

POLITECHNIKA WARSZAWSKA

WYDZIAŁ MECHATRONIKI

Rozprawa doktorska

mgr inż. Kamil Szelaąg

Metoda wizyjnego wyznaczania trajektorii znanego obiektu
z wykorzystaniem stałych elementów sceny

Promotor

prof. dr hab. inż. Robert Sitnik

Promotor pomocniczy

dr inż. Marcin Witkowski

Warszawa 2021

*Chciałbym serdecznie podziękować
promotorowi, prof. dr hab. inż. Robertowi Sitnikowi,
za merytoryczne wsparcie, radę
i pomoc w trakcie realizacji niniejszej pracy.*

*Równie serdecznie dziękuję mojej żonie Monice,
za wyrozumiałość, wiarę i motywację do pracy. Dziękuję, że jesteś.*

STRESZCZENIE

Od wielu lat obserwuje się niegasnący wzrost zainteresowania technikami wykorzystującymi obrazowanie z wykorzystaniem detektorów wizyjnych. Zarówno w dziedzinach analizy dwuwymiarowej, jak i trójwymiarowej, wzrost możliwości obliczeniowych i powszechny dostęp do detektorów sprawiają, że techniki te wkraczają w kolejne dziedziny codziennego życia. Jedną z nich jest, omawiane w niniejszej pracy, zagadnienie wizyjnej lokalizacji i śledzenia obiektów. Celem pracy była analiza i rozwiązanie problemu śledzenia obiektu w przestrzeni 3D w zmiennej scenie. W wyniku analizy opracowany został uogólniony model problemu śledzenia, w ramach którego powstały autorskie algorytmy i modyfikacje takich problemów jak: kalibracja wewnętrzna detektora wizyjnego w przypadku niedoboru danych kalibracyjnych, metoda kalibracji i re-kalibracji zewnętrznej, metoda detekcji i interpretacji stałych elementów sceny wraz z algorytmem wykrywania ruchu detektora oraz metoda kompensacji błędów śledzenia związanych ze zniekształceniami perspektywicznymi. Na początku pracy przedstawiono podstawy teoretyczne matematycznego modelowania zależności geometrycznych w scenie, w tym modele odwzorowania i obrazowania pojedynczego detektora wizyjnego oraz metody opisu transformacji geometrycznych w układach wielokamerowych. Następnie opisane zostały techniki kalibracji wewnętrznej ze szczególnym uwzględnieniem technik użytych i modyfikowanych w ramach niniejszej pracy. Po nich opisane zostały techniki wyznaczania pozycji i orientacji detektora w scenie – począwszy od sposobów detekcji i interpretacji danych kalibracyjnych (analiza obrazu 2D i wiedzy a priori), a skończywszy na metodach wyznaczania pozycji względnej i bezwzględnej. Przegląd literatury kończy analiza błędów śledzenia związanych ze zniekształceniem perspektywnym obiektów sferycznych – błędem ekscentryczności. Opisany jest mechanizm powstawania błędu oraz metody obecnie używane w celu jego eliminacji. Część koncepcyjną pracy otwiera krótkie wprowadzenie i opis warunków użytkowych, w których wykorzystywane były elementy nowości pracy. Następnie zamieszczono krótki opis dwóch aplikacji – systemu wspomagającego decyzje sędziowskie i niskokosztowego skanera światła strukturalnego w ujęciu wyzwań i ograniczeń implementacyjnych. W tak zdefiniowanych warunkach w dalszej części pracy wprowadzony zostaje opracowany w ramach pracy modułowy schemat koncepcyjny systemu śledzenia oraz wymagania i warunki pracy każdego z modułów (cel, dane wejściowe, dane wyjściowe i realizacja we wdrożonych aplikacjach). Wśród opisywanych modułów wskazane i szczegółowo opisane zostają te, których rozwój jest przedmiotem niniejszej pracy. Kolejną

część pracy stanowi rozdział poświęcony implementacji – wdrożeniom dwóch opisywanych w poprzedniej części systemów. Omówiony został skaner światła strukturalnego, w którym dla dwóch położenia wzorca kalibracyjnego osiągnięto dokładność pomiaru na poziomie 0,4 mm co stanowi 0,13% długości przekątnej objętości pomiarowej. Po nim, opisany zostaje system wspomagający decyzje sędziowskie, w którym pozycja detektora wyznaczana jest z dokładnością około 1 mm. W systemie tym pokazano, że możliwe jest wykrywanie położenia śledzonego obiektu z niepewnością mniejszą niż 10 mm, co jak sprawdzono eksperymentalnie jest dokładnością wyznaczającą do podjęcia automatycznej decyzji sędziowskiej. Praca zakończona jest podsumowaniem przeprowadzonych prac, spełnienia celów badawczych i udowodnieniem tezy wraz z wyznaczeniem kierunku dalszych prac.

Słowa kluczowe: śledzenie 3D, przetwarzanie obrazu, kalibracja kamery, pozycjonowanie kamery

ABSTRACT

It can be observed that interest in image processing based techniques has been growing recently. As a result of computational capability development and visual sensor availability, 2D and 3D analysis has been becoming present in everyday activities. An example of these techniques is the visual tracking of an object in 3D space, described in this dissertation. The aim of the research was to analyze and solve a problem of three-dimensional tracking of an object located in dynamic scene. As a result, a generic modular model of a problem was proposed, and new solutions as well as improvement for existing algorithms were designed. Among developed methods, following ones can be listed: intrinsic camera calibration in scene with low amount of calibration data, extrinsic camera calibration (pose estimation) and online recalibration, extraction and data interpretation of known scene elements (from 2D images) including camera movement detection algorithm and method for correction of perspective mapping based distortions (eccentricity error). In the beginning of the dissertation theoretical basis for mathematical model of scene geometry was presented, which includes: single camera perspective projection and imaging model as well as methods of multi camera relative transformation description in complex hierarchies. Next, intrinsic calibration were presented and methods used during research at hand were described in detail. In following sections, camera pose estimation related techniques were described – beginning with keypoints and other calibration data detection and interpretation, and finishing with absolute and relative pose estimation algorithms. At the end of the literature review, eccentricity error in spherical and circular object projection and existing methods of its compensation were presented. Then, at the beginning of a conceptual part of this dissertation, brief discussion of practical features and limitations in 3D tracking applications was conducted. After discussion, generic modular model of 3D tracking system with modules' description and requirements were introduced. For each module, inputs, outputs, purpose and implementations were defined. Among described modules, ones which are connected with algorithms developed during presented research are described in detail. Fourth chapter is devoted to implementation and applications. Two systems implemented during research were described: low cost structural light scanner calibrated with only two calibration artifact positions in which 0,4 mm measurement accuracy were achieved (which is a 0,13% of a measurement volume) and referee support system, in which the accuracy of camera position is 1mm and object was tracked with 10 mm maximal error. In referee support system there were also experiment presented, which proved system utility and requirements

fulfilment. At the end of a dissertation summary, a discussion on scientific and utility goals was performed and future work direction are proposed.

Keywords: 3D tracking, camera calibration, image processing, pose estimation

SPIS TREŚCI

1	Wstęp	17
1.1	Motywacja	17
1.2	Opis problemu badawczego.....	19
1.3	Cele badawcze	20
1.4	Organizacja dokumentu.....	21
2	Przegląd literatury.....	23
2.1	Matematyczny model sceny	23
2.1.1	Wprowadzenie	23
2.1.2	Układy jednokamerowe.....	23
2.1.2.1	Model kamery otworkowej (pinhole camera).....	23
2.1.2.2	Inne podejścia do modelowania odwzorowania detektorów wizyjnych.....	26
2.1.3	Układy wielokamerowe.....	27
2.1.3.1	Transformacje	27
2.1.3.2	Hierarchia układów współrzędnych.....	31
2.2	Kalibracja wewnętrzna.....	34
2.2.1	Wprowadzenie	34
2.2.2	Techniki optymalizacji nieliniowej.....	35
2.2.3	Techniki wyznaczające macierz wypadkową.....	35
2.2.4	Techniki interpolacyjne n-płaszczyznowe.....	36
2.2.5	Techniki kalibracji wewnętrznej – porównanie.....	37
2.2.6	Hybrydowe techniki kalibracji.....	37
2.2.7	Opis wybranych metod użytych w pracy	38
2.2.7.1	Direct Linear Transformation (DLT)	38
2.2.7.2	Hybrydowa kalibracja Zhanga.....	40
2.3	Kalibracja zewnętrzna	45
2.3.1	Wprowadzenie	45

2.3.2	Wyznaczanie transformacji bezwzględnej	46
2.3.2.1	Detekcja i interpretacja informacji w obrazie.....	46
2.3.2.2	Rozwiązanie zredukowanego problemu.....	50
2.3.3	Wyznaczanej transformacji względnej – estymacja ruchu kamery	55
2.3.3.1	Detekcja i interpretacja informacji w obrazie.....	55
2.3.3.2	Rozwiązanie zredukowanego problemu.....	56
2.3.4	Opis wybranych metod użytych w pracy	58
2.3.4.1	Detekcja i interpretacja informacji w obrazie.....	58
2.3.4.2	Rozwiązywanie relacji punkt-punkt.....	62
2.4	Korekcja wyznaczania środka znaczników sferycznych i kołowych	66
2.4.1	Wprowadzenie	66
2.4.2	Błąd ekscentryczności	66
2.4.3	Kompensacja błędu ekscentryczności	68
2.4.3.1	Metody oparte o znajomość płaszczyzny obiektu.....	69
2.4.3.2	Metody wykorzystujące przestrzeń Hougha.....	70
2.4.3.3	Metody wykorzystujące predefiniowany obiekt.....	71
2.4.3.4	Metody wykorzystujące równania parametryczne.....	72
2.4.3.5	Metody kompensujące błąd ekscentryczności – porównanie	73
3	Koncepcja.....	74
3.1	Wprowadzenie	74
3.1.1	Niskokosztowy skaner światła strukturalnego.....	74
3.1.2	System wspomagający decyzje sędziowskie	75
3.2	Schemat koncepcyjny systemu	76
3.2.1	Elementy systemu i wymagania.....	80
3.2.1.1	Moduł akwizycji	80
3.2.1.2	Moduł analizy wiedzy o scenie.....	80
3.2.1.3	Moduł analizy 2D sceny.....	81

3.2.1.4	Moduł kalibracji wewnętrznej	82
3.2.1.5	Moduł kalibracji zewnętrznej i re-kalibracji.....	83
3.2.1.6	Moduł zarządzania transformacjami	85
3.2.1.7	Moduł śledzenia obiektu 2D	86
3.2.1.8	Moduł korekcji zniekształceń obiektu.....	87
3.2.1.9	Moduł analizy trajektorii 2D obiektu	88
3.2.1.10	Moduł wyznaczający równanie promienia/promieni w GCS.....	88
3.2.1.11	Moduł integrujący dane z wielu detektorów	89
3.3	Opracowane algorytmy i modyfikacje	91
3.3.1	Moduł analizy sceny 2d.....	91
3.3.1.1	Detekcja i interpretacja informacji.....	91
3.3.2	Moduł kalibracji wewnętrznej	97
3.3.2.1	Wymagania użytkowe jako ograniczenia dla procedury kalibracji.	98
3.3.2.2	Uproszczenia modelu wynikające ze struktury systemu – dyskusja.....	98
3.3.3	Moduł automatycznej re-kalibracji	100
3.3.3.1	Opis algorytmu.....	101
3.3.4	Uogólniony moduł zarządzania transformacjami	104
3.3.4.1	Opis modułu.....	105
3.3.5	Moduł korekcji ekscentryczności.....	106
3.3.5.1	Wprowadzenie	106
3.3.5.2	Metoda wykorzystująca płaszczyznę normalną do osi stożka.....	106
3.3.5.3	Metoda wykorzystująca dopasowanie równania okręgu.....	107
3.3.5.4	Walidacja.....	108
4	Zastosowania praktyczne	117
4.1	Wprowadzenie	117
4.2	Niskokosztowy skaner światła strukturalnego.....	117
4.2.1	Wzorzec kalibracyjny	117

4.2.2	Układ detektorów	118
4.2.3	Pozycje wzorca kalibracyjnego.....	119
4.2.4	Ewaluacja działania systemu	119
4.2.4.1	Pomiary płaszczyzny referencyjnej.....	120
4.2.4.2	Pomiary sfer referencyjnych.....	122
4.2.4.3	Pomiar złożonego obiektu geometrycznego	125
4.2.4.4	Pomiary geometryczno-barwne prostych obiektów.....	126
4.2.5	Porównanie z innymi dostępnymi metodami	127
4.3	System wspomagający decyzje sędziowskie	128
4.3.1	Wprowadzenie	128
4.3.2	Układ współrzędnych i punkty kluczowe.....	129
4.3.3	Układ kamer.....	129
4.3.4	Synchronizacja akwizycji.....	131
4.3.5	Przetwarzanie danych – realizacja sprzętowa.....	132
4.3.6	Środowisko symulacyjne.....	133
4.3.6.1	Badanie kalibracji wewnętrznej	133
4.3.6.2	Badanie kalibracji zewnętrznej	134
4.3.7	Ewaluacja poprawności działania systemu.....	136
4.3.7.1	Wykrywanie punktów charakterystycznych.....	137
4.3.7.2	Kalibracja zewnętrzna	138
4.3.7.3	Rekonstrukcja współrzędnych 3D	141
4.3.7.4	Symulacja rzeczywistej sytuacji meczowej.....	144
5	Podsumowanie.....	147
5.1	Wypełnienie celów badawczych.....	147
5.1.1	Opracowanie metody kalibracji i re-kalibracji pozycji i orientacji kamery	147
5.1.2	Opracowanie metody analitycznej kompensacji błędów projekcji perspektywicznej związanych z charakterem wybranych modeli kamer	147

5.1.3	Opracowanie modyfikacji algorytmu kalibracji wewnętrznej w sytuacji niedoboru danych kalibracyjnych.	148
5.2	Realizacja celów użytkowych.....	148
5.2.1	Opracowanie uogólnionego modelu wizyjnego systemu śledzenia obiektu w przestrzeni trójwymiarowej.....	148
5.2.2	Projekt i implementacja nisko-kosztowego skanera światła strukturalnego	149
5.2.3	Projekt i implementacja systemu wspomagającego podejmowanie decyzji sędziowskich w piłce siatkowej.....	149
5.3	Udowodnienie postawionej tezy pracy	149
5.4	Kierunki dalszych prac.....	150
6	Bibliografia.....	151

Słownik pojęć

Nazwa	Skrót	Opis
Punkt nodalny	NP	Środek rzutów, przez który przechodzi wiązka prostych reprezentujących promienie przechodzące przez piksele matrycy detektora.
Wirtualna rzutnia	VPP	Płaszczyzna równoległa do płaszczyzny opisującej płaszczyznę matrycy detektora symetryczna do niej względem NP .
Przestrzeń obrazu	IS	Przestrzeń 2D, w której opisywana jest wynikowa projekcja dla detektorów matrycowych.
Środek projekcji	CP	Punkt w IS odpowiadający prostej będącej osią optyczną obiektywu detektora.
Macierz parametrów wewnętrznych	CM	Macierz, której elementy opisują przekształcenie współrzędnych punktu opisanego w VPP we współrzędne jego obrazu w IS .
Stereopara	SP	Konfiguracja dwukamerowego systemu, w którym układ współrzędnych jednej z kamer jest jednocześnie układem odniesienia.
Globalny układ współrzędnych	GCS	Układ odniesienia. Wszystkie położenia i orientacje układów współrzędnych lokalnych są zdefiniowane poprzez transformację między układem lokalnym a GCS .
Procedura kalibracji	-	Procedura prowadząca do wyznaczenia nieznanymi parametrów w równaniach transformacji modelu matematycznego.
Parametry kalibracji	-	Zbiór parametrów wyznaczany w procedurze kalibracji.
Parametry kalibracji wewnętrznej	-	Cechy fizyczne detektora wizyjnego takich jak np. ogniskowa, współczynniki dystorsji.
Parametry kalibracji zewnętrznej	-	Parametry opisujące za położenie i orientację detektora w scenie.
Punkty charakterystyczne	KP	Przestrzenne miejsca w scenie zdefiniowane za pomocą współrzędnych punktów w GCS odpowiadające wyróżnionym fragmentom analizowanej sceny.

		Algorytmy detekcji bardzo często mają za cel znalezienie w IS projekcji zdefiniowanych wcześniej punktów charakterystycznych.
Linie charakterystyczne	KL	Przestrzenne miejsca w scenie zdefiniowane za pomocą równań prostych w GCS odpowiadające wyróżnionym fragmentom analizowanej sceny. Algorytmy detekcji bardzo często mają za cel wyznaczenie równań w IS projekcji tak zdefiniowanych prostych.
Obszar zainteresowania	ROI	Prostokątny wycinek obrazu opisywany za pomocą dwóch przedziałów (u_{min}, u_{max}) oraz (v_{min}, v_{max})
Niskokosztowy skaner światła strukturalnego	LCS	Jedna z aplikacji powstałych w ramach niniejszej pracy. Układ składający się z kamery światła widzialnego i projektora, którego zadaniem był pomiar kształtu i barwy obiektów trójwymiarowych umieszczonych wewnątrz zdefiniowanej objętości pomiarowej.
System wspomagający decyzje sędziowskie	VBS	Jedna z aplikacji powstałych w ramach niniejszej pracy. System realizował zadanie śledzenia znanego obiektu (piłki siatkowej) w przestrzeni trójwymiarowej.
Interfejs programistyczny aplikacji	API	Pozwala na komunikowanie się aplikacji między sobą. Zdefiniowany jest na poziomie kodu źródłowego. Zadaniem API jest dostarczenie odpowiednich specyfikacji podprogramów, struktur danych, klas obiektów i wymaganych protokołów komunikacyjnych [1].
Silnik renderingowy	-	Oprogramowanie służące do symulacji sygnału detektora wizyjnego. Na podstawie wiedzy o geometrii, materiałach i oświetleniu w scenie generuje on syntetyczne widoki (obrazy) rejestrowane przez wirtualny detektor.

1 Wstęp

1.1 Motywacja

Od wielu lat obserwuje się niegasnący wzrost zainteresowania technikami obrazowania z wykorzystaniem detektorów wizyjnych. Zarówno w dziedzinach analizy dwuwymiarowej jak i trójwymiarowej, wzrost możliwości obliczeniowych i powszechny dostęp do detektorów sprawia, że techniki te wkraczają w kolejne dziedziny codziennego życia. Jedną z nich jest, omawiane w niniejszej pracy, zagadnienie wizyjnej lokalizacji i śledzenia obiektów.

Poprzez wizyjne śledzenie rozumieć należy **precyzyjne** (z założoną dokładnością), **stałe w czasie** (z założoną częstotliwością) i **niezawodne** (odporne na zmiany środowiska i zmiany w scenie) wyznaczanie przestrzennego położenia obiektu na podstawie obrazu pochodzącego z detektora lub wielu detektorów wizyjnych, a w szczególności relacji geometrycznych pomiędzy obiektem a detektorem. Znajomość tych relacji pozwoliła w ostatnich latach na przykład na kontrolę ruchu mitochondriów [2], planowanie procesu rehabilitacji [3], czy obserwację ruchu dzikich zwierząt [4].

