikacja postawionych tez oraz przeprowadzone badania zaowocowały wnioskami i wskazówkami w zakresie przetwarzania chmur punktów oraz procesu wykonywania pomiaru skanerem laserowym:

1. Wzrost objętości danych w postaci chmury punktów na pewnym etapie wymusi konieczność wykorzystania przetwarzania równoległego. Co z kolei będzie wymagać wcześniejszej operacji segmentacji danych.
2. Wraz ze wzrostem postępu technologicznego będzie rosła złożoność instalacji przemysłowych, a wraz z nią zapotrzebowanie na kompleksowe systemy diagnostyczne.
3. Nie każdy rodzaj instalacji można zinwentaryzować przy pomocy technik skaningu laserowego. Przed przystąpieniem do wykonywania pomiaru należy wcześniej określić współczynniki odbicia powierzchni wszystkich obiektów istotnych z punktu widzenia pomiaru.
4. Stacjonarne skanery laserowe nie nadają się do rejestrowania szybkich zmian geometrii zachodzących na obiekcie. Wiąże się to głównie z procesem konieczności przetwarzania danych online w trybie automatycznym, czego na chwilę obecną nie udało się jeszcze zrealizować dla skanerów laserowych badanego typu.

10. Kierunki dalszych badań

Opracowane rozwiązanie ma wiele potencjalnych ścieżek zastosowań, lecz w pracy skupiono się na wyszukiwaniu elementów dwóch typów, jakimi są płaszczyzny oraz walce. Podejście takie podyktowane jest specyfiką instalacji pod kątem, której prowadzono badania. Docelowym obiektem badawczym, dla którego zostanie wykonana analiza powierzchni jest ekran kotła energetycznego elektrowni. Na rysunku 10.1 przedstawiono sposób łączenia rur kotłach dużej mocy. Można zaobserwować, że ekran kotła składa się z grupy charakterystycznych elementów, jakimi są rury oraz elementy łączeniowe, które można uogólnić do płaszczyzn.



Rys. 10.1. Sposób łączenia rur palenisk kotłów energetycznych dużej mocy. Wymiary zależą od typu kotła i wynoszą kolejno: a – od 5 do 20 mm; b – 5 mm; r – od 7,5 do 27,5; R odpowiednio – od 12,5 do 33,5 [94]

Obecnie diagnostyka powierzchni kotłów energetycznych polega na żmudnym i czasochłonnym pomiarze grubości ekranów cieplnych przy użyciu grubościomierzy ultradźwiękowych. Kontrola pomiarów jest wybiórcza, głównie ze względów ekonomicznych, gdyż czas pomiaru wydłuża wyłączenie kotła z eksploatacji. Na rys. 10.2 przedstawiono wycinek ekranu, na którym można zaobserwować stopień degradacji zarówno elementów rurowych jak i elementów łączących.



Rys. 10.2. Przykład degradacji powierzchni w kotle energetycznym

Z punktu widzenia badania powierzchni nie istotna jest odległość elementu do skanera, a wzajemne relacje pomiędzy obiektami w scenie (rura - łącznik). Badania posłużą do szybkiej oceny stanu degradacji oraz wytypowania miejsc, w których ubytki na rurach są największe, aby w tych miejscach przeprowadzić szczegółowe pomiary ultradźwiękowe. Pojedynczy pomiar skanerem dla podanej odległości pozwala na uzyskanie wyników odległości z niepewnością 0,6 mm. Jak wykazano w pracy wielokrotny pomiar pozwala na jej zmniejszenie. Znając początkowy kształt ekranu, w szczególności w obszarze podlegającym diagnostyce jako wycinek walca i tworząc na podstawie uśrednionych pomiarów powierzchnie, możliwe jest uzyskiwanie danych o ubytkach, z niepewnością rzędu 0,2 mm już przy 10-krotnie przeprowadzonym skanowaniu, którego łączny czas nie przekracza 40 minut i pozwala jednorazowo uzyskać dane z obszaru około 600-900 m² z bardzo dużą szczegółowością.

Kolejnym kierunkiem badań będzie rozszerzenie bazy wyszukiwanych wzorców wykorzystując deskryptory złożonych kształtów oraz opracowanie wzajemnych zależności i relacji pomiędzy bryłami prostymi dopasowanymi do chmury punktów. W efekcie możliwe będzie uzyskanie wielopoziomowego modelu instalacji mogący posłużyć, jako obiekt do przeprowadzania symulacji, czy też jako model diagnostyczny. Podejście takie znacznie rozszerzy użyteczność opracowanego rozwiązania w stosunku do różnych obiektów infrastruktury technicznej.