Samo śledzenie obiektów w przestrzeni nie jest zagadnieniem nowym. Od dawna znane i wykorzystywane są algorytmy śledzenia począwszy od metod obrazowych w układach jednokamerowych [5], a skończywszy na technikach stosowanych w systemach wielokamerowych [6]. I tak na przykład śledzenie 2D realizowane jest na przykład w pracy [7], gdzie położenie znaczników LED jest wykorzystywane do wyznaczania pozycji robota mobilnego lub w pracy [8], gdzie znaczniki zamontowane na głowie użytkownika są wykorzystywane do określania jego pola widzenia w zastosowaniach rzeczywistości rozszerzonej. W przypadku śledzenia 3D najczęściej stosowane są systemy stereowizyjne [9], chociaż w związku z malejącymi kosztami kamer, udział systemów o większej liczbie kamer rośnie [10], jak na przykład w pracy [11], w której wynik śledzenia wielokamerowego wykorzystywany jest przez algorytm sterujący samochodem autonomicznym.

Duży udział systemów wielokamerowych jest dobrze widoczny w aplikacjach związanych ze sportem i monitorowaniem przebiegu rozgrywki. W ostatnich latach obserwuje się dążenie środowisk sportowych do obiektywizacji procesu sędziowania, w którym duże objętości pomiarowe często wymuszają użycie więcej niż dwóch kamer. I tak, na przykład można zaobserwować aplikacje realizujące systemy śledzące [12] lub, dla sportów piłkowych przez systemy śledzące piłkę, których przegląd został pokazany w pracy [13].

Jak zostało zauważone w pracy [14], systemy te pracują w zmiennych warunkach oświetleniowych, śledzone obiekty są często przysyłane, a pole pomiarowe jest duże w odniesieniu do wymaganych dokładności. Mimo tego od systemów wizyjnych używanych w sporcie oczekuje się milimetrowych dokładności w śledzeniu oraz analiz w wysokim poziomie abstrakcji i szybkości działania, która nie wpływa na dynamikę samej rozgrywki. Wymienione powyżej cechy systemów sprawiają, że wdrożenie ich często wymaga usprawnienia stosowanych algorytmów lub dostosowania przyjętych sposobów implementacji. Z tego powodu stanowią one interesujące wyzwanie badawcze, szczególnie w przypadku systemów, które pracują w zmiennym, dynamicznym otoczeniu. Są to zastosowania, w których konieczna jest aktualizacja parametrów opisujących układ pomiarowy na skutek działania niezależnych czynników zewnętrznych.

Mimo rosnącej liczby publikacji dotyczących metod kompensacji wyżej wymienionych zmian [15], niewiele miejsca poświęcone jest dostosowaniu samego modelu matematycznego i jego definicji (najczęściej geometrycznej) tak, aby można było w nim stosować opisywane algorytmy. Ponadto, metody prezentowane w tych publikacjach często wymagają dodatkowych informacji, które uzyskuje się na przykład poprzez jej wstępny skan 3D sceny lub dodawanie znaczników kalibracyjnych. Wiele metod bazuje na charakterystycznym kształcie obiektu i więzach, które tworzy [16] wykorzystuje informacje o budowie szkieletu człowieka). Wad tych pozbawione są modele neuronowe, używające sieci LSTM [17], które jednak wymagają dużego zbioru danych uczących przez co nie mogą być stosowane w nietypowych przypadkach, dla których nie ma baz danych uczących. Wskazane cechy powodują, że wśród systemów śledzących istnieją takie, w których stosowanie algorytmów LSTM lub optymalizacyjnych jest utrudnione a często niemożliwe. Jednym z takich zastosowań jest wspieranie pracy sędziego sportów drużynowych. Mimo dobrze zdefiniowanej sceny (boisko), możliwa jest sytuacja, w której w krótkich odstępach czasu jej stałe elementy (przecięcia linii, słupki, banery reklamowe) na podstawie których wykonywana jest aktualizacja parametrów modelu, są niewidoczne (na przykład przesłonięte przez zawodnika). Co więcej, boiska często są dostosowywane przed samym meczem (w przypadku siatkówki na przykład korygowane jest położenie maty będącej polem gry). To może w pewnych sytuacjach utrudnić lub wręcz uniemożliwić wykorzystywanie danych pochodzących ze wstępnych skanów 3D. Dodatkowym utrudnieniem, w przypadku przytoczonych zastosowań, jest możliwa konieczność wykonywania szybkiej re-kalibracji w czasie działania systemu po przesunięciu detektora (na przykład uderzonego piłką lub potraconego przez zawodnika). Ten wymóg może ograniczać

zastosowanie modeli neuronowych, które przy obecnych możliwościach obliczeniowych i wymaganej częstotliwości aktualizacji kalibracji (nawet 200 Hz), nie byłyby dość szybkie [18].

Problemy związane z projektowaniem i kalibracją systemów w wyżej wymienionych zastosowaniach są rozważane w niniejszej pracy, w ramach której wykonano badania prowadzące do powstania rozwiązania problemu śledzenia położenia 3D obiektu w zmiennej scenie z wykorzystaniem jej stałych elementów. Implementacja wyników badań jest elementem rozwiązania, które wspomaga proces podejmowania decyzji sędziowskich w trakcie trwania meczu. Metody powstałe w ramach pracy adresują potrzebę obiektywności i wykorzystują możliwości współczesnych detektorów wizyjnych w sposób, który uatrakcyjni rozgrywkę dla widzów, a sędziom da narzędzie ułatwiające stojące przed nimi zadanie. W związku z niewielką liczbą stałych elementów boiska, niniejsza praca jest także odpowiedzią na potrzebę realizacji złożonych zadań śledzenia w scenach dynamicznych, o których nie ma wielu informacji.

W opinii autora, potencjał wykorzystania metod zaprezentowanych w pracy, ze względu na prostotę implementacji, duże zdolności do adaptacji nowych algorytmów kompensacji i niskie wymagania sprzętowe, jest bardzo duży. Dowodem mogą być prezentowane w pracy, wdrożone systemy komercyjne oraz moduły oprogramowania, które korzystają z opracowanych metod.

1.2 Opis problemu badawczego

Niniejsza praca obejmuje analizę problemu śledzenia znanego obiektu w przestrzeni trójwymiarowej z zastosowaniem matrycowych detektorów wizyjnych. Jednym z wariantów zadania śledzenia, jest ten, w którym obiekt jest umiejscowiony w scenie, o której posiadamy informacje *a priori*. Może to być wiedza o śledzonym obiekcie, o geometrii i/lub barwie sceny czy też o stałych elementach tejże. Metoda proponowana w pracy dotyczy sytuacji, w której stałe elementy sceny wnoszą wystarczająco dużo informacji, aby wyznaczyć położenie kamer i dzięki temu zlokalizować i śledzić położenie obiektu w sposób wymagany w danej aplikacji. W procesie śledzenia można wyróżnić kilka głównych etapów:

- wyznaczanie parametrów wewnętrznych kamer w trakcie procesu nazywanego kalibracją kamery. W trakcie tego procesu parametry wyznaczone są na podstawie zależności pomiędzy znanym geometrycznie wzorcem i jego obrazem na matrycy detektora,
- detekcja i interpretacja informacji o scenie zawartych w jej obrazie rejestrowanym przez detektor. Informacją tą mogą być na przykład punkty lub linie charakterystyczne, znane

obiekty, znaczniki kalibracyjne lub inne elementy sceny, które dostarczają informacji o relacjach geometrycznych pomiędzy detektorem a obiektami w scenie,

- wyznaczanie parametrów zewnętrznych detektora (jego położenie i orientacja w przyjętym układzie współrzędnych). W trakcie tego procesu parametry wyznaczone są na podstawie zależności pomiędzy wiedzą a priori o scenie a wykrytą i zinterpretowaną informacją zawartą na obrazie,
- detekcja śledzonego obiektu na obrazach z kamer. Wykrywany może być punkt - środek masy - ale też otoczka, prostokąt okalający itp.,
- wyznaczanie parametrów modelu opisującego ruch obiektu dla przypadku, gdy obiekt lub kamera są ruchome,
- rekonstrukcja pozycji 3D obiektu (jego otoczki, środka masy, punktów kluczowych) w czasie na podstawie wykrytych pozycji 2D i parametrów detektora (wewnętrznych i zewnętrznych).

Na każdym z etapów można wyróżnić wielkości wejściowe i wyjściowe, które opisują pośrednie stany śledzenia, ale także pewne parametry sterujące, które wpływają na sposób działania algorytmów wykorzystywanych w poszczególnych etapach. Dobór parametrów sterujących, algorytmów i wielkości opisujących proces śledzenia wpływa na dokładność i niezawodność śledzenia, na złożoność obliczeniową, odporność, łatwość wdrożenia i koszt docelowego systemu.

Analiza procesu śledzenia jako całości jest przedmiotem niniejszej pracy. Ponadto w ramach pracy rozważane są algorytmy dotyczące kalibracji wewnętrznej kamer, detekcji i interpretacji informacji o scenie, re-kalibracji zewnętrznej i korekcji błędów wynikających ze sposobu obrazowania detektorów (Rozdział 3). W warstwie aplikacyjnej praca skupia się na dwóch implementacjach – systemu wspomagającego sportowe decyzje sędziowskie oraz nisko-kosztowego skanera światła strukturalnego (Rozdział 4).

1.3 Cele badawcze

Jak wspomniano wcześniej, celem pracy jest rozwiązanie problemu śledzenia obiektu w przestrzeni 3D w zmiennej scenie. Cel ten jest ściśle związany z opracowaniem rozwiązania będącego częścią aplikacji wspierającej decyzje sędziowskie, a w szczególności metod używanych w kalibracji geometrycznej systemu i metod kompensacji błędów detekcji podczas wyznaczania pozycji 3D obiektu. Opracowane metody mają umożliwić przeprowadzenie re-kalibracji geometrycznej w czasie rzeczywistym po wykryciu zmian w parametrach sceny np.

przesunięciu jednej z kamer przy zachowaniu funkcjonalności systemu. Funkcjonalność ta jest rozumiana jako zdolność do detekcji i śledzenia obiektu z zadaną dokładnością i możliwość wykonywania wysokopoziomowych analiz ocenianych przez sędziów jako poprawne.

Tezą pracy jest stwierdzenie, że możliwe jest opracowanie metody służącej pozycjonowaniu kamery w znanym środowisku w czasie rzeczywistym z dokładnością wyrażoną przez średni błąd wyznaczenia pozycji kamery mniejszy niż 0,01% wymiaru przekątnej objętości pomiarowej. Tak wyznaczone pozycje kamery pozwalają na śledzenie środka geometrycznego piłki w przestrzeni z dokładnością wyrażoną przez niepewność wyznaczania pozycji piłki mniejszą niż 0,1% wymiaru przekątnej objętości pomiarowej, co umożliwia wspieranie decyzji sędziowskich.

Aby osiągnąć postawiony cel w pracy wyróżniono następujące pomocnicze cele naukowe i użytkowe:

Cele naukowe:

- opracowanie metody kalibracji i re-kalibracji pozycji i orientacji kamery,
- opracowanie metody analitycznej kompensacji błędów projekcji perspektywicznej związanych z charakterem wybranych modeli kamer,
- opracowanie modyfikacji algorytmu kalibracji wewnętrznej w sytuacji niedoboru danych kalibracyjnych.

Cele użytkowe:

- opracowanie uogólnionego modelu wizyjnego systemu śledzenia obiektu w trójwymiarowej przestrzeni,
- projekt i implementacja niskokosztowego skanera światła strukturalnego,
- projekt i implementacja systemu wspomagającego podejmowanie decyzji sędziowskich w piłce siatkowej.

1.4 Organizacja dokumentu

Niniejsza praca została podzielona na pięć rozdziałów. Rozdział pierwszy stanowi wstęp, który opisuje okoliczności, pokazuje motywacje i formułuje cele rozprawy. Rozdział drugi zawiera przegląd literatury wraz ze szczegółowym opisem wybranych metod i algorytmów. Rozdział trzeci poświęcony jest koncepcji systemu śledzenia, który został opracowany w ramach pracy. Opisuje rozważane zagadnienia, formułuje wymagania stawiane systemowi jako całości oraz

poszczególnym jego składowym. Na podstawie wymagań sformułowane są następnie opracowane w ramach pracy autorskie algorytmy i modyfikacje. Rozdział czwarty poświęcony jest implementacji opracowanych metod. Pokazuje dwa systemy opisywane w ramach pracy: nisko-kosztowy skaner światła strukturalnego oraz system wspomagający podejmowanie decyzji sędziowskich. Ponadto odwołując się do publikacji, które dotyczą tych systemów, przytacza ewaluację ich działania oraz przykładowe wyniki. Ostatni rozdział jest podsumowaniem, w którym opisywana jest realizacja celów badawczych naukowych i użytkowych oraz pokazywane są kierunki możliwych dalszych prac.

2 Przegląd literatury

2.1 Matematyczny model sceny


2.1.1 Wprowadzenie

Pierwszym krokiem adekwatnego opisu badanego zjawiska fizycznego jest zdefiniowanie go w ramach spójnego modelu matematycznego. W przypadku problemu śledzenia obiektu w przestrzeni trójwymiarowej model powinien opisywać wzajemne położenie śledzonego obiektu, sceny w której się porusza, oraz detektora (detektorów) używanego się w celach pomiarowych. Ponadto, konieczne jest zdefiniowanie relacji łączącej współrzędne przestrzenne obiektu ze współrzędnymi jego projekcji w dziedzinie obrazu. W zależności od liczby detektorów opis można przeprowadzić za pomocą pojedynczego, lokalnego układu współrzędnych detektora (dla układów jedno-kamerowych) lub za pomocą wielu układów współrzędnych i transformacji między nimi (dla układów wielokamerowych).

2.1.2 Układy jednokamerowe

2.1.2.1 Model kamery otworkowej (pinhole camera)


Odwzorowanie obiektów w przestrzeni trójwymiarowej na dwuwymiarowej płaszczyźnie obrazu może być opisywane na wiele sposobów. Jednym z najprostszych jest model kamery otworkowej (pinhole camera), który odpowiada matematycznemu opisowi rzutu środkowego [19]. Zgodnie z założeniami modelu, detektor reprezentuje wiązkę prostych przechodzących przez jeden punkt, środek rzutów, który w pracy nazywany będzie punktem nodalnym **NP** (ang. **Nodal Point**) [20] (Rysunek 2.1).



Rysunek 2.1 Rzut środkowy. A, B, C, D – punkty rzeczywiste; A', B', C', D' – rzuty środkowe punktów na płaszczyznę π' (rzutnię); A'', B'', C'', D'' – rzuty na płaszczyznę π'' (wirtualną rzutnię). NP – punkt nodalny; NP', NP'' – rzuty prostopadłe punktu nodalnego na rzutnię i wirtualną rzutnię.

Płaszczyzna, na którą rzutowane są punkty, rzutnia π' , opisuje położenie matrycy detektora. Często stosowanym zabiegiem upraszczającym jest zdefiniowanie płaszczyzny π'' , która jest równoległa do płaszczyzny π' i symetryczna do niej względem **NP**. W pracy płaszczyzna π'' nazywana będzie wirtualną rzutnią **VPP** (ang. **virtual projection plane**). W opisanej powyżej konfiguracji możemy zdefiniować dwa układy współrzędnych (Rysunek 2.2).

- układ kamery (X,Y,Z) , którego początek znajduje się w **NP**, osie X i Y równoległe do rzutni a oś Z odpowiada kierunkowi osi optycznej kamery,
- układ wirtualnej rzutni **VPP** (x,y,z) , w którym osie są parami równoległe z osiami lokalnego układu współrzędnych kamery, a sam układ jest przesunięty translacją jednostkową wzdłuż osi Z ($\|(\mathbf{NP}-\mathbf{NP}'')\| = 1$).



Rysunek 2.2 Układy współrzędnych 3D w modelu otworkowym kamery. *NP* – punkt nodalny; *NP''* – rzut prostopadły punktu nodalnego na wirtualną rzutnię. *A* – rozważany punkt, *A''* – rzut *A* na wirtualną rzutnię.


Dla dowolnego punktu *A* o współrzędnych (a_x, a_y, a_z) wyrażonych w układzie współrzędnych kamery można zapisać równanie prostej, która przechodzi przez punkt *A* i **NP** (równanie 2.1.1)

$$\begin{cases} X = a_x \cdot t \\ Y = a_y \cdot t \\ Z = a_z \cdot t \end{cases}, t \in (-\infty, +\infty) \quad (\text{równanie 2.1.1})$$

W układzie wirtualnej rzutni, współrzędna *z* jest równa 1. Stąd możliwe jest wyznaczenie współrzędnych punktu przecięcia *A''* prostej z **VPP** (równanie 2.1.2).

$$\begin{cases} a''_x = \frac{a_x}{a_z} \\ a''_y = \frac{a_y}{a_z} \\ a''_z = 1 \end{cases} \quad (\text{równanie 2.1.2})$$

Aby opis odwzorowania kamery był pełny, należy zdefiniować pojęcie przestrzeni obrazu **IS** (ang. **image space**) (Rysunek 2.3), czyli przestrzeni, w której opisywana jest wynikowa projekcja 2D dla detektorów matrycowych.



Rysunek 2.3 Przestrzeń obrazu IS i układ współrzędnych obrazu (u, v) .

W przestrzeni tej zdefiniujemy układ (u, v) , którego współrzędne opisują położenie piksela w obrazie cyfrowym. W modelu kamery otworkowej, każdej z prostych rzutujących odpowiada pojedynczy punkt w **IS**. Punktem szczególnym jest środek projekcji **CP** (ang. **center of projection**), który odpowiada prostej będącej osią optyczną obiektywu detektora. Aby wyznaczyć współrzędne $(\tilde{a}_u, \tilde{a}_v)$ punktu \tilde{A} , który jest rzutem punktów leżących na prostej przechodzącej przez punkt A (Rysunek 2.2), można posłużyć się równaniem (równanie 2.1.3).

$$\begin{cases} \tilde{a}_u = f_x \cdot a''_x + CP_x \\ \tilde{a}_v = f_y \cdot a''_y + CP_y \end{cases} \quad (\text{równanie 2.1.3})$$

gdzie (CP_x, CP_y) są współrzędnymi **CP** a (f_x, f_y) są parametrami charakterystycznymi dla detektora (równanie 2.1.4).

$$\begin{cases} f_x = f \cdot \frac{i_w}{s_w} \\ f_y = f \cdot \frac{i_h}{s_h} \end{cases} \quad (\text{równanie 2.1.4})$$

w którym (i_w, i_h) są rozdzielczością obrazu (szerokością i wysokością w pikselach), (s_w, s_h) są rozmiarami sensora w milimetrach, a f jest ogniskową obiektywu w milimetrach. Równania 2.1.1-2.1.4 pozwalają na powiązanie współrzędnych punktu w układzie kamery ze współrzędnymi w **IS** (równanie 2.1.5) :

$$\left\{ \begin{array}{l} s \cdot \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & CP_x \\ 0 & f_y & CP_y \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = K \cdot \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} \\ K = \begin{bmatrix} f_x & 0 & CP_x \\ 0 & f_y & CP_y \\ 0 & 0 & 1 \end{bmatrix} \end{array} \right. \quad (\text{równanie 2.1.5})$$

W którym macierz K nazywana jest macierzą parametrów wewnętrznych **CM (ang. camera matrix)** kamery a s jest współczynnikiem skali.

2.1.2.2 Inne podejścia do modelowania odwzorowania detektorów wizyjnych

Opisany w poprzedniej sekcji model kamery otworkowej jest szczególnym przypadkiem modelu projekcji dwuetapowej [21]. W modelach tych odwzorowanie można podzielić na: etap projektowania przestrzeni 3D na jednostkową sferę i etap projekcji obrazu ze sfery na płaszczyznę obrazu za pomocą funkcji ξ . W większości aplikacji, a także w modelu otworkowym, funkcja ξ , jest funkcją radialnie symetryczną względem osi optycznej kamery. Odległość r projekcji \tilde{A} punktu A od CP jest zależna od ogniskowej obiektywu f i kąta pomiędzy osią optyczną, a promieniem przechodzącym przez piksel θ . I tak, można na przykład wyróżnić projekcję perspektywiczną, którą opisuje model otworkowy (równanie 2.1.6)

$$r \sim f \cdot tg(\theta) \quad (\text{równanie 2.1.6})$$

lub stosowane przy opisie obiektywów typu fish-eye projekcje azymutalna (równanie 2.1.7), proporcjonalna (równanie 2.1.8), czy typu sine law (równanie 2.1.9) [22]. W zależności od wartości ogniskowej f dla wyżej wymienionych projekcji uzyskuje się różne nachylenia krzywej do osi układu współrzędnych.

$$r \sim 2 \cdot f \cdot tg\left(\frac{\theta}{2}\right) \quad (\text{równanie 2.1.7})$$

$$r \sim f \cdot \theta \quad (\text{równanie 2.1.8})$$

$$r \sim f \cdot sin(\theta) \quad (\text{równanie 2.1.9})$$

Dwuetapowe modele projekcji z radialnie symetryczną funkcją ξ są uproszczonym sposobem przedstawiania odwzorowania przestrzeni przez detektory wizyjne, przez co nie zawsze pozwalają na wystarczająco dokładny opis zagadnienia. I tak na przykład w obiektywach szerokokątnych stosowanych w robotyce mobilnej i pojazdach autonomicznych lepsze działanie systemów wizyjnych osiągnąć można przez zastosowanie opisanego w pracy

[23] modelu dwusferowego. Innym przykładem odchodzenia od modeli symetrycznych, jest praca [24], w której odejście od modelu symetrycznego na rzecz modelu nieprzecinającej się wiązki promieni pozwoliło na poprawę dokładności kalibracji systemów pomiarowych z detektorami, do których montowano obiektywy o znaczących otworach.

Mimo zalet wyrafinowanych modeli, których przykłady podano powyżej, nie zawsze można ich użyć w praktycznych zastosowaniach. W problemach rozważanych w ramach tej pracy ilość danych kalibracyjnych, a także wpływ zakłóceń są poważnymi ograniczeniami wpływającymi na wybór modelu. Stąd prostota i duża odporność na lokalne zakłócenia sprawiły, że do opisu odwzorowania detektora został wybrany, opisany na początku tego rozdziału, model kamery otworkowej.

2.1.3 Układy wielokamerowe

2.1.3.1 Transformacje

W układach wielokamerowych poza analitycznym opisem projekcji każdej pojedynczej kamery, można zdefiniować zależności pomiędzy układami ich współrzędnych w przestrzeni 3D. To zadanie jest jednoznaczne ze zdefiniowaniem transformacji pomiędzy ich układami lokalnymi, którą można opisać transformacją prostą Ψ i odwrotną Ψ^{-1} pozwalającą na przechodzenie z jednego układu współrzędnych do drugiego. Transformacja taka powinna mieć następujące cechy:

- obliczenia transformacji i transformacji punktu powinny nieść ze sobą możliwie małe błędy numeryczne,
- transformacja, z uwagi na możliwość jej aktualizacji w trakcie działania systemu, powinna być możliwa do skalowania i interpolacji,
- transformacja, z uwagi na użycie algorytmów iteracyjnych w procesie kalibracji, powinna być łatwo parametryzowana w jednorodnej przestrzeni.

W czasie badań, wraz z definiowaniem nowych potrzeb wynikających z aplikacji (które zostały zestawione powyżej), stosowano trzy reprezentacje modelu transformacji ciała sztywnego. Były to:

- klasyczna reprezentacja macierzowa rotacja-translacja z parametryzacją Rodrigues, stosowana na przykład w pracy [25],
- reprezentacja kwaternion-translacja z pracy [26],
- reprezentacja za pomocą kwaternionów dualnych [27].

Wymienione powyżej reprezentacje zostały opisane szczegółowo w kolejnych sekcjach.

2.1.3.1.1 Reprezentacja rotacja-translacja

Przy niezmienności skali transformację pomiędzy układem (x_1, y_1, z_1) i (x_2, y_2, z_2) , można zapisać równaniem macierzowym (równanie 2.1.10) - (równanie 2.1.12):

$$\begin{bmatrix} x_2 \\ y_2 \\ z_2 \end{bmatrix} = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} + \begin{bmatrix} x_1 \\ y_1 \\ z_1 \\ 1 \end{bmatrix} = [R|T] \cdot \begin{bmatrix} x_1 \\ y_1 \\ z_1 \\ 1 \end{bmatrix} \quad (\text{równanie 2.1.10})$$

$$R = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \quad (\text{równanie 2.1.11})$$

$$T = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \quad (\text{równanie 2.1.12})$$


w którym macierz R jest ortonormalną macierzą rotacji, a macierz T jest macierzą translacji. Powyższy opis jest stosowany w implementacji **silników renderingowych** [28], procedur kalibracyjnych [29] i układów pomiarowych [30]. Niestety, z punktu widzenia projektowania rozwiązań działających na niekompletnych danych opisywana realizacja nie jest wolna od wad, szczególnie jeśli spojrzymy na macierz rotacji. Poniżej przedstawiono najważniejsze z nich w odniesieniu do opisywanych metod śledzenia obiektu 3D:

- wyznaczanie transformacji odwrotnej wymaga odwrócenia macierzy (transpozycji dla macierzy ortonormalnej) i mnożenia. Dla małych kątów rotacji mogą pojawić się duże błędy numeryczne,
- transformacji danej za pomocą równania macierzowego (równanie 2.1.10) nie można interpolować i skalować. Utrudnione jest konstruowanie Jakobianu (choć jak np. w [25] można to zrobić dla konkretnych przypadków). Stanowi to duże utrudnienie przy konstruowaniu algorytmów wykorzystujących optymalizację nieliniową.

Rozwiązaniem tego problemu jest zastosowanie interpolacji sferycznej **SLERP** [32] (równanie 2.1.16).

$$\text{Slerp}(q_0, q_1, t) = \frac{q_0 \cdot \sin((1-t)\theta) + q_1 \cdot \sin(t\theta)}{\sin\theta} \quad (\text{równanie 2.1.16})$$

W przypadku, gdy zastosujemy tę interpolację, problem niejednorodności prędkości kąta nie występuje, co ilustruje rysunek (Rysunek 2.5).



Rysunek 2.5 Obrót wektora $x = [1, 0, 0]$ dookoła osi $y = [0, 1, 0]$ i prędkość kątowa obrotu przy zastosowaniu interpolacji liniowej.

Podczas projektowania algorytmów wymagających kalibracji położenia kamer, dualizm kwaternion-translacja wydaje się wystarczający. Niestety, w związku z różnymi przestrzeniami, w których znajdują się te parametry, jednostkowe zmiany współrzędnych kwaternionu nie odzwierciedlają tych samych zmian w transformacji co jednostkowe zmiany współrzędnych wektora translacji. Utrudnia to formułowanie funkcji celu i często uniemożliwia sformułowanie zadania optymalizacji nieliniowej. Tych wad pozbawiona jest, opisana poniżej, reprezentacja kwaternion-kwaternion.

2.1.3.1.3 Reprezentacja kwaternion-kwaternion (kwaternion dualny)

W przypadku reprezentacji z użyciem kwaternionów dualnych, każda transformacja ciała sztywnego może być zapisana za pomocą jednego kwaternionu dualnego [27]. Kwaterniony dualne to kwaterniony, których współczynniki są liczbami dualnymi, których zastosowanie w geometrii jako jeden z pierwszych wprowadził Veldkamp [33] (równanie 2.1.17).

$$a = a_0 + \varepsilon \cdot a_\varepsilon \quad (\text{równanie 2.1.17})$$

$$\varepsilon^2 = 0$$

Grupując kwaterniony i ich części dualne, możemy zapisać kwaternion dualny za pomocą dwóch kwaternionów q_0 i q_ε (równanie 2.1.18).

$$a = q_0 + \varepsilon \cdot q_\varepsilon \quad (\text{równanie 2.1.18})$$

Przy tak zdefiniowanym kwaternionie dualnym można pokazać, że kwaternion q_0 jest kwaternionem rotacji, a translacja jest zależna od obu kwaternionów (równanie 2.1.19).


$$T = 2 \cdot q_\varepsilon \cdot q_0^* \quad (\text{równanie 2.1.19})$$

W którym q_0^* jest kwaternionem sprzężonym do q_0 . Takie przedstawienie rotacji i translacji pozwala na korzystanie z właściwości interpolacji kwaternionowej zarówno rotacji i translacji. Ponadto, taka reprezentacja staje się naturalną parametryzacją problemu optymalizacji nieliniowej, w której można różniczkować kwaterniony dualne w celu znalezienia macierzy Jacobiego.

2.1.3.2 Hierarchia układów współrzędnych


2.1.3.2.1 Stereopara

Najprostszą konfiguracją, w odniesieniu do systemów wielokamerowych, jest system dwukamerowy, w którym układ współrzędnych jednej z kamer jest równocześnie układem odniesienia (Rysunek 2.6). Taki układ nazywany jest często **stereoparą** [34] [35] [36].




Rysunek 2.6 Dwukamerowa hierarchia – stereopara. Po lewej schemat przestrzenny możliwego układu kamer, po prawej reprezentacja hierarchii w postaci grafu.

Aby móc kalibrować kamery niezależnie od siebie i aby konfiguracja mogła być rozszerzana, układ kamer można zdefiniować z użyciem globalnego układu współrzędnych **GCS** (**ang. Global Coordinate System**) (Rysunek 2.7). Transformacja lokalnego układu współrzędnych i -tej kamery, Ψ_i wyznaczają wtedy jej pozycję i orientację w **GCS**.



Rysunek 2.7 Dwukamerowa hierarchia – użycie GCS. Po lewej schemat przestrzenny możliwego układu kamer, po prawej reprezentacja hierarchii w postaci grafu.

Układy z rysunków (Rysunek 2.6), (Rysunek 2.7) są równoważne gdy Ψ_1 jest transformacją jednostkową, a $\Psi_2 = \Psi$. Hierarchię wykorzystującą **GCS**, równoważną z hierarchią stereopary wykorzystano na przykład w skanerze światła strukturalnego, który jest jedną z aplikacji powstałych w ramach tej pracy [37]. Dzięki temu, w razie potrzeby system mógł być rozszerzany o dodatkowe kamery. Hierarchie opisane powyżej obejmują wyłącznie przestrzeń 3D i układy współrzędnych kamer. Aby opis był kompletny, schematy należy uzupełnić o transformacje K_i wirtualnej rzutni i **IS** opisaną na początku tego rozdziału (Rysunek 2.8).




Rysunek 2.8 Dwukamerowa hierarchia – użycie GCS z zaznaczoną transformacją do przestrzeni obrazu IS. Po lewej schemat przestrzenny możliwego układu kamer, po prawej reprezentacja hierarchii w postaci grafu.

2.1.3.2.2 Hierarchie wieloukładowe


W ramach badań dotyczących tej pracy powstawały aplikacje, w których hierarchie używające **GCS**, były bardziej złożone. Poniżej przedstawiono dwa przykłady: aplikację wspomagającą trening ratowników medycznych i system wspomagający decyzje sędziowskie.

W aplikacji wspomagającej ewaluację efektywności wykonywania resuscytacji krążeniowo-oddechowej, globalny układ współrzędny związany został z kalibracyjnym wzorcem przestrzennym (Rysunek 2.9). Dodatkowo wyróżniono układy współrzędnych urządzeń (x_i, y_i, z_i) i fantomu treningowego (x_m, y_m, z_m) .



Rysunek 2.9 Hierarchia użyta w aplikacji wspomagającej ewaluację efektywności wykonywania resuscytacji krążeniowo-oddechowej. Po lewej schemat przestrzenny układu kamer, po prawej reprezentacja hierarchii w postaci grafu.

W aplikacji będącej przedmiotem tej pracy, a mianowicie w systemie wspomagającym decyzje sędziowskie układ globalny związany został z informacjami, które *a priori* wiemy o scenie. (Rysunek 2.10) Jego początek znajduje się w jednym z punktów charakterystycznych (keypoints), a osie są równoległe do kierunków wiodących sceny. Oś “Z” układu jest prostopadła do powierzchni boiska, a osie X,Y są równoległe do jego linii. Wszystkie kamery są powiązane z **GCS** niezależnymi transformacjami, które w razie potrzeby mogą być aktualizowane. Pozwala to na analizę zrekonstruowanych położzeń 3D śledzonego obiektu w jednym, niezmiennym układzie współrzędnych.



Rysunek 2.10 Hierarchia użyta w aplikacji wspomagającej decyzje sędziowskie w piłce siatkowej. Po lewej schemat przestrzenny układu kamer, po prawej reprezentacja hierarchii w postaci grafu.

2.2 Kalibracja wewnętrzna

2.2.1 Wprowadzenie

W poprzednim rozdziale pokazane zostały modele matematyczne, które opisują transformacje pomiędzy globalnym układem współrzędnych (**GCS**) a układem przestrzeni obrazu (**IS**). W odniesieniu do kalibracji kamery, parametry modeli można podzielić na dwie grupy:

- grupa parametrów wewnętrznych – należą do niej wielkości, które nie zależą od położenia detektora w scenie. W detektorze matrycowym, grupa ta opisuje właściwości układu optycznego detektora i jego wewnętrzne relacje geometryczne,
- grupa parametrów zewnętrznych – należą do niej wielkości, które nie zależą od użytego detektora. Opisują one położenie i orientację detektora w scenie.

Niezależnie od przyjętego modelu matematycznego obie grupy parametrów muszą zostać wyznaczone. Procedura prowadząca do wyznaczenia nieznanymi wielkościami w równaniach transformacji nazywana jest **procedurą kalibracji**, a zbiór parametrów bywa nazywany **parametrami kalibracji**. W systemach śledzenia, które funkcjonują w dynamicznych scenach, często potrzebne jest korygowanie kalibracji detektora w czasie działania systemu. Korygowane są jednak przede wszystkim wyznaczone wartości zmiennych w czasie parametrów zewnętrznych. Parametry wewnętrzne, w przeciwieństwie do wspomnianych powyżej parametrów zewnętrznych można w wielu przypadkach uznać za stałe w czasie działania systemu. Przykładami takiego podejścia jest na przykład praca [38], w której wyznaczana jest pozycja robota mobilnego względem podłoża po którym się porusza, lub praca [39], w której wyznaczanie kolejnych kalibracji zewnętrznych pozwala modelować ruch samochodu, na którym znajduje się kamera. W podobny sposób rozwiązano problem korekcji wartości parametrów w systemie śledzenia, który jest przedmiotem niniejszej pracy. Dzięki temu procedura kalibracji parametrów wewnętrznych mogła być wykonywana w kontrolowanych warunkach laboratoryjnych.

Wśród procedur kalibracji wewnętrznej, można wyróżnić kilka głównych grup. W zależności od wybranej grupy, można osiągnąć rezultaty uwzględniające inny zestaw czynników wpływających na wartości parametrów. Z drugiej strony inne są wymagania dotyczące wzorca kalibracyjnego, ilości potrzebnych danych czy złożoności obliczeniowej. W literaturze najczęściej spotkać można metody, która znajdują się w jednej z trzech grup: technik

optymalizacji nieliniowej, technik analitycznych wyznaczających macierz wypadkową i technik interpolacyjnych.

2.2.2 Techniki optymalizacji nieliniowej

W opisywanych metodach rozwiązywane jest globalne zadanie optymalizacji nieliniowej dla dowolnie zdefiniowanego zestawu parametrów modelu. Przykładem może być praca [40], która jako jedna z pierwszych rozwiązywała problem wyznaczania i korygowania złożonych dystorsji obiektywów, praca [41], w której sformułowano problem optymalizacji dla dyskretyzowanych zdjęć fotogrametrycznych, czy też praca [34], w której sformułowano problem optymalizacji dla układu wielu kamer. Jedną z technik omawianej grupy jest również druga, rozwinięta wersja techniki **DLT** (ang. **direct linear transformation**), opracowana w pracy [42], której elementy wykorzystywane są obecnie w wielu hybrydowych technikach kalibracji. Wśród późniejszych publikacji warto wspomnieć o pracy [43], w której parametry i składowe nieliniowe są formułowane w postaci równoważnego układu liniowego. Grupa opisywanych technik używana jest również w modelach, w których transformacje mają charakter lokalny, przez co utrudnione jest wyznaczenie globalnego analitycznego rozwiązania. Przykładem mogą być modele projekcji rozwijane w [24], gdzie w czasie kalibracji geometrycznej wyznaczone są parametry modelu opartego o wiązkę promieni. Wadą rozwiązań z tej grupy jest duża czułość na przyjęte wartości parametrów początkowych, które często muszą być wstępnie wyznaczone inną metodą. Z drugiej strony, metody te pozwalają na wyznaczenie parametrów kalibracji przy uwzględnieniu wielu czynników, których wpływ na odwzorowanie nie musi być dokładnie znany.

2.2.3 Techniki wyznaczające macierz wypadkową

W przypadku tych metod wyznacza się wypadkową macierz transformacji 3D-2D, która jest złożeniem transformacji Ψ (kalibracja zewnętrzna) z transformacją perspektywiczną (kalibracja wewnętrzna). W podejściu klasycznym, w którym transformacja Ψ jest zdefiniowana w reprezentacji rotacja-translacja (Rozdział 2.1.3), macierz wypadkowa jest wynikiem mnożenia macierzy K (równanie 2.1.5) i macierzy $[R|T]$ (równanie 2.1.10). Wyznaczenie macierzy wypadkowej uzyskuje się rozwiązując **nadokreślony układ równań liniowych** metodą najmniejszych kwadratów. W drugim kroku używając wiedzy a priori o

macierzach \mathbf{K} i $[\mathbf{R}|\mathbf{T}]$, wykonuje się dekompozycję macierzy wypadkowej, jak na przykład w pracy [44], gdzie dekompozycja wykorzystywana jest do odtwarzania pozycji rysika na w tablecie trójwymiarowym, czy w pracy [45], w której kalibrowane są kamery robotów mobilnych. W tej grupie znajduje się także pierwsza wspomniana powyżej metody DLT, opracowanej przez [42], w której pomija się parametry dystorsji. Inną, często stosowaną metodą dekompozycji jest faktoryzacja QR [46], która wykorzystuje fakt, że macierz kamery jest macierzą górno-trójkątną a macierz rotacji jest ortonormalna. Technika ta jest używana na przykład w metodzie kalibracji opartej o jądro macierzy zaproponowanej przez [47], czy w metodach **SFM** (ang. structure from motion) prezentowanych na przykład w pracy [48]. Dużą zaletą technik opisywanych w tej sekcji jest liniowość układów równań, które są rozwiązywane w trakcie procedury kalibracyjnej. Dzięki temu, są one najmniej złożone obliczeniowo i mają najniższe wymagania co do ilości danych kalibracyjnych spośród wszystkich prezentowanych w niniejszej pracy metod. Z drugiej strony rozwiązania nie uwzględniają wpływu aberracji, a nadznaczoność układów może skutkować spadkiem dokładności kalibracji, gdy kalibracja jest przeprowadzana na danych zaszumionych [49].