Bibliografia

- [1] Jain R., Kasturi R., Schunck B. G.: *Machine Vision*. McGraw-Hill, Inc., New York, 1995.
- [2] Grimson W. E. L.: *Object Recognition by Computer: The Role of Geometric Constraints*. MIT Press, Cambridge, MA, 1990.
- [3] Chora's R. S.: *Komputerowa wizja. Metody interpretacji i identyfikacji obiektów*. Akademicka Oficyna Wydawnicza EXIT, 2004.
- [4] Cyganek B.: *An Introduction to 3D Computer Vision Techniques and Algorithms*. John Wiley & Sons, 2007.
- [5] Li J., Li E., Chen Y., Xu L., Zhang Y.: *Bundled Depth-Map Merging for Multi-View Stereo*. Computer Vision and Pattern Recognition, 2010, pp. 2769-2776.
- [6] Braid I. C.: *Designing with Volumes*. PhD dissertation, CANTAB Press, Cambridge Computer Laboratory, University of Cambridge, 1974.
- [7] Requicha A. A.: *Mathematical Models of Rigid Solid Objects*. Raport instytutowy, Production Automation Project / TM-28, University of Rochester, 1977.
- [8] Inverso S.A.: *Ellipse Detection Using Randomized Hough Transform*, Final Project: Introduction to Computer Vision, 2006, pp. 4005-757.
- [9] Brooks R. A.: *Symbolic Reasoning among 3D Models and 2D Images*. Artificial Intelligence, vol. 17, Brooks and R.A. 1981, pp. 285-348.
- [10] Fedorov E.: *Symmetry in the plane*. Proceedings of the Imperial St. Petersburg Mineralogical Society, series 2, volume 28, 1891, pp. 245-291.
- [11] Kepler J.: *Harmony of the Worlds*. Forgotten Books, 2008.
- [12] Frackiewicz M., Palus H.: *Outlier-based initialisation of K-means in colour image quantisation*, Informatics and Applications (ICIA), 2013, pp. 36-41
- [13] Newton I.: *A photogrammetric method for measuring the change in body volume associated with anaesthesia*, IAPRS, Kyoto, 1988, pp. 436-442.
- [14] Hejmanowska B., Borowiec N., Badurska M.: *Przetwarzanie lotniczych danych lidarowych dla potrzeb generowania NMT i NMPT*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 18, 2008, s. 151-162.
- [15] Borowiec N.: *Reconstructing building model based on integrating lidar data and cadastral maps*. Archiwum Fotogrametrii, Kartografii i Teledetekcji, vol. 21, 2010, s. 43-52.

- [16] Kraszewski B.: *Wykorzystanie naziemnego skaningu laserowego do inwentaryzacji pomieszczeń biurowych*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 23, 2012, s. 187-196.
- [17] Kamiński W., Bojarowski K., Dumalski A., Mroczkowski K., Trystuła J.: *Ocena możliwości wykorzystania skanera laserowego scanstation firmy leica w badaniu deformacji obiektów budowlanych*. Czasopismo Techniczne, Wydawnictwo Politechniki Krakowskiej, Kraków 2008.
- [18] Greblicki W.: *Nieparametryczna identyfikacja systemów*, Archiwum Automatyki i Robotyki, tom XXXVI, zeszyt 2, 1991, s. 277-290,
- [19] Salamończyk A.: *Generowanie modeli widokowych wielościanów monottonnych do identyfikacji wizualnej*, Rozprawa doktorska, Instytut Podstawowych Problemów Techniki PAN, Warszawa, 2011
- [20] Szymonik J.: *Widzenie maszynowe, jako narzędzie zapewniające wysoką jakość wyrobów*, Problemy Techniki Uzbrojenia, Wyd. Wojskowa Akademia Techniczna, 2010, s. 67-76
- [21] Rak M., Woźniak A.: *Wpływ algorytmu przetwarzania chmury punktów na dokładność wyznaczania wymiaru małych elementów*, Pomiar Automatyka Kontrola R. 59, nr 5 2013, s.406-409
- [22] Lowe D.G.: *Distinctive Image Features from Scale-Invariant Keypoints*. Journal of Computer Vision, 2004, pp. 91-110
- [23] Weichel H.: *Propagation in the Atmosphere*, SPIE Optical Engineering Press, Bellingham, 1990.
- [24] Marshall, G.F.: *Gaussian Laser Beam Diameters*. In Laser Beam Scanning; Optical Engineering Series, Marcel Dekker: New York, Vol. 9, 1985, pp. 289–301.
- [25] Sotoodeh S.: *Outlier detection in laser scanner point clouds*, IAPRS, Dresden, Germany, Sep. 25-27, vol. 36, 2006, pp. 297-298.
- [26] Cosarca C., Jocea A., Savu A.: *Analysis of error sources in Terrestrial Laser Scanning – RevCAD*. Journal of Geodesy and Cadastre, 2008, pp. 115-123.
- [27] Marmol U.: *Analiza algorytmów detekcji obiektów infrastruktury kolejowej na podstawie chmury punktów mobilnego skaningu laserowego*, Archiwum Fotogrametrii, Kartografii i Teledetekcji Vol. 24, 2012, s. 211-220.
- [28] Donoghue, D.N.M., Watt, P.J., Cox, N.J., Wilson, J.: *Remote sensing of species mixtures in conifer plantations using LIDAR height and intensity data*. Remote Sensing of Environment, 110(4), 2007, pp. 509-522.