2.2.4 Techniki interpolacyjne n-płaszczyznowe

Techniki n-płaszczyznowe modelują przekształcenie perspektywiczne za pomocą funkcji interpolacji. Funkcja ta jest definiowana w różny sposób w zależności od liczby płaszczyzn i dostępności punktów kalibracyjnych. I tak funkcję interpolacji liniowej w postaci macierzy można zaobserwować na przykład w pracy [50], w której na podstawie interpolacji wyznaczone jest równanie promienia przechodzącego przez dany piksel w przestrzeni obrazowej. Innym przykładem jest praca [51], w której znajdowane jest mapowanie między dwiema płaszczyznami obrazowymi jako interpolacja liniowa lub dana wielomianem drugiego stopnia. Technika kalibracji n-płaszczyznowej jest wykorzystywana również w pracy [52], w której na podstawie obrazu czterech płaszczyzn, wyznaczany jest wielomian interpolacji trzeciego rzędu na podstawie którego określana jest odległość obiektu od kamery w skanerach światła strukturalnego. Niewątpliwą zaletą technik interpolacyjnych jest możliwość uwzględnienia wielu czynników, nawet tych, które nie są zdefiniowane. Rozwiązywane zadanie interpolacji jest odporne na zakłócenia i szumy, a poprawa dokładności kalibracji może być uzyskana w łatwy sposób przez dodanie kolejnych płaszczyzn kalibracyjnych. Wadą tych technik jest czysto empiryczny charakter metody i wymagana znajomość pozycji każdej z n płaszczyzn w układzie współrzędnych kamery.

2.2.5 Techniki kalibracji wewnętrznej – porównanie

	Techniki optymalizacji	Techniki liniowe	Techniki interpolacyjne
Wyznaczanie parametrów modeli lokalnych	TAK	NIE	TAK
Modelowanie aberracji	TAK	NIE	NIE
Wymagania ilość danych	DUŻA	MAŁA	DUŻA
Odporność na zaszumienie danych	TAK	NIE	NIE
Konieczność wyznaczenia warunków początkowych	TAK	NIE	NIE
Złożoność obliczeniowa	DUŻA	MAŁA	ŚREDNIA

Tabela 2.1 Porównanie technik kalibracji wewnętrznej w odniesieniu do parametrów użytkowych.

Wymienione w tabeli 2.1 cechy algorytmów rozważanych grup determinują możliwość ich zastosowania w rzeczywistych aplikacjach. I tak na przykład techniki optymalizacji pozwalają na dokładne wyznaczenie parametrów złożonych modeli z zamodelowaną aberracją co pozwala na zastosowania laboratoryjne. Niestety duże wymagania co do ilości danych pomiarowych i konieczność definiowania warunków początkowych ogranicza ich zastosowanie w dynamicznych, nieznanych scenach. Z drugiej strony, w sytuacjach, w których konieczne jest wyznaczenie parametrów kalibracji on-line, przydatne okazują się techniki liniowe. Niestety błąd wyznaczenia parametrów (definiowany przez odległość algebraiczną pomiędzy wyznaczonymi a referencyjnymi wartościami parametrów) w przypadku zastosowania metod tej grupy jest duży w porównaniu do błędów powstałych w trakcie kalibracji metodami innych grup.

2.2.6 Hybrydowe techniki kalibracji

Osobną grupą rozwiązań są metody, które łączą w sobie elementy technik opisanych w poprzednich podrozdziałach. I tak, na przykład w pracy [53] lub [54] techniki liniowe są wykorzystywane do wstępnego wyznaczenia analitycznego rozwiązania problemu kalibracji bez uwzględnienia dystorsji. W kolejnym kroku iteracyjnie wyznaczone są parametry dystorsji, a wyznaczone analitycznie wartości parametrów modelu są korygowane. Wstępne rozwiązanie analityczne rozwiązuje problem czułości na wyznaczenie warunków początkowych i zwiększa

szanse na prawidłową zbieżność rozwiązania. Innym przykładem rozwiązania hybrydowego jest algorytm zaproponowany w pracy [49], który również dzieli się na dwa etapy. W pierwszym wyznaczane jest położenie i orientacja kamery niezależnie od parametrów detektora. Dzięki temu zwiększa się odporność na zaszumienie danych w porównaniu z technikami liniowymi. W drugim etapie wykorzystywane są techniki iteracyjne aby wyznaczyć parametry związane z detektorem. Warto zauważyć, że w porównaniu z technikami globalnej optymalizacji, w drugim etapie wyznaczana jest mniejsza liczba parametrów co skutkuje zmniejszeniem złożoności obliczeniowej.

2.2.7 Opis wybranych metod użytych w pracy

2.2.7.1 Direct Linear Transformation (DLT)

Zaproponowana w [42] metoda pozwala na wyznaczenie macierzy parametrów wewnętrznych i transformacji wzorca kalibracyjnego względem detektora. Metoda zakłada, że znane są współrzędne n położen punktów w lokalnym układzie współrzędnych wzorca $X_i = (x_i, y_i, z_i)$, opowiadające im współrzędne w przestrzeni obrazowej (u_i, v_i) . Korzystając z równań (równanie 2.1.5),(równanie 2.1.10) , można zapisać równania dla pojedynczego punktu (równanie 2.2.1).

$$\left\{ \begin{array}{l} s \cdot \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & \gamma & CP_x \\ 0 & f_y & CP_y \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \cdot \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} = K \cdot [R|T] \cdot \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} = P \cdot \begin{bmatrix} x_i \\ y_i \\ z_i \\ 1 \end{bmatrix} \\ K = \begin{bmatrix} f_x & 0 & CP_x \\ 0 & f_y & CP_y \\ 0 & 0 & 1 \end{bmatrix} \\ P = K \cdot [R|T] \end{array} \right. \quad (\text{równanie 2.2.1})$$

Macierz P , nazywana przez autorów metody **macierzą projekcji kamery**, jest macierzą 3x4 (równanie 2.2.2).

$$P = \begin{bmatrix} p_{11} & p_{12} & p_{13} & p_{14} \\ p_{21} & p_{22} & p_{23} & p_{24} \\ p_{31} & p_{32} & p_{33} & p_{34} \end{bmatrix} \quad (\text{równanie 2.2.2})$$

Macierz P można zapisać za pomocą trzech macierzy – A, B, C (równanie 2.2.3).

$$P = \begin{bmatrix} A^T \\ B^T \\ C^T \end{bmatrix} \quad (\text{równanie 2.2.3})$$

$$A = \begin{bmatrix} p_{11} \\ p_{12} \\ p_{13} \\ p_{14} \end{bmatrix} \quad B = \begin{bmatrix} p_{21} \\ p_{22} \\ p_{23} \\ p_{24} \end{bmatrix} \quad C = \begin{bmatrix} p_{31} \\ p_{32} \\ p_{33} \\ p_{34} \end{bmatrix}$$

co pozwoli na przekształcenie równania (równanie 2.2.1) do równoważnej formy (równanie 2.2.4).

$$s \cdot \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} A^T \\ B^T \\ C^T \end{bmatrix} \cdot X_i \quad (\text{równanie 2.2.4})$$

co pozwala na ułożenie równań oddzielnie dla każdej ze współrzędnych (równanie 2.2.5).

$$\begin{aligned} s &= C^T \cdot X_i \\ s \cdot u_i &= A^T \cdot X_i \quad s \cdot v_i = B^T \cdot X_i \end{aligned} \quad (\text{równanie 2.2.5})$$

skąd można wyznaczyć równania z niewiadomymi A,B,C (równanie 2.2.6).

$$\begin{aligned} C^T \cdot X_i \cdot u_i - A^T \cdot X_i &= 0 \\ C^T \cdot X_i \cdot v_i - B^T \cdot X_i &= 0 \end{aligned} \quad (\text{równanie 2.2.6})$$

W równaniu (równanie 2.2.6) do wyznaczenia jest 11 niewiadomych (skala pozostaje niewyznaczona), a każda para punkt-obraz daje dwa równania. Stąd do przeprowadzenia kalibracji potrzeba przynajmniej sześciu par punktów ($n = 6$). Dla liczby par $n < 6$ nie można znaleźć rozwiązania, a dla liczby par $n > 6$ otrzymujemy **nadokreślony układ równań**, którego rozwiązanie można przybliżyć stosując metodę najmniejszych kwadratów. Wykonuje się to zapisując równanie (równanie 2.2.1) dla wszystkich par punktów w postaci równoważnego równania macierzowego. Aby było to możliwe, należy zapisać **macierz projekcji** jako jednowymiarowy wektor p (równanie 2.2.7).

$$\begin{aligned} p^T &= [p_{11}, p_{12}, p_{13}, p_{14}, p_{21}, p_{22}, p_{23}, p_{24}, p_{31}, p_{32}, p_{33}, p_{34}] \\ &= [p_1, p_2, p_3, p_4, p_5, p_6, p_7, p_8, p_9, p_{10}, p_{11}, p_{12}] \end{aligned} \quad (\text{równanie 2.2.7})$$

Samo równanie macierzowe ma zaś postać pokazaną poniżej (równanie 2.2.8).

$$\begin{bmatrix} -x_1 & -y_1 & -z_1 & -1 & 0 & 0 & 0 & 0 & u_1 x_1 & u_1 y_1 & u_1 z_1 & u_1 \\ 0 & 0 & 0 & 0 & -x_1 & -y_1 & -z_1 & -1 & v_1 x_1 & v_1 y_1 & v_1 z_1 & v_1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -x_i & -y_i & -z_i & -1 & 0 & 0 & 0 & 0 & u_i x_i & u_i y_i & u_i z_i & u_i \\ 0 & 0 & 0 & 0 & -x_i & -y_i & -z_i & -1 & v_i x_i & v_i y_i & v_i z_i & v_i \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -x_n & -y_n & -z_n & -1 & 0 & 0 & 0 & 0 & u_n x_n & u_n y_n & u_n z_n & u_n \\ 0 & 0 & 0 & 0 & -x_n & -y_n & -z_n & -1 & v_n x_n & v_n y_n & v_n z_n & v_n \end{bmatrix} \cdot p = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{równanie 2.2.8})$$

Po wyznaczeniu wartości współczynników wektora p obliczane są parametry DLT $L_1 - L_{11}$, według zależności (równanie 2.2.9):

$$L_i = \frac{p_i}{p_{12}} \quad (\text{równanie 2.2.9})$$

Na podstawie wartości **parametrów DLT**, obliczane są następnie parametry wewnętrzne detektora (równanie 2.2.10).

$$\left\{ \begin{array}{l} CP_x = \frac{(L_1L_9 + L_2L_{10} + L_3L_{11})}{L_9^2 + L_{10}^2 + L_{11}^2} \\ CP_y = \frac{(L_5L_9 + L_6L_{10} + L_7L_{11})}{L_9^2 + L_{10}^2 + L_{11}^2} \\ \varphi = \sin^{-1} \left(\frac{-L_9}{\sqrt{L_9^2 + L_{10}^2 + L_{11}^2}} \right) \\ k = \cos^{-1} \left(\frac{CP_x L_9 - L_1}{\cos \varphi \cdot \sqrt{(CP_x L_9 - L_1)^2 + (CP_x L_{10} - L_2)^2 + (CP_x L_{11} - L_3)^2}} \right) \\ f = \left(\frac{CP_x L_9 - L_1}{\cos \kappa - \cos \varphi \cdot \sqrt{L_9^2 + L_{10}^2 + L_{11}^2}} \right) \end{array} \right. \quad (\text{równanie 2.2.10})$$

2.2.7.2 Hybrydowa kalibracja Zhanga

W metodzie pierwszy raz zaprezentowanej w pracy [53], tak jak w przypadku metody **DLT**, zakłada się znajomość par punktów zdefiniowanych w lokalnym układzie współrzędnych wzorca z ich obrazami w przestrzeni obrazu **IS**. Jednak w przeciwieństwie do metody **DLT**, w metodzie Zhanga używa się płaskiego wzorca kalibracyjnego. Wykonywane są zdjęcia wzorca w k położeniach. Dla każdego z k położeni, wszystkie n punktów w lokalnym układzie współrzędnych wzorca leżą w jednej płaszczyźnie ($z=0$). Sam algorytm kalibracji składa się z następujących etapów:

- wyznaczenie homografii \mathbf{H}_k pomiędzy współrzędnymi punktów w k -tym lokalnym układzie współrzędnych wzorca, a ich obrazami w **IS**,
- analityczne wyznaczenie macierzy parametrów wewnętrznych i macierzy parametrów zewnętrznych na podstawie homografii wyznaczonych dla k położeni wzorca,
- wyznaczenie parametrów dystorsji jako rozwiązania układu równań liniowych metodą najmniejszych kwadratów,
- korekcja wyznaczonych parametrów - rozwiązanie globalnego zadania optymalizacji z uwzględnieniem współczynników dystorsji i z warunkami początkowymi obliczonymi w poprzednich krokach.

2.2.7.2.1 Wyznaczanie homografii

Homografia wyznaczana jest oddzielnie dla każdego z k położów wzorca. W związku ze współpłaszczyznowością punktów w każdym z k zbiorów, równanie można uprościć do postaci pokazanej poniżej (równanie 2.2.11).

$$\left\{ \begin{array}{l} s \cdot \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & \gamma & CP_x \\ 0 & f_y & CP_y \\ 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_1 \\ r_{21} & r_{22} & r_{23} & t_2 \\ r_{31} & r_{32} & r_{33} & t_3 \end{bmatrix} \cdot \begin{bmatrix} x_i \\ y_i \\ 0 \\ 1 \end{bmatrix} = K \cdot \begin{bmatrix} r_{11} & r_{12} & t_1 \\ r_{21} & r_{22} & t_2 \\ r_{31} & r_{32} & t_3 \end{bmatrix} \cdot \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \\ H = K \cdot \begin{bmatrix} r_{11} & r_{12} & t_1 \\ r_{21} & r_{22} & t_2 \\ r_{31} & r_{32} & t_3 \end{bmatrix} \end{array} \right. \quad (\text{równanie 2.2.11})$$

Macierz H jest **macierzą homografii** 3x3 o dziewięciu współczynnikami. Podobnie jak w przypadku **DLT**, ze względu na nieznaną skalę, układ ma o jeden mniej stopień swobody. Procedura wyznaczania współczynników macierzy H jest taka sama jak w przypadku wyznaczania **macierzy projekcji** P w metodzie **DLT**. Inna jest tylko postać równania macierzowego, w którym nie ma wyrazów zawierających \mathbf{z}_i , a wektor parametrów jest dziewięć wymiarowy (równanie 2.2.12).

$$\begin{bmatrix} -x_1 & -y_1 & -1 & 0 & 0 & 0 & u_1 x_1 & u_1 y_1 & u_1 \\ 0 & 0 & 0 & -x_1 & -y_1 & -1 & v_1 x_1 & v_1 y_1 & v_1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -x_i & -y_i & -1 & 0 & 0 & 0 & u_i x_i & u_i y_i & u_i \\ 0 & 0 & 0 & -x_i & -y_i & -1 & v_i x_i & v_i y_i & v_i \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -x_1 & -y_1 & -1 & 0 & 0 & 0 & u_n x_n & u_n y_n & u_n \\ 0 & 0 & 0 & -x_1 & -y_1 & -1 & v_n x_n & v_n y_n & v_n \end{bmatrix} \cdot h = \begin{bmatrix} 0 \\ 0 \\ \vdots \\ 0 \\ 0 \\ \vdots \\ 0 \\ 0 \end{bmatrix} \quad (\text{równanie 2.2.12})$$

$$h^T = [h_{11}, h_{12}, h_{13}, h_{21}, h_{22}, h_{23}, h_{31}, h_{32}, h_{33}]$$

2.2.7.2.2 Wyznaczanie macierzy parametrów wewnętrznych

O homografii H wiadomo, że jest iloczynem macierzy parametrów wewnętrznych i uproszczonej macierzy RT (równanie 2.2.11). Podobnie jak podczas przekształceń (równanie 2.2.3), (równanie 2.2.4), macierz H i RT możemy zapisać w równoważnych formie (równanie 2.2.13).

$$\begin{aligned}
RT &= [r_1 \quad r_2 \quad t] \\
r_1 &= \begin{bmatrix} r_{11} \\ r_{21} \\ r_{31} \end{bmatrix} \quad r_2 = \begin{bmatrix} r_{12} \\ r_{22} \\ r_{32} \end{bmatrix} \quad t = \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \\
H &= [h_1 \quad h_2 \quad h_3] \\
h_1 &= \begin{bmatrix} h_{11} \\ h_{21} \\ h_{31} \end{bmatrix} \quad h_2 = \begin{bmatrix} h_{12} \\ h_{22} \\ h_{32} \end{bmatrix} \quad h_3 = \begin{bmatrix} h_{13} \\ h_{23} \\ h_{33} \end{bmatrix}
\end{aligned} \tag{równanie 2.2.13}$$

Podstawiając do (równanie 2.2.11), otrzymamy (równanie 2.2.14).

$$\begin{aligned}
[h_1 \quad h_2 \quad h_3] &= K \cdot [r_1 \quad r_2 \quad t] \\
[r_1 \quad r_2 \quad t] &= K^{-1} \cdot [h_1 \quad h_2 \quad h_3] \\
r_1 &= K^{-1} \cdot h_1 \\
r_2 &= K^{-1} \cdot h_2
\end{aligned} \tag{równanie 2.2.14}$$

Kolumny r_1 i r_2 są kolumnami ortonormalnej macierzy rotacji, z tego powodu, możliwe jest sformułowanie dwóch zależności (równanie 2.2.15).

$$\begin{cases} r_1^T \cdot r_2 = 0 \\ \|r_1\| - \|r_2\| = 0 \end{cases} \tag{równanie 2.2.15}$$

Na podstawie (równanie 2.2.14) i (równanie 2.2.15) otrzymujemy równania opisujące zależności znanych parametrów homografii od macierzy K (równanie 2.2.16).

$$\begin{cases} h_1^T \cdot (K^{-1})^T \cdot K^{-1} \cdot h_2 = 0 \\ h_1^T \cdot (K^{-1})^T \cdot K^{-1} \cdot h_1 - h_2^T \cdot (K^{-1})^T \cdot K^{-1} \cdot h_2 = 0 \end{cases} \tag{równanie 2.2.16}$$

W obu równaniach macierz K pojawia się wyłącznie w formie $(K^{-1})^T \cdot K^{-1}$. Można wprowadzić macierz pomocniczą, symetryczną dodatnio określoną, $B = (K^{-1})^T \cdot K^{-1}$ i przekształcić równanie (równanie 2.2.16) do postaci równoważnej (równanie 2.2.17).

$$\begin{aligned}
h_1^T \cdot B \cdot h_2 &= 0 \\
h_1^T \cdot B \cdot h_1 - h_2^T \cdot B \cdot h_2 &= 0
\end{aligned} \tag{równanie 2.2.17}$$

Warto zauważyć, że parametry macierzy B są ściśle powiązane z parametrami wewnętrznymi kamery (równanie 2.2.18). Dzięki temu możliwe jest definiowanie ograniczeń dla parametrów kamery na etapie wyznaczania macierzy B , co zostało wykonane w pracy [37], która powstała w trakcie badań w ramach niniejszej rozprawy.

$$B = \begin{bmatrix} b_{11} & b_{12} & b_{13} \\ b_{21} & b_{22} & b_{23} \\ b_{31} & b_{32} & b_{33} \end{bmatrix} = \begin{bmatrix} \frac{1}{f_x^2} & -\frac{\gamma}{f_x^2 f_y} & \frac{CP_y \gamma - CP_x f_y}{f_x^2 f_y} \\ -\frac{\gamma}{f_x^2 f_y} & \frac{1}{f_y^2} & -\frac{\gamma(CP_y \gamma - CP_x f_y)}{f_x^2 f_y^2} - \frac{CP_y}{f_y^2} \\ \frac{CP_y \gamma - CP_x f_y}{f_x^2 f_y} & -\frac{\gamma}{f_x^2 f_y} & \frac{(CP_y \gamma - CP_x f_y)^3}{f_x^2 f_y^2} + \frac{CP_y^2}{f_y^2} + 1 \end{bmatrix} \tag{równanie 2.2.18}$$

Macierz B może być opisana za pomocą sześciowymiarowego wektora \mathbf{b} (równanie 2.2.19).

$$b^T = [b_{11}, b_{12}, b_{13}, b_{22}, b_{23}, b] = [b_1, b_2, b_3, b_4, b_5, b_6] \quad (\text{równanie 2.2.19})$$

Po wyznaczeniu macierzy B na podstawie równania (równanie 2.2.17), można wyznaczyć macierz K używając dekompozycji Cholesky'ego [55].

2.2.7.2.3 Wyznaczanie parametrów dystorsji

Dystorsje układu optycznego można uwzględnić, definiując równania zniekształcające wirtualną rzutnię VPP. Współrzędne punktu $(a''_x, a''_y, 1)$ obliczane za pomocą równania (równanie 2.1.2) przekształca się we współrzędne $(a''_x, a''_y, 1)$ za pomocą zależności (równanie 2.2.20)(równanie 2.2.19).

$$\begin{cases} a'''_x = a''_x \frac{1 + k_1 r^2 + k_2 r^4 + k_3 r^6}{1 + k_4 r^2 + k_5 r^4 + k_6 r^6} + 2p_1 a''_x a''_y + p_2 (r^2 + 2(a''_x)^2) \\ a'''_y = a''_y \frac{1 + k_1 r^2 + k_2 r^4 + k_3 r^6}{1 + k_4 r^2 + k_5 r^4 + k_6 r^6} + 2p_2 a''_x a''_y + p_1 (r^2 + 2(a''_y)^2) \\ r = (a''_x)^2 + (a''_y)^2 \end{cases} \quad (\text{równanie 2.2.20})$$

W którym k_i to współczynniki dystorsji promieniowej, a p_i to współczynniki dystorsji stycznej. Następnie współrzędne $(a'''_x, a'''_y, 1)$ można przekształcić we współrzędne obrazowe (u, v) za pomocą macierzy K. Macierz K jest znana po poprzednim etapie kalibracji, a współrzędne $(a''_x, a''_y, 1)$ można obliczyć z korzystając z równania (równanie 2.2.21).

$$\begin{bmatrix} a''_x \\ a''_y \\ 1 \end{bmatrix} = \begin{bmatrix} r_{11} & r_{12} & t_1 \\ r_{21} & r_{22} & t_2 \\ r_{31} & r_{32} & t_3 \end{bmatrix} \cdot \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \quad (\text{równanie 2.2.21})$$

Przy założeniu, że parametry $k_4 - k_6$ są równe 0, równanie (równanie 2.2.19) można przekształcić do równoważnego równania liniowego. W połączeniu z równaniem (równanie 2.1.5), uzyskujemy układ równań, który podobnie jak poprzednio możemy przekształcić do pojedynczego równania macierzowego, które pozwala wyznaczyć współczynniki dystorsji (równanie 2.2.22).

$$\begin{bmatrix} f_x a_{x1}'' r^2 & f_x a_{x1}'' r^4 & f_x a_{x1}'' r^6 & 2f_x a_{x1}'' a_{y1}'' & (r^2 + 2(a_{x1}'')^2) \\ f_y a_{y1}'' r^2 & f_y a_{y1}'' r^4 & f_y a_{y1}'' r^6 & (r^2 + 2(a_{y1}'')^2) & 2f_y a_{x1}'' a_{y1}'' \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ f_x a_{xi}'' r^2 & f_x a_{xi}'' r^4 & f_x a_{xi}'' r^6 & 2f_x a_{xi}'' a_{yi}'' & (r^2 + 2(a_{xi}'')^2) \\ f_y a_{yi}'' r^2 & f_y a_{yi}'' r^4 & f_y a_{yi}'' r^6 & (r^2 + 2(a_{yi}'')^2) & 2f_y a_{xi}'' a_{yi}'' \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ f_x a_{xn}'' r^2 & f_x a_{xn}'' r^4 & f_x a_{xn}'' r^6 & 2f_x a_{xn}'' a_{yn}'' & (r^2 + 2(a_{xn}'')^2) \\ f_y a_{yn}'' r^2 & f_y a_{yn}'' r^4 & f_y a_{yn}'' r^6 & (r^2 + 2(a_{yn}'')^2) & 2f_y a_{xn}'' a_{yn}'' \end{bmatrix} \cdot k = \begin{bmatrix} u_1 - CP_x - f_x a_{x1}'' \\ v_1 - CP_y - f_y a_{y1}'' \\ \vdots \\ u_i - CP_x - f_x a_{xi}'' \\ v_i - CP_y - f_y a_{yi}'' \\ \vdots \\ u_n - CP_x - f_x a_{xn}'' \\ v_n - CP_y - f_y a_{yn}'' \end{bmatrix} \quad (\text{równanie 2.2.22})$$

$$k^T = [k_1, k_2, k_3, k_4, p_1, p_2]$$

$$Dk = d$$

Korzystając z metody najmniejszych kwadratów możemy wyznaczyć wartości macierzy k za pomocą zależności (równanie 2.2.23)

$$k = (D^T \cdot D)^{-1} \cdot D^T \cdot d \quad (\text{równanie 2.2.23})$$

2.2.7.2.4 Globalne zadanie optymalizacji

Danymi wejściowymi kalibracji są pary punktów zdefiniowanych w lokalnych układach współrzędnych wzorca i ich obrazów w **IS**. Używając równań (równanie 2.1.13), (równanie 2.2.19), (równanie 2.2.23), mając wyznaczone wartości parametrów modelu, można dla każdego punktu opisanego w lokalnym układzie współrzędnych wzorca, wyznaczyć jego współrzędne w dziedzinie obrazu. Tak wyznaczone współrzędne uwzględniają dystorsje obiektywu, położenie wzorca względem kamery i parametry detektora. Zdefiniujmy (u'_{ki}, v'_{ki}) jako obliczane na podstawie modelu współrzędne obrazu i -tego punktu w k -tym położeniu wzorca. Porównanie współrzędnych (u'_{ki}, v'_{ki}) z danymi wartościami referencyjnymi (u_{ki}, v_{ki}) (wykrytymi na obrazie), pozwala na szacowanie dokładności kalibracji.

Zaproponowaną w pracy Zhanga miarą jakości kalibracji, jest **błąd reprojektacji**, obliczany jako suma odległości pomiędzy współrzędnymi (u'_{ki}, v'_{ki}) i (u_{ki}, v_{ki}) punktów w **IS** (równanie 2.2.24)

$$e = \sum_k \sum_i [(u'_{ki} - u_{ki})^2 + (v'_{ki} - v_{ki})^2] \quad (\text{równanie 2.2.24})$$

Równanie (równanie 2.2.24) może posłużyć do sformułowania funkcji celu w zadaniu optymalizacji. Zadanie optymalizacji rozwiązywane jest przez algorytm Levenberga-Marquardta [56]. Wartości początkowe ustawione są na podstawie wyników poprzednich kroków. Takie sformułowanie zadania optymalizacji pozwala na wyznaczenia parametrów które minimalizują odległość w przestrzeni obrazowej, a nie w przestrzeni algebraicznej tak jak rezultaty poprzednich kroków.

2.3 Kalibracja zewnętrzna

2.3.1 Wprowadzenie

Opisane w poprzednim rozdziale techniki kalibracji wewnętrznej pozwalają na wyznaczenie cech fizycznych detektora wizyjnego, które są stałe w czasie działania systemu. Druga grupa parametrów (**kalibracja zewnętrzna**), odpowiadających za orientację i położenie detektora w scenie, w systemach śledzenia działających w dynamicznych scenach musi być wyznaczana w trakcie pracy systemu i na bieżąco korygowana. Aktualizacja **kalibracji zewnętrznej** może być przeprowadzana na dwa sposoby:

- wyznaczanie transformacji bezwzględnej dla każdej chwili czasowej: w tym podejściu transformacje są wyznaczane niezależnie. **Kalibracja zewnętrzna** jest ustalana albo na podstawie kalibracji z ostatniej chwili czasowej, albo na podstawie historii wyznaczonych transformacji,
- wyznaczanie transformacji względnej – ruchu kamery – pomiędzy i -tą a $(i-1)$ -szą chwilą czasową. Kalibracja zewnętrzna wyznaczana jako suma lub suma ważona dotychczasowych transformacji względnych.

Niezależnie od przyjętego podejścia konieczne jest wyznaczanie transformacji względnej lub bezwzględnej dla danej chwili czasowej. Wykonuje się to analizując związki między współrzędnymi odpowiadających sobie par punktów lub parametrami par prostych. W przypadku wyznaczania transformacji bezwzględnej analizowane są zależności pomiędzy modelem zdefiniowanym w **GCS** a jego projekcją w **IS**. W przypadku wyznaczania transformacji względnej analizuje się zależności między kolejnymi projekcjami w **IS**. W większości zastosowań opisane powyżej relacje muszą być wyznaczone przy zastosowaniu algorytmów przetwarzania obrazu i wiedzy apriori o scenie. Stąd samą procedurę kalibracji można podzielić na dwa etapy:

- etap detekcji i interpretacji informacji zawartych na obrazie pochodzącym z detektora wizyjnego, w którym problem jest redukowany do problemu relacji punkt-punkt lub prosta-prosta,
- etap wyznaczenia **kalibracji zewnętrznej** jako rozwiązania zredukowanego problemu relacji punkt-punkt lub prosta-prosta.

Wybór sposobu aktualizacji parametrów zewnętrznych, a także wybór realizacji etapów kalibracji musi być dostosowany do wymagań danej aplikacji i dostępnej wiedzy o scenie. Cechami rozwiązań, które decydują o skuteczności w danej aplikacji są:

- dopuszczalny wspierany charakter zmian sceny: może to być ciągły ruch kamery zamontowanej na robocie mobilnym, ruch obiektu referencyjnego w scenie, drgania kamery wokół jednego punktu lub niespodziewane, nagłe, małe lub duże przesunięcia,
- poziom wiedzy o obserwowanej scenie – począwszy od dobrze zdefiniowanych scen laboratoryjnych, a skończywszy na przybliżonej kalibracji w nieznanej scenie,
- wymagana ilość danych kalibracyjnych,
- odporność procedury kalibracji na błędy detekcji i szумы w dziedzinie obrazu,
- częstotliwość z jaką może być aktualizowana kalibracja i czas reakcji – rozwiązania wykorzystujące uśrednianie lub filtracje mogą wprowadzać opóźnienia, które w jednych zastosowaniach są akceptowalne a w innych nie,
- złożoność obliczeniowa,
- prawdopodobieństwo popełnienia błędu grubego i uwarunkowania numeryczne.

Wielość konfiguracji, technik i podejść powoduje, że przegląd istniejących rozwiązań w dalszej części pracy zostanie przeprowadzony osobno w podziale na dwa podejścia – względne i bezwzględne. Każdy z etapów kalibracji zostanie zaś potraktowany jako osobny problem, którego rozwiązaniami będą prezentowane algorytmy. W przeciwieństwie do przeglądu technik kalibracji wewnętrznej podczas omawiania cech poszczególnych rozwiązań nacisk zostanie położony przede wszystkim na ograniczenia i dodatkowe wymagania. Dzięki temu łatwiejsza będzie ewaluacja istniejących algorytmów w odniesieniu do wymagań aplikacji realizowanych w ramach niniejszej pracy, a także wybór konfiguracji użytych rozwiązań.

2.3.2 Wyznaczanie transformacji bezwzględnej

2.3.2.1 Detekcja i interpretacja informacji w obrazie

W przypadku algorytmów kalibracji bezwzględnej, konieczna jest znajomość dobrze zdefiniowanych relacji pomiędzy modelem sceny zdefiniowanym w globalnym układzie współrzędnych a jego projekcją w przestrzeni obrazu. W zależności od sceny i dostępnych informacji możemy wyróżnić przypadki, w których analiza dotyczy prymitywów geometrycznych, syntetycznej projekcji modelu sceny, analizy kształtu i konturów obiektów

oraz transformacji widoku kamery do widoku referencyjnego. Wynikiem analizy jest znalezienie w scenie projekcji punktów charakterystycznych **KP** (**ang. keypoints**) lub linii charakterystycznych **KL** (**ang. key-lines**).

2.3.2.1.1 Zależności geometryczne w scenie

W algorytmach tej grupy wykorzystywane są własności rzutu środkowego i jego niezmienników by na obrazie z detektora wykryć projekcje punktów charakterystycznych.

Jednym z niezmienników jest przynależność punktu do prostej, dzięki czemu punkty leżące na przecięciu linii w **GCS** będą leżały na przecięciu projekcji linii w **IS**. Przykładem rozwiązań korzystających z przecięć linii jest na przykład praca [57], w której autorzy znajdują narożniki boiska tenisowego, by móc śledzić głowę zawodnika we współrzędnych XY boiska. Innym przykładem jest system, zaimplementowany w ramach badań prowadzonych w niniejszej pracy [58]. Są w nim wykrywane przecięcia linii boiska do siatkówki i zmiany współrzędnych tych przecięć w celu aktualizowania informacji o wzajemnym położeniu kamer.

Innym niezmiennikiem rzutu środkowego jest dwustosunek (**ang. cross-ratio**) czterech współliniowych punktów. Cecha ta jest wykorzystywana w pracy [59], w której kalibracja przeprowadzana jest z użyciem wzorca złożonego z dwóch koncentrycznych okręgów. Autorzy wyznaczają prostą przechodzącą przez środki rzutowanych elips, które ze względu na błąd ekscentryczności (Rozdział 2.4) nie pokrywają się z rzutem środków okręgów, lecz leżą na tej samej prostej. Znajomość punktów współliniowych i niezmiennik dwustosunku pozwalają wyznaczyć skorygowane równanie projektowanej elipsy sparametryzowane w tej samej przestrzeni co równanie wewnętrznego okręgu. Dzięki temu, możliwe jest wspólne próbkowanie okręgu i jego projekcji w celu znalezienia n par odpowiadających sobie punktów.

Kolejnym niezmiennikiem rzutu środkowego jest własność przecinania się rzutów dwóch prostych równoległych w **GCS** w jednym punkcie w **IS**, zwanym punktem zbiegu (**ang. vanishing point**). Cecha ta wykorzystywana jest w pracy [60], w której autorzy używają szacowanych współrzędnych punktów znikających w celu zredukowania złożoności i większej odporności algorytmu wyznaczania homografii (Rozdział 2.2). Następnie używają modelu neuronowego, który wyznacza transformacje kamer widzących boisko do piłki nożnej lub hokeja.

Zaletą algorytmów tej klasy jest niska złożoność obliczeniowa. Algorytmy detekcji okręgów czy linii są znane od wielu lat i dobrze zoptymalizowane. Co więcej, dokładność wyznaczania punktów charakterystycznych w związku z dużymi kontrastami jest duża, dzięki czemu potrzebna jest mniejsza liczba punktów, a samą korespondencję można rozwiązać stosując metody liniowe. Istotnym ograniczeniem opisanych powyżej metod jest zastosowanie wyłącznie w scenach, w których możliwe jest zdefiniowanie fragmentów, będących prostymi prymitywami geometrycznymi i zastosowanie niezmienników rzutu.

2.3.2.1.2 Syntetyczna projekcja modelu

W algorytmach tej kategorii znany jest model 3D całej sceny w postaci siatki trójkątów lub chmury punktów. W czasie działania algorytmu wykonywana jest symulacja rzutu modelu na matrycę detektora, w wyniku której powstaje syntetyczny obraz sceny. Detekcja i analiza informacji opiera się na korelacji pomiędzy obrazem syntetycznym a rzeczywistym obrazem z detektora. Przykładem takiego rozwiązania jest na przykład praca [61], w której autorzy używają cech SIFT [62] i SURF [63] aby porównać widok z kamery umieszczonej na samochodzie autonomicznym z syntetycznym widokiem modelu placu Stanisława we francuskim mieście Nancy. Znalezione relacje wraz z danymi z nadajnika GPS pozwoliły im na lokalizację i sprawną nawigację pojazdu w scenie. Innym przykładem podejścia wykorzystującego wiedzę a priori w postaci znanego modelu sceny jest praca [64], w której autorzy wykorzystują chmury punktów powstałe w wyniku dokumentacji dziedzictwa kulturowego w aplikacji rzeczywistości rozszerzonej działającej na urządzeniu mobilnym. Podobnie jak w poprzedniej pracy, tak i tutaj porównanie obrazu z jego syntetycznym odpowiednikiem wykonywane jest w oparciu o cechy SIFT. Dodatkowym etapem przetwarzania jest wybór podzbioru znalezionych punktów charakterystycznych z wykorzystaniem metody z grupy RANSAC (**ang. RAndom SAmple Consensus**) zaproponowanej po raz pierwszy w [65].

Algorytmy wykorzystujące projekcję modelu mogą być używane w dowolnie złożonych scenach o ile znany jest wcześniej ich model 3D. Złożoność obliczeniowa tych metod do niedawna była dużym ograniczeniem, jednak rozwój kart graficznych i przetwarzania równoległego w połączeniu z metodami wyboru podzbioru punktów charakterystycznych sprawił, że obecne aplikacje pozwalają osiągać wyniki w czasie rzeczywistym. Istotną wadą tych rozwiązań jest natomiast wrażliwość na zmiany sceny, jej oświetlenia i obecność

informacji związanej z odbiciem zwierciadlanym (**ang. specular reflection**) w zdjęciach. Dodatkowo, dokładność działania tych metod w dużej mierze zależy od dokładności używanego modelu, co często wymusza wstępne skanowanie scen, w których ma funkcjonować system.

2.3.2.1.3 Analiza kształtu i konturu

Inną grupą algorytmów są metody wyznaczające punkty charakterystyczne na podstawie analizy kształtu konturu znanego obiektu. Wiedza ta jest później wykorzystywana na przykład do wyznaczania orientacji obiektu w znanej scenie tak jak w pracy [66], w której autor analizuje kontur wątroby podczas zabiegu termoablacji celu wyznaczenia jej położenia i orientacji w scenie. Dzięki temu możliwe było projektowanie jej wewnętrznych struktur, co wspomagało pracę chirurga. Innym przykładem podejścia analizy konturu jest praca [67], w której korelacja między szablonami kształtu (**ang. shape templates**) znanych obiektów pochodzącymi z różnych widoków a konturem obiektu obserwowanego w scenie pozwala wyznaczyć punkty charakterystyczne, na podstawie których określana jest najbardziej prawdopodobna pozycja kamery w odniesieniu do obserwowanego obiektu.

Podobnie jak w modelach wykorzystujących projekcję modelu tak i tu, dużą rolę odgrywa znajomość obserwowanego obiektu. W obu prezentowanych rozwiązaniach kontury porównywane były do dyskretnej przestrzeni szablonów kształtu. Im więcej próbek w tej przestrzeni, tym dokładność wyznaczania cech charakterystycznych jest większa. Niestety, zwiększa się także czas potrzebny na przeszukanie przestrzeni rozwiązań.

2.3.2.1.4 Reprojektacja

Ostatnią grupą metod prezentowanych w tej części pracy, są algorytmy przekształcające rzeczywisty obraz detektora do widoku referencyjnego. Jest to podejście podobne do podejścia z syntetyczną projekcją modelu. W tym przypadku jednak to nie model a obraz z kamery jest przekształcany. Przykładem może być praca [68], w której autorzy analizując boisko do piłki nożnej znajdują relacje między czterema narożnikami zdjęcia a punktami w referencyjnym widoku boiska z góry. Po znalezieniu homografii zdjęcie jest transformowane. Błąd wyznaczenia relacji jest następnie określany na podstawie analizy przetransformowanego zdjęcia w odniesieniu do widoku referencyjnego. Cały proces powtarzany jest iteracyjnie do momentu, w którym błąd wyznaczenia relacji jest wystarczająco mały. Inną metodą należąca

do tej grupy jest ta przedstawiona w pracy [69], w której wykrywane są linie boiska sportowego. Następnie za pomocą techniki punktów znikających [70] wyznaczane jest wstępne przekształcenie widoku boiska do widoku referencyjnego. Ostateczne relacje między liniami wykrytymi na boisku a liniami w widoku referencyjnym zostają ustalone przez iteracyjny algorytm optymalizacyjny [71] lub technikę dopasowania grafów [72].