- [29] Höfle, B., Pfeifer, N.: *Correction of laser scanning intensity data: Data and model-driven approaches*. ISPRS Journal of Photogrammetry and Remote Sensing, No. 62(6), 2007, pp. 415-433.
- [30] Bubnicki Z.: *Podstawy informatycznych systemów zarządzania*, Wydawnictwo Politechniki Wrocławskiej, Wrocław 1993.
- [31] Chmielniak T., Kosman G., Rusin A., Łukowicz H., Roskosz M.: *Rozwój metod diagnostyki eksploatacyjnej oraz nowych procedur sterowania pracą bloków energetycznych*. Materiały konferencyjne: Maszyny i urządzenia energetyczne zagrożenia eksploatacyjne, Szczyrk, 05 -06 czerwca 2001
- [32] Roy B.: *Wielokryterialne wspomaganie decyzji*, Wydawnictwo Naukowo-Techniczne, Warszawa 1990
- [33] Varady T., Martin R.R., Cox J.: (Editorial) *Special issue: Reverse engineering of geometric models*, Computer-Aided Design, Vol 29, No. 4, 1997, pp.253-254.
- [34] Karbowski K.: *Podstawy rekonstrukcji elementów maszyn i innych obiektów w procesach wytwarzania*, Oficyna Wydawnicza Politechniki Krakowskiej, Kraków 2008
- [35] Varady T., Martin R.R., Cox J.: *Reverse engineering of geometric models -Introduction*, Computer-Aided Design, Vol 29, No. 4 1997, pp.255-268.
- [36] Alda J.: *Laser and Gaussian Beam Propagation and Transformation*, Encyclopedia of Optical Engineering, New York, 2002.
- [37] Lesparre J.: *Noise reduction by range image filtering*, 9th Conference on Optical 3D Measurement Techniques, Vienna, July 1-3, t/m 47, No. 01/2009, pp. 38.
- [38] Firas A.J.: *Image Denoising Using Interquartile Range Filter with Local Averaging*, International Journal of Soft Computing and Engineering (IJSCE), Volume-2, Issue-6, January 2013, pp. 424-428
- [39] Cholewa W.: *Transakcje w diagnostycznych systemach doradczych*, Diagnostyka Procesów Przemysłowych, Materiały: II Konferencja Naukowo-Techniczna, Łągów Lubuski, 1997, s.51-56.
- [40] Tadeusiewicz R., Korohoda P.: *Komputerowa analiza i przetwarzanie obrazów*, Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków, 1997
- [41] Schall O., Belyaev A., Seidel H.P.: *Robust Filtering of Noisy Scattered Point Data*, Eurographics Symposium on Point-Based Graphics, 2005, pp. 71-77.
- [42] Sankaranarayanan J., Samet H., Varshney A.: *A Fast k-Neighborhood Algorithm for Large Point-Clouds*, Eurographics Symposium on Point-Based Graphics, Boston 2006, pp. 75-84.

- [43] 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, 24(6)/1981, pp. 381–395.
- [44] Torr P., Zisserman A.: *MLE-SAC: A new robust estimator with application to estimating image geometry*. Computer Vision and Image Understanding, No. 78(1)/2000, pp. 138-156.
- [45] VDI/VDE 2634 Optical 3D-measuring systems Multiple view systems based on area scanning December 2008.
- [46] Zator S., Michalski P.: *Możliwości wykorzystania skanera laserowego do pomiarów precyzyjnych*, Pomiar Automatyka Kontrola, nr 11/2012, s. 1013-1015.
- [47] Sithole G., Vosselman G.: *Experimental comparison of filter algorithms for bare-Earth extraction from airborne laser scanning point clouds*, ISPRS Journal of Photogrammetry & Remote Sensing 59, 2004, pp. 85-101.
- [48] Roggero, M.: *Airborne laser scanning: clustering in raw data*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIV (Pt. 3/W4), 2001, 227-232.
- [49] Sithole, G.: *Filtering of laser altimetry data using a slope adaptive filter*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIV (Pt. 3/W4), 2001, pp. 203-210.
- [50] Axelsson, P.: *DEM generation from laser scanner data using adaptive TIN models* International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXIII (Pt. B4/1), 2000, pp. 110–117.
- [51] Sohn G., Dowman I.: *Terrain surface reconstruction by the use of tetrahedron model with the MDL Criterion*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXIV (Pt. 3A), 2002, pp. 336–344.
- [52] Wack R., Wimmer A.: *Digital terrain models from airborne laser scanner data—a grid based approach*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXIV (Pt. 3B), 2002, pp. 293–296.
- [53] Pfeifer N., Kostli A., Kraus K.: *Interpolation and filtering of laser scanner data—implementation and first results*. International Archives of Photogrammetry and Remote Sensing, XXXII (Pt. 3/1), 1998, pp. 153–159.
- [54] Gonzalez R. C., Woods R.E.: *Digital Image Processing 2nd Edition*, Prentice Hall, New Jersey 2002.

- [55] Jarząbek-Rychard M., Borkowski A.: *Porównanie algorytmów RANSAC oraz rosnących płaszczyzn w procesie segmentacji danych lotniczego skaningu laserowego*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 21, 2010, s. 119-129.
- [56] Vosselman G., Maas H. G.: *Airborne and terrestrial laser scanning*. Whittles Publishing, Dunbeath, 2010.
- [57] Vosselman G.: *Point cloud segmentation for urban scene classification*, International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-7/W2, ISPRS2013-SSG, 11 – 17 November 2013, Antalya, Turkey, pp.257-262.
- [58] Omidalizarandi M., Saadatsersht M.: *Segmentation and classification of point clouds from dense aerial image matching*, The international Journal of Multimedia & Its Applications (LIMA) Vol 5, No 4. August 2013, pp. 33-51.
- [59] Poręba M., Goulette F.: *Automatyczna detekcja płaszczyzn w chmurze punktów w oparciu o algorytm RANSAC i elementy teorii grafów*, Archiwum Fotogrametrii, Kartografii i Teledetekcji Vol. 24, 2012, s. 301-310.
- [60] Choi S., Taemin K., Wonpil Y.: *Performance Evaluation of RANSAC Family*, In Proceedings of the British Machine Vision Conference 2009, pp. 1-12.
- [61] Zuliani M.: *RANSAC for Dummies*, With examples using the RANSAC toolbox for Matlab™ & Octave and more, 2012.
- [62] Derpanis G. K.: *Overview of the RANSAC Algorithm*, Version 1.2, May 13, 2010
- [63] How to use Random Sample Consensus model, ze strony http://www.pointclouds.org/documentation/tutorials/random_sample_consensus.php, czerwiec 2013.
- [64] Chum O.: *Two-View Geometry Estimation by Random Sample and Consensus*, PhD dissertation, Faculty of the Electrical Engineering, Czech Technical University in Prague July 1, 2005.
- [65] Mańczak K., Nahorski Z.: *Komputerowa identyfikacja obiektów dynamicznych*, Państwowe Wydawnictwo Naukowe, Warszawa 1983.
- [66] Mańczak K.: *Metody identyfikacji wielowymiarowych obiektów sterowania*, Wydawnictwa Naukowo-Techniczne Warszawa 1979.
- [67] Cholewa W.: *Metoda diagnozowania maszyn z zastosowaniem zbiorów rozmytych*. Zeszyty Naukowe Politechniki Śląskiej nr 764, Gliwice 1983.