Dużą zaletą algorytmów tej klasy jest wysoka dokładność wyznaczania zależności między widokiem referencyjnym a widokiem z kamery, dzięki czemu niepewności związane z kalibracją zewnętrzną są mniejsze. Niestety iteracyjny charakter oraz konieczność porównywania całych obrazów powodują, że nawet przy szybkiej implementacji z użyciem kart graficznych czas wyznaczania transformacji dla jednego widoku przekracza 0,1 s, co wyklucza zastosowanie metod w zastosowaniach automatycznej aktualizacji parametrów kalibracji w czasie rzeczywistym.

2.3.2.2 Rozwiązanie zredukowanego problemu

Po wyznaczeniu zależności między modelem sceny a obrazem rzeczywistym detektora, możliwe jest rozwiązanie problemu wyznaczenia **parametrów zewnętrznych** (transformacji lokalnego układu współrzędnych) detektora. W większości spotykanych opracowań wykorzystywane są relacje 3D-2D par punkt-punkt lub prosta-prosta.

2.3.2.2.1 Punkt-punkt

Jak wspomniano w Rozdziale 2.1, pozycja kamery jest opisana za pomocą sześciu stopni swobody – trzech związanych z rotacją i trzech związanych z translacją. Dlatego też, minimalna informacja, jaka jest potrzebna do wyznaczenia **kalibracji zewnętrznej** to trzy pary odpowiadających sobie, nie współliniowych, punktów w **GCS** i **IS**. Często w celu poprawy odporności algorytmu na szумы i zwiększenia dokładności używa się większej liczby punktów, co niestety często powoduje istnienie więcej niż jednego rozwiązania i zwiększa złożoność obliczeniową rozwiązania. Prowadzone w tym obszarze prace skupiają się na uniezależnieniu dokładności kalibracji od szumów pomiarowych, wyborem i detekcją punktów odstających a także optymalizacją czasu działania algorytmów. Dotychczas powstało wiele rozwiązań i udoskonalień dotyczących tej sfery, które można podzielić na dwie rodziny: rodzinę algorytmów analitycznych i rodzinę algorytmów iteracyjnych.

2.3.2.2.1.1 Algorytmy analityczne

Wśród algorytmów analitycznych warto zacząć od klasycznego podejścia, badanego już w XIX w. – od podejścia **P3P** (ang. **perspective-3-point**), które skupia się na znalezieniu rozwiązania zadania korelacji przy minimalnej liczbie punktów. Jako pierwszy problem zbadał i rozwiązał Grunert [73]. Po nim przez kolejne 150 lat problem był rozważany przez matematyków a powstałe w tym czasie propozycje zostały zestawione w pracy [74]. W trakcie procesu kalibracji, w metodach tych rozważany jest układ trzech równań drugiego stopnia, którego rozwiązaniem jest lokalizacja lokalnego układu współrzędnych kamery oraz trzech kątów, które w osi optyczną kamery tworzą proste przechodzące przez punkty kontrolne. Algorytmy rozwiązujące problem **P3P** były rozwijane później również w pracach [75], [76] oraz [77]. Rozwiązania korzystające z trzech par punktów są bardzo wrażliwe na jakość detekcji i szumy pomiarowe. Ograniczenie to zostało pokonane dzięki rozszerzeniu algorytmów do wersji używających większej liczby punktów – **P4P** [78], czy **P5P** [79]. Niestety, rozwiązania te nie mogły być używane dla większej liczby punktów. Osobną grupę stanowią algorytmy znajdowania rozwiązania nieoznaczonego układu równań z minimalizacją błędu średniokwadratowego. Przykładem może być praca [80], która podobnie jak w metodzie **DLT** prezentowanej w poprzednim rozdziale wykorzystuje dekompozycję SVD do znalezienia rozwiązania zlinearyzowanego równania drugiego rzędu. Niestety, złożoność obliczeniowa rozwiązania to $O(n^5)$, co dla większej liczby punktów przekreśla jej zastosowanie w aplikacjach działających w czasie rzeczywistym nawet pomimo rozwinięć jak na przykład w pracy [81], gdzie rozwiązanie cechuje się złożonością obliczeniową $O(n^2)$.

Współczesne rozwiązania opierają się na algorytmie **EPnP** zaproponowanym w [82], w którym zbiór n -punktów charakterystycznych został zastąpiony kombinacją liniową czterech wirtualnych punktów. Dzięki temu, możliwe stało się efektywne używanie informacji zawartych w dowolnie dużym zbiorze punktów przy zachowaniu dokładności metod klasycznych. Metoda **EPnP** zaproponowana przez Lepetit'a została w ostatnich latach rozwinięta – kombinację liniową zastąpiono przybliżaniem wielomianem, dzięki czemu kosztem niewielkiego wzrostu czasu obliczeń poprawiono skuteczność kalibracji – na przykład w algorytmach **RPnP** [83] i **OPnP** [84].

Zaletą podejścia analitycznego jest niska złożoność obliczeniowa i brak konieczności ustalania warunków brzegowych (jak w przypadku algorytmów optymalizacyjnych). Z drugiej strony,

dokładności wyznaczania **parametrów zewnętrznych** są niższe niż w przypadku opisywanego podejścia wykorzystującego algorytmy optymalizacji.

2.3.2.2.1.2 Algorytmy iteracyjne

Wśród metod tej kategorii klasyczne podejście zakłada minimalizację błędu reprojekcji w przestrzeni obrazu **IS**. Używając równania projekcji perspektywicznej dla każdego punktu kluczowego **P** w **GCS** wyznaczana jest projekcja otrzymana przy szacowanych w danym kroku rotacji i translacji. Funkcją celu jest średnia odległość pomiędzy punktami wyznaczonymi tą metodą a punktami wykrytymi na obrazie. To podejście zastosowano na przykład w pracy [85], w której problem optymalizacji rozwiązano metodą Gaussa-Newtona [86], lub w pracy [87], w której dołączenie pochodnych ruchu pozwoliło na niezależne wyznaczenie translacji i rotacji. Największym ograniczeniem algorytmów optymalizacyjnych bazujących na błędzie reprojekcji jest zależność od dobrze wyznaczonych warunków początkowych. Ten problem częściowo rozwiązuje zastosowanie algorytmu Levenberga-Marquardta [56] jak w pracy [88]. Niestety, w niekorzystnych warunkach liczba iteracji potrzebna do znalezienia jest duża, co zwiększa złożoność obliczeniową algorytmów iteracyjnych wykorzystujących błąd reprojekcji jako funkcję celu.

Inną klasą algorytmów iteracyjnych są algorytmy minimalizujące błąd reprojekcji w przestrzeni obiektu. Przykładem algorytmu tej klasy jest algorytm **OI** (**ang. orthogonal optimization**) zaproponowany w pracy [89], w którym autorzy wykorzystują fakt, że punkt **p** w **GCS**, punkt nodalny **NP** i rzut punktu **P** na wirtualnej rzutni **VPP** leżą na jednej prostej. Ta własność, po kilku przekształceniach geometrycznych pozwala wyrazić błąd reprojekcji w przestrzeni obiektu. Pozwoliło to na zwiększenie dokładności i skrócenie czasu obliczeń w przypadku źle dobranych warunków początkowych. Czas obliczeń może być dodatkowo skrócony, gdy w kalibracji konieczne będzie wyznaczenie jedynie rotacji, tak jak w pracy [90]. Wadą podejścia używającego funkcji celu w przestrzeni obiektu jest nierówne traktowanie punktów charakterystycznych – większą wagę przykładają się do punktów bardziej oddalonych. W przypadku, gdy analizowane są prymitywy geometryczne takie jak na przykład linie boiska, detekcja punktów charakterystycznych bardziej oddalonych od detektora często obciążona jest większymi błędami. Tego ograniczenia pozbawione jest klasyczne podejście z użytym algorytmem Levenberga-Marquardta, którego skuteczność i złożoność obliczeniowa są zbliżone do algorytmu **OI** dla warunków początkowych blisko globalnego optimum (jak na przykład w zadaniu aktualizacji **kalibracji zewnętrznej**).

2.3.2.2.2 Prosta-Prosta

W scenach, w których utrudnione jest wyznaczenie punktów charakterystycznych, na przykład z powodu przysłaniania, złego oświetlenia lub zniekształceń perspektywicznych, często łatwo znaleźć zbiory linii charakterystycznych. Co więcej, wpływ szumów i błędów detekcji na znajdowanie linii w większości zastosowań jest mniejszy, a sama linia przynosi wiele informacji o scenie, co pokazano na przykład w pracy [91]. Z drugiej strony wielomianowe układy równań, które pozwalają wyznaczyć **kalibrację zewnętrzną** mają stopień 8 lub wyższy, przez co ich rozwiązanie jest o wiele trudniejsze i bardziej złożone obliczeniowo niż w przypadku wielomianów związanych z relacjami punkt-punkt. Ponadto algorytmy prosta-prosta są mniej odporne na obecność obserwacji odstających (wpływ obserwacji odstających na algorytmy rozwiązujące problem relacji linia-linia w sposób ilościowy zbadany jest w pracy [92]). Dlatego też w ostatnich latach prowadzone są liczne badania, które mają na celu pokonanie ograniczeń algorytmów tej grupy, co pozwoli na ich stosowanie w rzeczywistych aplikacjach.

Klasycznym, rozwijanym od lat 90-tych XX w. przypadkiem, jest wyznaczanie **kalibracji zewnętrznej** kamery na podstawie trzech odpowiadających sobie linii – **P3L (ang. perspective 3 lines)**. Prace związane z wyprowadzaniem wzoru jawnego (**ang. closed form solution**) są zawarte w pracach [93] oraz [94]. Dalsze prace pokazywały sposoby redukcji stopnia wielomianu i samego problemu dla specjalnych przypadków jak w artykule [95], w którym pokazano rozwiązanie dla linii leżących w jednej płaszczyźnie. Niestety, jak pokazali Navab i Faugeras [96], rozwiązanie problemu relacji trzech par linia-linia nie jest jednoznaczne dla każdego przypadku, a uzyskanie unikalnego rozwiązania możliwe jest dopiero przy użyciu czterech i więcej linii.

Dla problemu n-linii rozwijane są trzy podejścia: iteracyjne, z podzbiorem linii i sprowadzające problem do problemu punkt-punkt. W pierwszym podejściu, tak jak w przypadku problemu **PnP**, rozwiązuje się równanie minimalizujące błąd reprojekcji sparametryzowanej prostej. Przykładem może być praca [97], w którym w ciągu jednej iteracji wyznaczana jest pełna transformacja lub praca [98], w której oddzielnie wyznacza się rotację a później translację. Metody te zostały rozwinięte w pracach [99] oraz [100], w których poprawiono odporność algorytmów i szybkość ich działania. Tak, jak w przypadku wszystkich algorytmów iteracyjnych tak i tu dużą rolę odgrywa wyznaczenie warunków początkowych. Sam czas działania z uwagi na większą złożoność problemu jest dłuższy niż dla algorytmów **PnP**. W drugim podejściu ze zbioru wszystkich par linia-linia wybiera się podzbiory 3-elementowe.

Dzięki przekształceniom problemu **P3L** dla podzbiorów konstruowana jest wielomianowa funkcja celu 16-tego stopnia mająca dokładnie jedno rozwiązanie. Algorytm tej kategorii zaprezentowali wspomniani wcześniej Xu i in. [92]. Jak przyznają autorzy rozwiązanie to jest jednak wrażliwe na obecność informacji odstających. Trzecią grupą algorytmów rozwiązujących zredukowany problem linia-linia są algorytmy sprowadzające problem do problemu **PnP**. Pierwszy przykład pojawia się we wspomnianej dwukrotnie pracy Xu i in, gdzie autorzy zaproponowali kilka algorytmów grupy **LPnL** (**ang. linearization point n line**), które są odporne na obecność informacji odstających. W algorytmach tej grupy algorytmy **PnP** używane są po zredukowaniu prostych do punktów leżących na końcach wykrytych linii. Niestety, algorytmy tej grupy są złożone obliczeniowo i wymagają obecności $n > 50$ par linia-linia.

Inną parametryzacją jest opis za pomocą współrzędnych Pluckera [101], który zaproponowali w swojej pracy Příbyl i in [102], a zastosowanie w analizie obrazów sportowych zaproponowali w swojej pracy Cao i in. ([103]). W tym podejściu prostą w 3D opisuje się na pomocą wektora sześćcioelementowego a prostą w 2D - czteroelementowego. W dalszej części rozwiązuje się problem **PnP** dla „punktów” o większej wymiarowości.

2.3.2.2.3 Podejście hybrydowe

W ostatnich latach rozwijane są również metody, które do wyznaczania **parametrów zewnętrznych** używają zarówno informacji zawartych w punktach charakterystycznych, jak i w prostych. Jednym z najprostszych podejść jest wykorzystanie błędów reprojekcji w przestrzeni obrazu i uzupełnienie algorytmów **LPnL** (wykorzystujących krańce linii) o wykryte na obrazie punkty kluczowe, tak jak pokazano w pracy [104]. We wspomnianej pracy autorzy uzupełnili technikę detekcji o metody przewidywania niewidocznych końców linii referencyjnych, dzięki czemu zmniejszyły się wymagania dotyczące sceny. Innym podejściem jest wykorzystanie zależności geometrycznych w przestrzeni obiektu, podobnie jak w algorytmach klasy **OI** opisywanych w poprzednim podrozdziale. I tak, w [105] warunek współliniowości punktu i jego projekcji znany z **OI** został uzupełniony o warunek współpłaszczyznowości prostych i ich projekcji. Dzięki temu możliwe było sformułowanie układu równań kalibracji mieszanej tzn. np. wymagające dwóch par punktów i jednej pary linii. Warta wspomnienia jest praca [106] w której do reprezentacji rotacji używa się kwaternionów

jednostkowych, które wymuszają ortogonalność macierzy rotacji i polepszają proces optymalizacji.

2.3.3 Wyznaczanej transformacji względnej – estymacja ruchu kamery

2.3.3.1 Detekcja i interpretacja informacji w obrazie

W przypadku algorytmów kalibracji względnej, relacje wymagane w procesie kalibracji dotyczą dwóch projekcji sceny w kolejnych chwilach czasowych. Sformułowanie zadania w przestrzeni obrazu, bez odniesienia do wiedzy o scenie w **GCS** zawęża opisywany problem do problemu korelacji dwóch obrazów. Stąd w odniesieniu do relacji między kolejnymi chwilami czasowymi możemy wyróżnić dwa przypadki: zupełnie nieznaną sceny w której znajdowanie zależności opiera się na lokalnych cechach obrazu i sceny, w których znajduje się znany obiekt – w tym przypadku relacja polega na detekcji tego obiektu w dwóch chwilach czasowych. Wynikiem analizy, podobnie jak w przypadku algorytmów kalibracji bezwzględnej jest znalezienie par punktów lub prostych charakterystycznych.

2.3.3.1.1 Nieznana scena

Techniki znajdowania relacji pomiędzy projekcjami sceny w kolejnych chwilach czasowych są podobne do tych używanych w algorytmach wykonujących syntetyczną projekcję modelu opisywanych w poprzedniej części pracy. Przewagą rozwiązań wyznaczających transformację względną jest mniejsza czułość na oświetlenie sceny, o ile jest ono zbliżone w kolejnych chwilach czasowych. Podobnie jak w algorytmach kalibracji bezwzględnej, do znajdowania relacji między obrazami w kolejnych chwilach czasowych wykorzystuje się deskryptory obrazu. Przykładem może być praca [107], w której kalibracja na podstawie odpowiadających sobie punktów w kolejnych klatkach poruszającego się robota, które znajdowane są za pomocą algorytmu wykorzystującego cechy SIFT. W ostatnich latach istotną rolę w zadaniach tego typu zaczęły odgrywać rozwiązania bazujące na modelach neuronowych, które wykorzystywane są do wstępnego przetwarzania obrazu jak w pracy [108] gdzie sieci splotowe zostały wykorzystane do zwiększenia kontrastu zdjęć. Innym przykładem jest, zaprezentowany w pracy DeTone [109] algorytm, który na obrazie z i -tej chwili czasowej wyszukuje cztery punkty odpowiadające arbitralnie wybranym punktom z chwili $(i-1)$ -szej. Modyfikacje algorytmu z pracy DeTone wykorzystywane były w opisywanych wcześniej metodach znajdowania relacji

opartych o reprojekcję do widoku referencyjnego. Mimo wielu zalet, wśród których warto odnotowania jest mała zależność od informacji a priori w scenie i duża odporność na błędy detekcji, użycie algorytmów tej grupy często ograniczone jest do ruchomej kamery w scenach statycznych. Dzieje się tak dlatego, że w scenach dynamicznych w wielu przypadkach niemożliwe jest odróżnienie zmian w obrazie wynikających z ruchu detektora od zmian wynikających z ruchu elementów sceny.

2.3.3.1.2 Znany obiekt

Ograniczenie wynikające z nieznaności sceny można pokonać, gdy dostępna jest choćby częściowa wiedza o scenie lub jej fragmencie. Metody tej klasy dzielą się na dwie grupy. Pierwszą z nich są metody wykrywające znany obiekt w scenie, w którym zaczepiony jest globalny układ współrzędnych. Jedną z metod tej grupy zaprezentowano w pracy [110], która skupia się na detekcji obiektów niezależnie od wzajemnego położenia obiektu i detektora. W jednym z rozdziałów pracy autorzy zaproponowali metodę wyznaczania względnej transformacji między widokami na podstawie zniekształceń znanego obiektu, jakie zaobserwowano w kolejnych chwilach czasowych. Drugą grupą są metody, w których a-priori wiadomo, które elementy sceny są nieruchome. Możliwe jest wtedy ograniczenie procesu detekcji i interpretacji wyników tylko i wyłącznie do pewnych fragmentów obrazu. Przykładem może być rozwiązanie z pracy [111], w której autorzy ograniczają detekcję do punktów charakterystycznych boiska do koszykówki oraz rzutów środków ciężkości zawodników na płaszczyznę boiska. Współrzędne rzutów środków ciężkości, wykrywane przez algorytm oparty na sieciach splotowych, wykorzystywane są jedynie w drugim etapie kalibracji do zawężania liczby znalezionych rozwiązań.

2.3.3.2 Rozwiązanie zredukowanego problemu

2.3.3.2.1 Punkt-Punkt

Rozwiązania prezentowane w tym podrozdziale należą do grupy algorytmów Point Relative Pose Problem. Rozwój metod tej grupy zapoczątkował Longuet-Higgins [112] który zaproponował analityczne rozwiązanie bazujące na rozwiązaniu równania macierzowego. W prezentowanej przez niego metodzie wymagane było zdefiniowanie 8 par 2D-2D punktów charakterystycznych. Dla liczby punktów mniejszej niż 8 nie istnieje jednoznaczne rozwiązanie używające metod liniowych i równań macierzowych. Jak pokazano w [113], dla pięciu punktów

istnieje 10 możliwych rozwiązań problemu transformacji względnej. Rozwiązaniem okazało się przejście do równań nieliniowych jak na przykład w pracy [114], w której używany jest wielomian dziesiątego stopnia, lub w pracy [115], gdzie parametryzacja macierzy transformacji między dwoma układami lokalnymi detektora, sprowadziła problem do układu dziewięciu równań kwadratowych. Przykłady te pokazują, że w ogólnym przypadku problem znalezienia transformacji względnej wymaga wykrycia większej ilości informacji na obrazie i jest bardziej złożony niż problem wyznaczania transformacji bezwzględnej ze znanym modelem sceny. Badania prowadzone w ostatnich latach przez zespół dr Kavetha Fathiana, pokazują, że użycie opisu kwaternionowego zarówno w rozwiązaniach analitycznych jak i iteracyjnych zmniejsza liczbę informacji potrzebnych do wyznaczenia transformacji między układami i poprawia uwarunkowanie numeryczne problemu. W pracy [116], autorzy udowodnili, że zastosowanie kwaternionów pozwala na iteracyjne wyznaczenie **kalibracji zewnętrznej** w szybszy i bardziej niezawodny sposób. W pracy [117], autorzy przedstawili analityczne rozwiązanie problemu **kalibracji zewnętrznej** przy użyciu kwaternionów, a w pracy [118] pokazali możliwe zastosowanie algorytmów linearyzacji [119] w rozwiązaniu tego zadania. Rozwój algorytmów wykorzystujących głębokie sieci neuronowe sprawił, że wśród rozwiązań wyznaczających transformację względną można znaleźć również rozwiązania przy użyciu tych sieci, które mają postać czarnej skrzynki. Przykładem może być praca [108], w której do wyznaczania transformacji względnej użyto sieci neuronowej, w której do połączonych równolegle dwóch warstw splotowych klasyfikatora alex-net [120] dołączono warstwę wyznaczającą transformację. Mimo dobrych wyników rozwiązanie potrzebuje około 60 000 par obrazów w procesie uczenia, a czas obliczeń jest rząd wielkości większy niż przy rozwiązaniach analitycznych.

2.3.3.2.2 Prosta-Prosta

Wyznaczanie transformacji względnej między obrazami w kolejnych chwilach czasowych w oparciu o relacje linia-linia są o wiele mniej popularne niż rozwiązania bazujące na punktach czy rozwiązania wyznaczające transformacje bezwzględną. Wśród prac warto wymienić pracę [121], w której autorzy wyznaczają transformację względną dwukrotnie rozwiązując problem transformacji bezwzględnej. Pełny opis wyznaczenia transformacji bezwzględnej można natomiast znaleźć w pracy [122], którzy wprowadzają uogólnienie metody **RPnL** pozwalające na obliczenia transformacji względnych. W obu przypadkach wymagana jest duża ilość informacji w scenie a problem nie ma jednoznacznego i prostego rozwiązania.

2.3.4 Opis wybranych metod użytych w pracy

2.3.4.1 Detekcja i interpretacja informacji w obrazie

2.3.4.1.1 Transformata Haara

Transformata Haara [123] jest przedstawicielem rodziny przekształceń, które wykorzystują kodowanie dowolnej funkcji za pomocą sumy ważonej funkcji, zwanych falkami. Falki (**ang. wavelet**) to rodziny funkcji wyprowadzane z funkcji macierzystej za pomocą skalowania i przesunięcia. Pomiędzy falką a funkcją macierzystą zachodzi relacja (równanie 2.3.1).

$$\psi_{j,k}(x) = \psi(2^j \cdot x + k) \quad (\text{równanie 2.3.1})$$

Gdzie ψ to funkcja macierzysta, a $\psi_{j,k}$ to falka o przesunięciu k i skali j . Aproksymacja funkcji za pomocą średniej ważonej falek ma postać pokazaną w równaniu (równanie 2.3.2).

$$f(x) = \sum_j \sum_k c_{j,k}(x) \cdot \psi_{j,k}(x) \quad (\text{równanie 2.3.2})$$

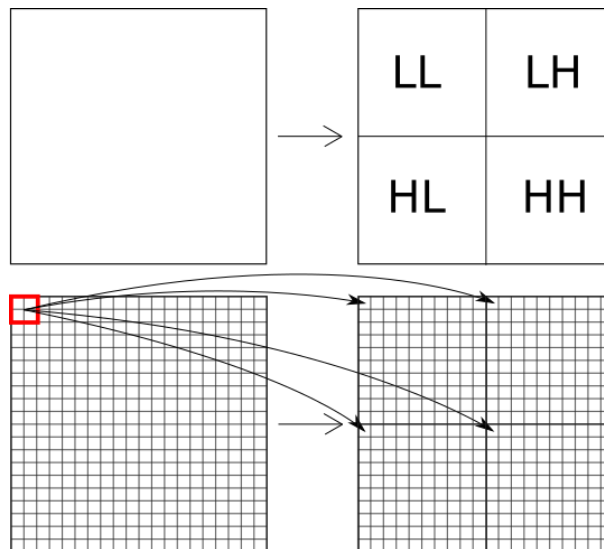
gdzie $c_{j,k}$ jest wyznaczoną wagą falki $\psi_{j,k}$. Postać szeregu przedstawionego w (równanie 2.3.2) jest podobna do rozwinięcia Fouriera, w którym rolę skali i przesunięcia pełnią częstotliwości funkcji trygonometrycznych sinus i cosinus. Funkcja macierzysta może przybierać różne formy. Użyta w przekształceniu Haara ma postać pokazaną poniżej (równanie 2.3.3).

$$\psi(x) = \begin{cases} -1 & \text{dla } x \in (0, \frac{1}{2}) \\ 1 & \text{dla } x \in [\frac{1}{2}, 1) \\ 0 & \text{dla } x \in R \setminus (0,1) \end{cases} \quad (\text{równanie 2.3.3})$$

Aproksymacje za pomocą falki Haara wykorzystuje się w algorytmach kompresji obrazów. W pracy [124] pokazano algorytm dekompozycji obrazu na składowe o różnej rozdzielczości. Każdy obraz rozbijany jest na cztery składowe. Wartości pikseli każdej składowej obliczane są na podstawie macierzowej wersji transformaty Haara, opracowanej w [125] (równanie 2.3.4).

$$\begin{bmatrix} a' & b' \\ c' & d' \end{bmatrix} = \frac{1}{2} \cdot \begin{bmatrix} a + b + c + d & a - b + c - d \\ a - b - c + d & a - b - c + d \end{bmatrix} \quad (\text{równanie 2.3.4})$$

Wartości a', b', c', d' wpisywane są kolejno w cztery ćwiartki obrazu jak pokazano na rysunku (Rysunek 2.11).




Rysunek 2.11 Ideowa reprezentacja dekompozycji Haara obrazu

Po przeprowadzeniu obliczeń dla każdego piksela za pomocą (równanie 2.3.4) obraz zostaje rozbity na cztery składowe, które przenoszą informacje o różnych częstotliwościach:

- LL – wartości średnie pikseli – odpowiednik filtra dolnoprzepustowego dla kolumn i wierszy,
- HL – wartości średnie w wierszach, różnice dla kolumn – odpowiednik filtra, dolnoprzepustowego dla wierszy i górnoprzepustowego dla kolumn,
- LH – wartości średnie w kolumnach, różnice dla wierszy – odpowiednik filtra, górnoprzepustowego dla wierszy i dolnoprzepustowego dla kolumn,
- HH – różnice w wierszach i kolumnach.

Obraz powstały po transformacji przenosi jednocześnie informacji o średnich (LL), krawędziach poziomych (LH), krawędziach pionowych (HL) i krawędziach diagonalnych (HH). Przykład przekształcenia pokazano na rysunku (Rysunek 2.12).



Rysunek 2.12 Przykład dekompozycji z wykorzystaniem transformaty Haara na obrazie Lena512. Obliczenia wykonane za pomocą biblioteki OpenCV [126]


Transformata Haara została wykorzystana w autorskim algorytmie przetwarzania wstępnego obrazów linii boiska. Algorytm ten zostanie opisany w dalszej części rozdziału poświęconej opracowanym metodom i algorytmom.

2.3.4.1.2 Transformata Hougha dla linii

Transformata Hougha [127] jest szczególnym przypadkiem transformaty Radona [128], w której współrzędne pikseli u, v mapowane są na n -przestrzeń cech (**ang. feature space**) odpowiadającą obiektom które chcemy wykryć na obrazie. W przypadku transformaty mającej na celu znalezienie informacji o liniach w obrazie, przestrzeń cech związania jest z równaniem prostej (równanie 2.3.5).

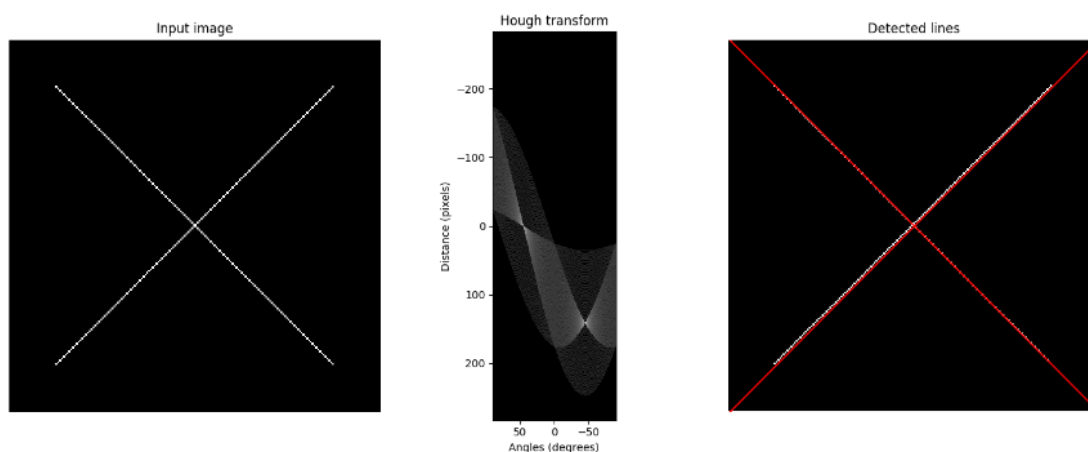
$$u \cdot \cos(\theta) + v \cdot \sin(\theta) = \rho \quad (\text{równanie 2.3.5})$$

Gdzie θ, ρ nazywane są współzrędnymi biegunowymi opisującymi prostą. Mapowanie Hougha współzrędných u, v polega na znalezieniu wszystkich wartości θ, ρ spełniających równanie (równanie 2.3.5), co odpowiada krzywej w przestrzeni cech (Rysunek 2.13).



Rysunek 2.13 Postać biegunowa prostej oraz reprezentacja pojedynczej pary u, v w przestrzeni cech

Wykonanie opisanej powyżej czynności dla wszystkich pikseli obrazu, których wartość jest niezerowa i dodanie do siebie odpowiadających im krzywych prowadzi do powstania swoistej **mapy prawdopodobieństwa**. (Rysunek 2.14).



Rysunek 2.14 Mapa prawdopodobieństwa dla linii na obrazie [129]

Analiza mapy prawdopodobieństwa pozwala na wykrycie linii w obrazie. Mapa prawdopodobieństwa ma jeszcze jedną interesującą właściwość – wykryte na obrazie linie dane są w postaci analitycznej (we współrzędnych biegunowych). Przy znanych układach i wzajemnych relacjach linii możliwe jest wyszukiwanie określonych wzorców. Cecha ta została wykorzystana w autorskim algorytmie dopasowywania obszaru zainteresowania **ROI (ang. region of interest)** opracowanym w ramach niniejszej pracy i opisanym w kolejnym rozdziale.

2.3.4.2 Rozwiązywanie relacji punkt-punkt

2.3.4.2.1 Algorytm EPnP

W aplikacjach powstałych w ramach niniejszej pracy problem kalibracji zewnętrznej rozwiązywano stosując podejście hybrydowe, analityczno-iteracyjne, w którym warunki początkowe algorytmu iteracyjnego wyznaczane były w poprzedzającym go kroku analitycznym. Wśród metod opisywanych w poprzedniej części rozdziału, algorytm **EPnP** zaproponowany w 2009 roku przez Lepetit [82] został wybrany jako bazowy algorytm analityczny. Wyboru dokonano ze względu na następujące cechy:

1. metoda pozwala wyznaczać kalibrację zewnętrzną na podstawie małej liczby punktów,
2. metoda ma porównywalną złożoność obliczeniową niezależnie od liczby punktów.

W szczególności druga cecha jest niewątpliwą zaletą w odniesieniu do projektowanych w tej pracy rozwiązań wyznaczających kalibrację zewnętrzną w czasie rzeczywistym. Dzieje się tak dlatego, że w algorytmie **EPnP** wyznaczanie pozycji i orientacji kamery opiera się na rozwiązywaniu problemu zdefiniowanego dla **wirtualnych punktów kalibracyjnych**, których liczba jest stała niezależnie od liczby punktów kluczowych wykrytych w scenie. W ogólnym przypadku potrzebne są cztery nie współpłaszczyznowe relacje 3D-2D punktów wirtualnych, a przypadku, gdy na obrazie z kamery można wyróżnić płaszczyznę, wystarczą trzy takie zależności. Sam algorytm zaś dzieli się na następujące etapy:

1. wyznaczanie punktów wirtualnych i wag kombinacji liniowej,
2. wyznaczenie macierzy projekcji **VPP** do **IS** opisującej przekształcenie punktów wirtualnych,
3. znalezienie współrzędnych punktów wirtualnych w lokalnym układzie współrzędnych kamery,
4. opcjonalne użycie algorytmu iteracyjnego w celu poprawienia uzyskanego wyniku,
5. wyznaczenie pozycji i orientacji kamery na podstawie relacji 3D-3D pomiędzy współrzędnymi punktów wirtualnych w układzie współrzędnych kamery a współrzędnymi punktów wirtualnych w globalnym układzie współrzędnych.

2.3.4.2.1.1 Wyznaczanie punktów wirtualnych

Punkty wirtualne mogą być zdefiniowane dowolnie, jednak autorzy algorytmu powołując się na pracę [130], proponują następującą metodę definiowania punktów wirtualnych:

- pierwszy punkt zdefiniowany jest w środku ciężkości punktów kluczowych sceny,
- wyznaczone są kierunki wiodące w zbiorze punktów charakterystyczny. Można je wyznaczyć stosując na przykład analizę **PCA** [131],
- na podstawie kierunków wiodących wyznacza się bazę przestrzeni liniowej,
- kolejne punkty (dwa dla przypadku płaskiego, trzy dla ogólnego) wyznaczone są poprzez przesunięcie pierwszego punktu o kolejne wektory bazy.

Następnie każdy z punktów kluczowych jest zapisywany jako średnia ważona punktów wirtualnych (równanie 2.3.6):

$$p_i = \sum_{j=1}^4 \alpha_{ij} \cdot c_j \quad (\text{równanie 2.3.6})$$

$$\sum_{j=1}^4 \alpha_{ij} = 1$$

Gdzie p_i to i -ty punkt kluczowy, c_j to j -ty punkt wirtualny a α_{ij} to współczynnik kombinacji liniowej wyznaczania i -tego punktu kluczowego na podstawie j -tego punktu wirtualnego.

Wagi α_{ij} mogą być zdefiniowane jako uogólnione współrzędne barycentryczne punktu p_i w bazie $[c_1, c_2, c_3, c_4]$.

W związku z tym, że przekształcenie pozycji punktów w globalnym układzie współrzędnych do pozycji w lokalnym układzie kamery jest transformacją ciała sztywnego, wagi α_{ij} pozwalają wyznaczyć współrzędne punktów w układzie lokalnym kamery na podstawie współrzędnych punktów wirtualnych w tymże układzie.

2.3.4.2.1.2 Wyznaczanie macierzy projekcji

Zależność opisana powyżej pozwala zapisać projekcję punktów kluczowych (równanie 2.1.5) za pomocą projekcji punktów wirtualnych (równanie 2.3.7):

$$s_i \cdot \begin{bmatrix} u_i \\ v_i \\ 1 \end{bmatrix} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \cdot \sum_{j=1}^4 \left(\alpha_{ij} \cdot \begin{bmatrix} x_j \\ y_j \\ z_j \end{bmatrix} \right) \quad (\text{równanie 2.3.7})$$

Ostatni wiersz równania macierzowego pozwala zapisać zależność wiążącą współczynnik skali ze współrzędną z punktu wirtualnego (równanie 2.3.8).

$$s_i = \sum_{j=1}^4 (\alpha_{ij} \cdot z_j) \quad (\text{równanie 2.3.8})$$

Po odjęciu od pozostałych dwóch wierszy równania (równanie 2.3.7) równania (równanie 2.3.8), dla każdej projekcji punktu kluczowego (u_i, v_i) powstaną dwa równania (równanie 2.3.9).

$$\sum_{j=1}^4 \alpha_{ij} \cdot f_x \cdot x_j + \alpha_{ij} \cdot (c_x - u_i) \cdot z_j = 0$$

$$\sum_{j=1}^4 \alpha_{ij} \cdot f_y \cdot x_j + \alpha_{ij} \cdot (c_y - v_i) \cdot z_j = 0 \quad (\text{równanie 2.3.9})$$

Po uwzględnieniu równań (równanie 2.3.9) dla wszystkich punktów kluczowych możliwe jest zdefiniowanie równania macierzowego, podobnie jak w metodzie DLT opisywanej we wcześniejszej części pracy (równanie 2.3.10).

$$Mx = 0 \quad (\text{równanie 2.3.10})$$

gdzie M jest macierzą o wymiarze $2n \times 11$ (gdzie n to liczba punktów kluczowych), a $x = [c_1^T, c_2^T, c_3^T, c_4^T]^T$ jest dwunastoelementowym wektorem współrzędnych wirtualnych punktów kalibracyjnych wyrażonych w lokalnym układzie współrzędnych kamery.

Układ ten ma dwanaście niewiadomych. Jego rozwiązania zaś są wyznaczane na podstawie analizy właściwości macierzy M .

2.3.4.2.1.3 Znalezienie współrzędnych punktów wirtualnych

Rozwiązanie równania należy do jądra macierzy M i ma postać pokazaną w (równanie 2.3.11).

$$x = \sum_{i=1}^N (\beta_i \cdot v_i) \quad (\text{równanie 2.3.11})$$

gdzie v_i są wektorami własnymi odpowiadającymi zerowym (lub zbliżonym do zera w rzeczywistych warunkach) wartościom własnym macierzy M , a współczynniki β_i są współczynnikami, które można wyznaczyć analitycznie. Liczba wektorów własnych N należy do przedziału $[1,4]$ i zależy od ogniskowej kamery i stopnia zaszumienia danych.

W zależności od N autorzy algorytmu proponują cztery procedury prowadzące do rozwiązania problemu bazujące na odległościach między punktami. Wiadomo, że odległości między

punktami wirtualnymi w lokalnym układzie współrzędnych kamery są równe odległościom między znanymi punktami w globalnym układzie współrzędnych. I tak dla:

1. dla $N = 1$ współczynniki β_i są wyznaczone jako stosunek odległości między punktami w globalnym układzie współrzędnych a odległościami między wektorami własnymi
2. dla $N = 2$ i $N = 3$ równanie przyjmuje bardziej złożoną formę a do jego rozwiązania stosowana jest technika linearyzacji z pracy [132],
3. dla $N = 4$ równanie rozwiązywane jest w oparciu o technikę linearyzacji z pracy [119].

Liczba wektorów własnych N w rzeczywistych zastosowaniach nie jest znana, gdyż macierz M ma same niezerowe wartości własne (część z nich jest bardzo mała). W praktyce obliczane są rozwiązania dla wszystkich wartości N a ostateczne rozwiązanie wybierane jest w sposób, który minimalizuje błąd reprojekcji (równanie 2.2.24), (równanie 2.2.21).