- [68] Chrzanowski P.: *Metody definiowania klas wartości cech sygnałów diagnostycznych*, II Diagnostyka Procesów Przemysłowych, II Krajowa Konferencja Naukowo-Techniczna, 1997, s. 239-244.
- [69] Bobcow A., Dąbkowski M.: *Biometryczna kontrola dostępu*, Pomiary Automatyka Kontrola 4/2007, s. 87-90
- [70] Feerman T.G.: *The Radon Transform*, The mathematics of Medical Imaging: A beginner's Guide 2010, Springer, 2010.
- [71] Radon J.: *Über die Bestimmung von Funktionen durch ihre Integralwerte längs gewisser Mannigfaltigkeiten.* „Ber. Verh. Säch. Akad. Wiss.”, Nr 69,1917, s. 262-277.
- [72] Toft P.: *The Radon transform – Theory and Implementation* PhD. Thesis Department of Mathematical Modeling, Technical University of Denmark, 1996.
- [73] Frączek R.: *Analiza metod detekcji dyfrakcyjnych linii kikuchiego*, Rozprawa doktorska Akademia Górniczo-Hutnicza, Katedra metrologii, Kraków 2006.
- [74] Deans S. R., *Hough transform from the Radon transform*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 3, No. 2, 1981, pp. 185-188.
- [75] Budzan S.: *Detekcja powierzchni parametrycznych na podstawie zbioru punktów pomiarowych pozyskanych ze skanera 3D*, Rozprawa doktorska, Politechnika Śląska 2008.
- [76] Borrmann D., Elseberg J., Lingemann, K., Nüchter A.: *The 3D Hough Transform for Plane Detection in Point Clouds: A Review and a new Accumulator Design*, 3D Res. Vol. 02, 2011, pp. 1-13.
- [77] Lakaemper R., Latecki L. J.: *Extended EM for Planar Approximation of 3D Data*, In IEEE International Conference on Robotics and Automation (ICRA '06), Florida 2006, pp. 1173-1179.
- [78] Poppinga J., Vaskevicius N., Birk A., Pathak K.: *Fast Plane Detection and Polygonalization in noisy 3D Range Images*, In IROS '08, 2008, pp. 3378-3383.
- [79] Hulik R., Spanel M., Smrz P. Materna Z.: *Continuous plane detection in point-cloud data based on 3D Hough Transform*, Journal of Visual Communication and Image Representation, 2014, pp.86-97
- [80] Gorte B., Sithole G.: *Lokup Table Hough Transform for Real Time Range Image Segmentation and Feature Co-Registration*, Journal of Sensor Technology, Vol 2 2012, pp. 148- 154.

- [81] Richter R., Behrens M., Dollner J.: *Object class segmentation of massive 3D point clouds of urban areas using point cloud topology*, International Journal of Remote Sensing, Potsdam, 2013, pp. 8408-8424.
- [82] Smolka B.: *Adaptive generalized vector median*, Journal of Medical Informatics and Technologies, 12, Oct. 2008 pp. 157-162
- [83] Frackiewicz M., Palus H.: *A study on clustering for colour image quantisation*, Computational Vision and Medical Image Processing IV, 2013, pp.81
- [84] Tokarczyk R.: *Fotogrametria cyfrowa w zastosowaniach medycznych do pomiaru ciała ludzkiego – przegląd i tendencje rozwojowe systemów pomiarowych*, Geodezja, Kartografija i Aerofotogrametria. Mizbidomczij Naukowo-Technicznij Zbornik., Wipusk 66, 2005, pp. 233–241.
- [85] Cempel C., Tomaszewski F.: *Diagnostyka maszyn. Zasady ogólne. Przykłady zastosowań*. Wyd. MCNEMT, Radom 1992
- [86] Isermann R., Balle P.: *Terminology in the field of supervision, fault detection and diagnosis*. Zaakceptowane propozycje terminologiczne prez IFAC Komitet SAFEPROCESS
- [87] Bieniecki W., Sekulska J.: Segmentacja i analiza obrazów mikroskopowych barwionych munohistchemicznie. Automatyka tom 7 zeszyt 3, Uczelniane Wydawnictwa Naukowo-Dydaktyczne, Kraków, s.283-293
- [88] Wrotkowski J.: *Gospodarka remontowa - Pojęcia i zasady ogólne*, Wydawnictwo Naukowo-Techniczne, Warszawa 1969.
- [89] Wawerek Z.: *Machine vision, widzenie maszynowe albo ...*, Pomiary Automatyka Robotyka 4/2008, s. 6-7
- [90] Rafajłowicz E., Rafajłowicz W.: *Wstęp do przetwarzania obrazów przemysłowych*, Wrocław, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2010.
- [91] Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*. Państwowe Wydawnictwo Naukowe, Warszawa 1991.
- [92] Wróbel K.: *Metoda porównywania i klasyfikacji obrazów z wykorzystaniem transformacji Hougha*, Rozprawa doktorska, Uniwersytet Śląski, 2006.
- [93] Bieniecki W.: *Nowe algorytmy przetwarzania obrazów w wizyjnych systemach komputerowych wspomagających diagnostykę patomorfologiczną*, Rozprawa doktorska, Wydział Elektrotechniki i Elektroniki, Politechnika Łódzka, Łódź 2005.

-
- [94] Cader M.: *Prototyp wspinającej się platformy przeznaczonej do diagnostyki ścian paleniska kotłów energetycznych dużej mocy*. *Pomiary Automatyka Robotyka* 2/2012, s. 260-264
- [95] Hough, P.V.C. (1962). *Method and Means for Recognizing Complex Patterns*. US Patent 3069654.
- [96] Kościelny J.M., Szczepaniak P.: *Terminologia oraz klasyfikacja metod detekcji i diagnostyki procesów przemysłowych*, *Diagnostyka Procesów Przemysłowych*, II Konferencja Naukowo-Techniczna, Łągów Lubuski 1997, s.57-68.
- [97] Frome A., Huber D., Kolluri R., Bulow T., Malik J.: *Recognizing Objects in Range Data Using Regional Point Descriptors*, *Computer Vision ECCV*, Part III Springer 2004, pp. 224-237.
- [98] Beard L. F. H., Fee J. E.: *An approach to the introduction of stereophotogrammetry as an alternative to traditional methods of measurement*. IAPRS, Hamburg 1980, pp. 62-68.
- [99] Tombari F., Salti S., Di Stefano L.: *Unique Shape context for 3D Data Description*, *3DOR Proceedings of the ACM workshop on 3D object retrieval*, 2010, pp. 57-62.

Spis rysunków

- Rys. 2.1. Gaussowski przekrój poprzeczny wiązki lasera [36]
- Rys. 2.2. Możliwe przypadki pomiaru krawędzi obiektu
- Rys. 2.3. Szum powstały po skanowaniu krawędzi
- Rys. 2.4. Zdjęcie skanera laserowego Trimble FX
- Rys. 2.5. Rozkład punktów dla pojedynczej linii w płaszczyźnie XY
- Rys. 2.6. Rozkład empiryczny odchyłek pomiaru odległości dla pojedynczej linii na tle krzywej rozkładu normalnego
- Rys. 2.7. Rozkład empiryczny odchyłek pomiaru odległości dla 10 linii na tle krzywej rozkładu normalnego
- Rys. 2.8. Model do wyznaczania błędu układu głowicy optycznej oraz chmura punktów z dopasowaną kulą
- Rys. 2.9. Model do wyznaczania błędu wskazania długości
- Rys. 3.1. Graficzna prezentacja zagadnienia kolinearności wektorów
- Rys. 3.2. Przykład wizualizacji chmury punktów ze skanera naziemnego
- Rys. 3.3. Przykład złożenia kilku skanów
- Rys. 3.4. Zasada działania systemu z zastosowaniem wiązki laserowej [84]
- Rys. 3.5. Zasada działania systemu z wykorzystaniem wzorca świetlnego [84]
- Rys. 3.6. Zasada działania systemu z wykorzystaniem wzorca świetlnego oraz dwóch kamer [84]
- Rys. 4.1. Stacja bez wykonanej segmentacji
- Rys. 4.2. Stacja po wykonaniu segmentacji oraz usunięciu segmentu odpowiadającego za szum
- Rys. 4.3. Przykład wykorzystania filtracji na bazie wykrywania zagęszczenia punktów
- Rys. 5.1. Algorytm rosnących płaszczyzn. Diagram aktywności [55]
- Rys. 5.2. Graficzne przedstawienie kolejnych kroków identyfikacji płaszczyzny
- Rys. 5.3. Segmentacja na bazie gęstości chmury.
- Rys. 5.4. Wejściowa próbka danych [63]
- Rys. 5.5. Prezentacja wyniku działania algorytmu RANSAC [63]
- Rys. 5.6. Przykład wyszukiwania prostej z wykorzystaniem Transformaty Hougha
- Rys. 5.7. Typy akumulatorów [76]
- Rys. 5.8. Płaszczyzna weryfikacji możliwości transformaty Hougha 3D
- Rys. 5.9. Reprezentacja pojedynczego punktu w przestrzeni Hougha, jako sinusoida 3D
- Rys. 5.10. Punkt przecięcia sinusoid 3D reprezentuje parametry szukanej płaszczyzny

- Rys. 5.11. Zależność ilości punktów oraz kroku kwantyzacji do wielkości tablicy akumulacji
- Rys. 6.1. Zasada obrotu lustra skanera laserowego podczas wykonywania pomiaru
- Rys. 6.2. Orientacyjna zasada segmentacji pojedynczej linii na zasadzie rachunku wektorowego
- Rys. 6.3. Algorytm segmentacji linii
- Rys. 6.4. Przykład nieposegmentowanej sceny
- Rys. 6.5. Przykład sceny z wykonaną segmentacją linii
- Rys. 6.6. Wynik obrotu wszystkich linii do układu XZ
- Rys. 6.7. Wynik działania segmentacji na bazie odległości, z lewej obiekt przed a z prawej po segmentacji
- Rys. 6.8. Wynik działania segmentacji na bazie odległości
- Rys. 6.9. Wynik działania segmentacji na bazie odległości
- Rys. 6.10. Wynik działania segmentacji na bazie odległości z jedną klasą obiektów w ramach segmentu
- Rys. 6.11. Ostateczny pożądany wynik działania segmentacji
- Rys. 6.12. Alternatywny ostateczny wynik działania segmentacji
- Rys. 6.13. Graficzna reprezentacja przestrzeni Hougha
- Rys. 6.14. Iteracyjny algorytm identyfikowania obiektów w obrębie segmentu
- Rys. 6.15. Zasada wyszukiwania okręgu o znanym promieniu r przy użyciu Transformaty Hougha
- Rys. 6.16. Zasada wyszukiwania okręgu o znanym r przy użyciu Transformaty Hougha
- Rys. 6.17. Tablica akumulacji dla okręgu o zmiennym promieniu
- Rys. 6.18. Tablica akumulacji dla łuku z wyznaczonym środkiem
- Rys. 6.19. Struktura danych utworzona w procesie segmentacji
- Rys. 6.20. Graficzna prezentacja mechanizmu grupowania
- Rys. 6.21. Diagram prezentujący kolejne etapy przetwarzania danych w zaproponowanej metodzie
- Rys. 7.1. Chmura punktów uzyskana po przeskanowaniu kartki papieru
- Rys. 7.2. Wykres zależności pomiędzy ilością punktów przypisanych do płaszczyzny a odległością
- Rys. 7.3. Wykres zależności pomiędzy czasem wyznaczania najlepiej dopasowanej płaszczyzny
- Rys. 7.4. Przykład punktów przypisanych do płaszczyzny dla kryterium odległości wynoszącego 0.1 mm
- Rys. 7.5. Przykład punktów przypisanych do płaszczyzny dla kryterium odległości wynoszącego 1 mm
- Rys. 7.6. Rozrzut punktów na powierzchni walca dla odległości 50 m
- Rys. 7.7. Wyznaczanie wartości promienia w zależności od odchyłek wektorów normalnych
- Rys. 7.8. Przyrost liczby punktów wraz ze zmianą odchyłek wektorów normalnych

Rys. 7.9. Punkty przypisane do walca dla 0,1 wartości odchyłki wektora normalnego

Rys. 7.10. Punkty przypisane do walca dla 0,6 wartości odchyłki wektora normalnego

Rys. 7.11. Przykład bryły dopasowanej do chmury punktów

Rys. 8.1. Fragment instalacji w postaci chmury punktów

Rys. 8.2. Filtracja sceny pomiarowej

Rys. 8.3. Podział sceny na niezależne linie

Rys. 8.4. Scena przetransformowana do układu XZ

Rys. 8.5. Segmentacja pojedynczej linii

Rys. 8.6. Segmentacja kolejnych linii sceny

Rys. 8.7. Grupowanie utworzonych segmentów metodą RANSAC

Rys. 8.8. Istotne elementy sceny pomiarowej

Rys. 10.1. Sposób łączenia rur palenisk kotłów energetycznych dużej mocy. Wymiary zależą od typu kotła i wynoszą kolejno: a – od 5 do 20 mm; b – 5 mm; r – od 7,5 do 27,5; R odpowiednio – od 12,5 do 33,5 [94]

Rys. 10.2. Przykład degradacji powierzchni w kotle energetycznym

Spis tabel

Tab. 2.1. Parametry skanera Trimble FX wg danych producenta

Tab. 2.2. Parametry linii dla kolejnych serii pomiarów: średnia współrzędna X_{sr} , jej odch. std. σ_x , odchylenie linii od pionu oraz skorygowana wsp. X_0

Tab. 2.3. Wyniki obliczeń odchyłeń standardowych na podstawie pomiaru parametrów kuli

Tab. 2.4. Wyniki pomiaru testu „ball bar”

Tab. 6.1. Organizacja tablicy przechowującej wartości odległości

Tab. 6.2. Organizacja tablicy głosowania

Identyfikacja i rekonstrukcja elementów rurowych w instalacjach przemysłowych na potrzeby inwentaryzacji

Streszczenie

Praca dotyczy możliwości wykorzystania technik skaningu laserowego na potrzeby diagnostyki elementów instalacji technicznych. W pracy przeprowadzono analizę literatury dotyczącej diagnostyki procesu obejmującej problematykę związaną z identyfikacją obiektu oraz procesem jego rekonstrukcji. Zwrócono uwagę na możliwości wykorzystania metod przetwarzania obrazu na potrzeby diagnostyki. Omówiono możliwe źródła zakłóceń dla wykorzystywanego w pracy skanera laserowego. Przedstawiono problem szumu w danych skaningowych oraz różne podejścia stosowane w zależności od jego specyfiki. Zaproponowano metodę pozwalającą na filtrację chmur punktów w oparciu o pomiar współczynnika intensywności odbicia wiązki laserowej dla każdego z punktów. Przedstawiono metody najczęściej wykorzystywane opisane w literaturze oraz ich modyfikacje i implementacje wykorzystane na potrzeby opracowanego systemu.

Autor przeprowadził szereg testów i eksperymentów praktycznych pozwalających ocenić możliwości wykorzystania skanera Trimble FX w diagnostyce. Zaproponowano również metodę podnoszenia rozdzielczości bazującą na seriach pomiarowych.

Przedstawiono proces segmentacji danych oraz jego celowości w przypadku danych pozyskanych ze skanerów. Zaprezentowano istniejące metody wykorzystywane dla danych skaningowych oraz przykłady ich wykorzystania w opracowanym systemie. W pracy zrealizowano modyfikację transformaty Hougha tak, aby można ją było wykorzystać na potrzeby segmentacji danych skaningowych.

Zaproponowana metoda wykorzystuje specyfikę skanera laserowego, generującego dane w postaci niezależnych linii pomiarowych. Każdą z linii transformuje się do układu 2D, zerując jedną ze współrzędnych. Następnie wyszukiwane są grupy punktów leżące blisko siebie i na ich podstawie tworzony jest podstawowy segment. Kolejnym etapem jest identyfikacja elementów w obrębie segmentu. Metoda pozwala na wyszukiwanie odcinków oraz łuków dzięki zaimplementowanej metodzie transformaty Hougha. Po analogicznej analizie wszystkich linii następuje grupowanie elementów począwszy od pierwszej linii. Uzyskuje się w ten sposób grupy segmentów jednego typu np. odcinki lub łuki leżące w sąsiednich liniach. W pracy zawarto szczegółowe opisy poszczególnych etapów wraz z przykładami graficznymi prezentującymi wyniki poszczególnych etapów.

Zaprezentowano również wyniki działania poszczególnych etapów przetwarzania dla danych rzeczywistych. W wyniku działania proponowanej metody uzyskano kilkadziesiąt niezależnych segmentów. Końcowy etap pracy stanowi podsumowanie, zawiera konkluzje i wnioski autora na temat możliwości oraz ograniczeń związanych z interpretacją danych skaningowych. Przedstawiono również kierunki dalszych badań w zakresie rozwoju funkcjonalnego opracowanego systemu oraz jego potencjalnie nowe zastosowania.

Identification and reconstruction of pipe elements in industrial installations for the inventory purposes

Abstract

This dissertation concerns the possibility of using laser scanning techniques for diagnosing components of technical installations. In the first chapters author analyzes the literature of the diagnostic process, including issues related to the identification of the object and the process of its reconstruction. Author focused on the possibility of using image processing methods for the purpose of diagnosis. In the next chapter the sources of noise in the laser scanner data is described. Author presents the problem of noise in the scanning data and different approaches depending on its specifics. Proposed a two methods that allows filtering point clouds first is based on measuring the intensity of the reflection of a laser beam for each of the points. The next method uses the k nearest neighbor method to filter out points which were measurement error of surface reflection.

The author conducted a series of tests and experiments to assess the practical possibilities of using the Trimble FX scanner diagnostics. Proposed method also does raise resolution based on a series of measurements.

The next chapter presents the process of data segmentation and its advisability in the case of data obtained from scanners. Presented existing methods used for scanning data and examples of their use in the developed system. The work was carried out modifying the Hough Transform so that it can be used for the purpose of scanning data segmentation.

The proposed method utilizes the specific nature of the laser scanner, which generates data in the form of independent measuring lines. Each line is converted to the 2D system, by setting one of the coordinates to zero. Then the algorithm is searching for a group of points lying close to each other and on this base the primary segment is created. The next step is to identify the elements within the segment. This method allows to search for segments and arcs through the implemented method Hough transform. Following a similar analysis of all line by grouping elements from the first line. This results in the groups of one type segments such as segments or arcs lying in adjacent lines. This dissertation contains detailed descriptions of the various stages of processing with examples as graphic presenting the results of the different stages Iso presented the results of the various stages of processing to the real scene data.

As a result of the proposed method obtained dozens of independent segments. The final stage of the work is summarized, contains authors findings and conclusions of the possibilities and limitations associated with the interpretation of scanning data. It also presents directions for further research in the development of a functional system developed and its potential new applications.