2.3.4.2.1.4 Poprawienie uzyskanego wyniku

Wspomniany powyżej błąd reprojekcji może być użyty jako miara funkcji celu w algorytmach optymalizacji nieliniowej. Autorzy algorytmu **EPnP** proponują zastosowanie optymalizacji Gaussa-Newtona, które pozwala na bardziej precyzyjne wyznaczenie współrzędnych punktów wirtualnych w lokalnym układzie współrzędnych kamery.

Samo wyznaczanie kalibracji zewnętrznej przeprowadzone jest w oparciu o czteropunktową realizację algorytmu **PnP** (P4P), która zaproponowana została w pracy [132].

2.4 Korekcja wyznaczania środka znaczników sferycznych i kołowych

2.4.1 Wprowadzenie


Obiekty o kształcie sfery i okręgu obecne są w wielu dziedzinach związanych z widzeniem maszynowym i śledzeniem 3D. Pełnią rolę:

- wzorców kalibracyjnych jak pokazano na przykład w pracy [133], w której kalibracja kamery wykonywana jest w oparciu o jedno zdjęcie, na którym widać przynajmniej trzy sfery,
- znaczników 3D, które śledzone są przez system. Jednym z zastosowań znaczników sferycznych jest praca [134], w której śledzony jest ruch nadgarstka podczas wykonywania codziennych czynności,
- znaczników używanych w płaskich wzorcach kalibracyjnych jak w pracy [135] lub w pracy [24], w której znaczników kołowych używa się do kalibracji systemu operującego w podczerwieni,
- śledzonych obiektów, jak na przykład w pracy [136], opisującej śledzenie piłki tenisowej.

W odniesieniu do obiektów sferycznych, zarówno w procesie śledzenia jak i w procedurze kalibracji, punktem, którego współrzędne są wyznaczane, jest środek sfery. Niestety, zadanie wyznaczenia współrzędnych obrazu środka sfery w **IS** często jest utrudnione. Dzieje się tak dlatego, że obrazem sfery i okręgu w przestrzeni **IS** jest elipsa [137], której środek w większości przypadków jest przesunięty względem obrazu środka sfery o nieznaną, niezerową wielkość. Wielkość ta, opisana w pracy [138], będąca odległością pomiędzy środkiem elipsy a obrazem środka sfery nazywana jest **błędem ekscentryczności (ang. eccentricity error)**. Jak pokazano w pracy [139], błąd ten może mieć znaczący wpływ na dokładność śledzenia w wielu praktycznych zastosowaniach tj. np. wyznaczanie przesunięcia obiektu w dwóch chwilach czasowych.

2.4.2 Błąd ekscentryczności

Zdefiniujmy kamerę, opisaną za pomocą modelu kamery otworkowej. Odwzorowanie obiektu sferycznego przez kamerę opisaną tym modelem pokazuje rysunek (Rysunek 2.15).




Rysunek 2.15 Odzworowanie obiektu sferycznego przez kamerę otworkową. NP – środek projekcji, S – odwzorowywana sfera, S' – obraz sfery (elipsa), O – środek sfery, O' – obraz środka sfery, O'' – środek obrazu sfery (środek elipsy)

Obraz sfery S jest wyznaczony przez zbiór przecięć prostych stycznych do sfery z płaszczyzną projekcji PP . Przecięcia wyznaczają elipsę S' , której środek O'' może być wykryty na obrazie przy użyciu algorytmów widzenia maszynowego. Obraz środka sfery O' znajduje się na prostej łączącej O'' z obrazem środka projekcji NP' . Błąd ekscentryczności jest wyrażony za pomocą odległości pomiędzy obrazami O' i O'' .

O błędzie ekscentryczności można mówić również w odniesieniu do relacji geometrycznych. Zbiór prostych stycznych do sfery S wyznacza stożek eliptyczny o ognisku w punkcie NP i osi k będącej prostą przechodzącą przez punkty NP i O' . W stożku można wyróżnić również prostą k' przechodzącą przez NP i O'' . Obraz sfery S jest krzywą stożkową będącą przecięciem zdefiniowanego powyżej stożka i płaszczyzny projekcji PP . Przy tej formie opisu błąd ekscentryczności wyrażony może być za pomocą kąta między prostymi k i k' .

Perspektywiczny błąd ekscentryczności jest geometrycznym błędem *radialnym*, czyli takim, którego wartość zależy od położenia elipsy S' względem obrazu środka projekcji (Rysunek 2.16).



Rysunek 2.16 Przykładowe obrazy sfer o różnym promieniu w odniesieniu do położenia względem obrazu środka projekcji

Należy również wspomnieć, że bezwzględna wartość błęd ekscentryczności zależy również od wielkości elipsy, która jest obrazem sfery. Im większa jest elipsa, tym błąd ekscentryczności jest większy. Na przykład dla detektora, którego obiektyw ma ogniskową 6 mm (a takie obiektywy używane są w systemie wspomagającym decyzje sędziowskie będącym jednym z wdrożeń przeprowadzonych w ramach niniejszej pracy) przy krawędziach obrazu błąd ekscentryczności może powodować przesunięcie wykrytego środka sfery o 0,5 px co w przypadku obiektów oddalonych o kilka metrów może skutkować pojawieniem się kilkumilimetrowego błęd śledzenia. Obecność takiego błęd w systemach, od których wymaga się, by śledziły obiekt z dokładnością wyrażoną w pojedynczych milimetrach nie może być dopuszczone.

2.4.3 Kompensacja błęd ekscentryczności


Spotykane w literaturze metody kompensujące błąd ekscentryczności wykorzystują wiedzę o kamerze i zależnościach geometrycznych w scenie. Wśród cech prezentowanych w kolejnych podrozdziałach metod warto wymienić:

- czas obliczeń – wśród prezentowanych metod znajdują się takie, które pozwalają na osiągnięcie wyników w czasie rzeczywistym oraz takie, w których wynik osiąga się po dłuższych obliczeniach,

- ilość potrzebnych informacji o scenie znanych a priori – cecha ta często ogranicza możliwe wykorzystanie metod wyłącznie do dobrze zdefiniowanych warunków laboratoryjnych,
- typ obiektów jakie można śledzić – niektóre metody służą do śledzenia jednego typu obiektu o ściśle określonych cechach,
- odporność na szумы występujące w pomiarach,
- skuteczność kompensacji – niektóre metody pozwalają na przybliżoną kompensację, inne pozwalają zredukować wpływ błędu ekscentryczności do pomijalnego poziomu.

2.4.3.1 Metody oparte o znajomość płaszczyzny obiektu

W metodach z tej grupy błąd ekscentryczności odnosi się do wyznaczania środków kołowych znaczników kalibracyjnych umieszczonych na płaskim wzorcu. W pracy [140], autorzy proponują rozwinięcie procedury kalibracji kamer o krok związany z korekcją błędu ekscentryczności. Modyfikacja dotyczy metody DLT opisywanej w sekcji 2.2.7.1 polega na analitycznym powiązaniu wartości błędu ekscentryczności z wyznaczanym w trakcie kalibracji równaniem płaszczyzny Π (Rysunek 2.17)



Rysunek 2.17 Relacje geometryczne wykorzystane w pracy Heikkila i Silven [8]. Π – płaszczyzna obiektu wyznaczana w procesie kalibracji.

Po uwzględnieniu wprowadzonej zależności autorzy proponują dwie metody rozwiązania zmodyfikowanego równania transformacji – wykorzystującą metody liniowe oraz rozwiązującą

globalne zadanie optymalizacji. Mimo, iż metoda nie wymaga znajomości a priori równania płaszczyzny, na której znajdują się znaczniki, to założenie współpłaszczyznowości znaczników kołowych ogranicza jej wykrozystywanie do metod kalibracji opartych na płaskim wzorcu.

Inną metodą, która wykorzystuje znajomość płaszczyzny, w której znajduje się okrągły znacznik jest algorytm opisany w pracy [141], gdzie korekcję błędu ekscentryczności wykonuje się w oparciu o znajomość wektora normalnego płaszczyzny wzorca. Współrzędne wektora wyznaczone są przy pomocy algorytmu kalibracji Zhanga. Warto zauważyć, że w tej pracy kompensacja błędu ekscentryczności nie jest uwzględniona w samej kalibracji, przez co procedura jest prostsza i łatwiejsza w implementacji. Z drugiej strony błędy kalibracji wynikające z nieuwzględnienia błędu ekscentryczności nie są eliminowane. Na koniec warto również wymienić wspomnianą wcześniej pracę [138], w której autorzy wyprowadzają kolejno wzory na zniekształconą elipsę S' , prostą k, k' , współrzędne punktu O, O' i O'' . Jest to rozwiązanie szybkie, w pełni analityczne, jednak w przeciwieństwie do poprzednich metod wymagające ściśle określonych warunków laboratoryjnych i precyzyjnie zmierzonej pozycji płaszczyzny obiektu, nazywanej w artykule płaszczyzną referencyjną.


2.4.3.2 Metody wykorzystujące przestrzeń Hougha

Prostą k , będącą osią symetrii stożka można wyznaczyć rozwiązując zadanie optymalizacji nieliniowej. Przykładem takiego podejścia jest praca [142], w której wykrywane są sfery referencyjne w scenach o niepełnym oświetleniu. W artykule zaproponowano zdefiniowanie trójwymiarowej dyskretnej przestrzeni Hougha stożków. Dwa pierwsze wymiary odpowiadają współrzędnym u, v w **IS**. Trzecim wymiarem jest kąt θ obliczany między prostymi przechodzącymi przez dany piksel i piksele krawędzi. Oznacza to że pojedynczemu pikselowi w obrazie odpowiada n punktów w przestrzeni Hougha, gdzie n jest liczbą pikseli krawędzi. W metodzie zaproponowano procedurę głosowania, w której po uwzględnieniu głosów wszystkich pikseli wybierany jest szukany stożek wyznaczony przez proste styczne do referencyjnej sfery. Zaletą metody jest mała ilość informacji wymagana w procesie kompensacji (jedynie parametry wewnętrzne kamery) i duża odporność na szумы (co jest charakterystyczne dla algorytmów opartych o głosowanie). Niestety dokładność metody zależy od poziomu dyskretyzacji a dla dużej liczby możliwych stożków czas obliczeń może być wydłużony. Innym przykładem wykorzystania przestrzeni Hougha jest praca [143], w której w celu przyspieszenia obliczeń definiuje się **hipotetyczną sferę (ang. hypothetical sphere)**,

która jest sferą zlokalizowaną na płaszczyźnie obrazu dającą taką samą projekcję jak sfera śledzona. W opisywanej metodzie niewiadomą jest promień **hipotetycznej sfery**. Niestety, autorzy nie opisują w jaki sposób wyznaczenie promienia hipotetycznej sfery pozwala na kompensację błędu ekscentryczności.


2.4.3.3 Metody wykorzystujące predefiniowany obiekt

W tych metodach wykorzystuje się obiekt złożony z wielu sfer/okręgów lub obiekt z naniesionymi dodatkowymi informacjami. Na przykład w pracy [144] zamiast wyznaczania środków elips, wyznacza się punkty charakterystyczne oparte o przecięcia stycznych w obiekcie płaskim złożonym z czterech jednakowych okręgów w układzie siatki (Rysunek 2.18). Autorzy dowiedli, że przekształcenie perspektywiczne nie zniekształca położenia tych punktów.



Rysunek 2.18 Siatka znaczników kołowych wykorzystywana w pracy Mateos i in (2000 [13]).

Innym przykładem może być praca [145], w której autorzy wykorzystują globus (sferę z naniesionymi południkami i równoleżnikami), aby wykonywać kalibrację kamery. Środek sfery jest wyznaczany na podstawie analizy przecięć południków i równoleżników (Rysunek 2.19).



Rysunek 2.19 Wykorzystanie południków i równoleżników do wyznaczania środka sfery [145].

2.4.3.4 Metody wykorzystujące równania parametryczne

W metodach tej grupy obiekt w przestrzeni trójwymiarowej opisuje się na pomocą równania parametrycznego. Później na tej podstawie wyprowadzane jest równanie parametryczne projekcji obiektu – elipsy. Przy znanej postaci równania elipsy rozwiązywany jest układ równań, co prowadzi do wyznaczenia środka sfery. Przykładem tego podejścia jest praca [146], w której autorzy na równania stożka złożonego z prostych stycznych do sfery wyznaczają parametryczne równanie elipsy będące jej projekcją zależne od trzech parametrów (równanie 2.4.1)

$$F(x, y, z) = \alpha x + \beta y + z - \gamma \sqrt{x^2 + y^2 + z^2} = 0$$

$$\alpha \left(\frac{u - u_0}{f_x} \right) + \beta \left(\frac{v - v_0}{f_y} \right) - \gamma \sqrt{\left(\frac{u - u_0}{f_x} \right)^2 + \left(\frac{v - v_0}{f_y} \right)^2} + 1 + 1 = 0 \quad (\text{równanie 2.4.1})$$

Wartości parametrów α, β, γ wyznaczone są metodą najmniejszych kwadratów na podstawie współrzędnych punktów leżących na elipsie na obrazie. Dzięki temu przy znanym promieniu sfery R są w stanie wyznaczyć współrzędne jej środka O rozwiązując układ (równanie 2.4.2).

Ta informacja służy później do kalibracji układu kamer przy użyciu asymetrycznego wzorca złożonego z kilku sfer.

$$\begin{aligned} \cos^2 p + \cos^2 q + \cos^2 r &= 1 \\ \alpha &= \frac{\cos p}{\cos r} \\ \beta &= \frac{\cos q}{\cos r} \\ \gamma &= \frac{\cos t}{\cos r} \end{aligned} \quad (\text{równanie 2.4.2})$$

$$\sin t = \sqrt{1 + \alpha^2 + \beta^2 - \gamma^2}$$

$$O = \left[R \frac{\cos p}{\sin t}, R \frac{\cos q}{\sin t}, R \frac{\cos r}{\sin t} \right]$$

2.4.3.5 Metody kompensujące błąd ekscentryczności – porównanie

	Metody z płaszczyzną	Przestrzeń Hougha	Predefiniowany obiekt	Równania parametryczne
Złożoność obliczeniowa	MAŁA	MAŁA/DUŻA	MAŁA	DUŻA
Informacje o scenie	Znana płaszczyzna	Nie wymagane	Znany obiekt	Nie wymagane
Typy obiektów	Okręgi	Okręgi /Sfery	Specjalne Okręgi /sfery	Sfery
Odporność na szumy	MAŁA	DUŻA	DUŻA	DUŻA
Skuteczność kompensacji	DUŻA	MAŁA/DUŻA	NIE	DUŻA

Metody, które pozwalają na korygowanie błędu ekscentryczności w czasie rzeczywistym wymagają wiedzy a priori o scenie lub są ograniczone tylko do wybranej klasy obiektów. Skuteczność metod wykorzystujących przestrzeń Hougha w wersji o małej złożoności może być niezadowalająca w aplikacjach wymagających dużych dokładności. Metody wykorzystujące równania parametryczne pozwalają na osiągnięcie dużych dokładności i nie wymagają wiedzy o scenie. Niestety, konieczność rozwiązywania nieliniowego zadania optymalizacji podczas wyznaczania równania elipsy zwiększa złożoność obliczeniową i ogranicza zastosowanie tych metod w aplikacjach wymagających korekcy w czasie rzeczywistym.

3 Koncepcja

3.1 Wprowadzenie

Opisane w poprzednim rozdziale metody pozwalają rozwiązać zadanie śledzenia obiektu w trójwymiarowej przestrzeni w wielu potencjalnych zastosowaniach. Nie zawsze jednak użycie istniejących algorytmów pozwala uzyskać z wystarczającą dokładność śledzenia. Ponadto, w niektórych zastosowaniach wykorzystanie procedur opisywanych w poprzedniej części pracy jest niemożliwe ze względu na dynamikę sceny, niedostatek danych pomiarowych lub obecność trudnych do modelowania zakłóceń. W badaniach prowadzonych w niniejszej pracy skupiono się na przypadkach, w których rozwiązanie problemu wymagało opracowania nowych algorytmów lub modyfikacji rozwiązań istniejących. W związku z aplikacyjnym charakterem pracy analiza wymagań i trudności zostanie przeprowadzona w odniesieniu do dwóch wdrożeń, które zrealizowano w trakcie prowadzonych badań. Były to:

- niskokosztowy skaner światła strukturalnego,
- system wspomagający decyzje sędziowskie w meczach piłki siatkowej.

Każdy z tych systemów zostanie szczegółowo opisany w rozdziale poświęconym aplikacjom. Poniżej pokazane zostaną główne jedynie cechy każdego z zastosowań i wyzwania, które były z nimi związane. Pozwoli to zdefiniować kontekst, w ramach którego prowadzone były prace.

3.1.1 Niskokosztowy skaner światła strukturalnego

Opisywany w dalszej części pracy skrótem **LCS** (ang. low-cost scanner) system składał się z jednej kamery i jednego projektora. Jego zadaniem był pomiar kształtu i barwy obiektów trójwymiarowych umieszczonych wewnątrz zdefiniowanej objętości pomiarowej. Zgodnie z wymaganiami, zaletą tego rozwiązania miał być niski koszt i prosta procedura kalibracyjna. Osiągnięto to używając taniej kamery, projektora i obiektywów, które jednocześnie kalibrowano geometrycznie, fazowo i barwnie na podstawie obrazów kalibracyjnych pochodzących z dwóch położenia wzorca. Główne wyzwania związane z tym wdrożeniem to:

- niewielka ilość danych kalibracyjnych,
- brak istniejącego wzorca, którego obraz pozwala na jednoczesną kalibrację geometryczną, fazową i barwną,

- powiązanie układu współrzędnych projektora z układem współrzędnych kamery – jednoczesna kalibracja obu urządzeń na podstawie tych samych zdjęć.

3.1.2 System wspomagający decyzje sędziowskie

Jest to drugi z systemów opisywanych w niniejszej pracy. W dalszej części pracy oznaczany będzie skrótem **VBS** (ang. Volleyball-system) Składał się z 14 kamer umieszczonych dookoła boiska, które skalibrowane były we wspólnym układzie współrzędnych. Jego zadaniem było śledzenie położenia piłki z częstotliwością 180 Hz i analiza trajektorii jej ruchu. To pozwalało dostarczyć sędziemu informacje o tym, w której części boiska odbiła się piłka, czy w trakcie jej ruchu zderzyła się z innym obiektem, czy też to na jakiej wysokości nad płaszczyzną boiska nastąpiło odbicie. Te informacje pozwalały podjąć sędziemu lepszą decyzję. Głównymi wyzwaniem, które pojawiły się podczas prac nad **VBS** były:

- konieczność re-kalibracji zewnętrznej w trakcie pracy systemu,
- duża dynamika sceny – zmienność oświetlenia, wielość ruchomych obiektów itp,
- mała ilość czasu, który można było poświęcić na obliczenia,
- duża liczba kamer, która wykluczała standardowe podejście stereo par, stereo-trójek,
- dane pomiarowe obarczone względnie dużymi błędami detekcji.

Z drugiej strony system operował w znanym środowisku, którym jest dobrze zdefiniowane boisko do piłki siatkowej. Warto wspomnieć, że w trakcie powstawania tej pracy prowadzone są badania nad drugą, komercyjną, wersją systemu **VBS**.

3.2 Schemat koncepcyjny systemu

Uwzględniając wymagania, jakie stawiały opisane powyżej wdrożenia, przeprowadzono analizę problemu śledzenia obiektu w trójwymiarowej przestrzeni. Pomimo różnic w charakterze danych, strukturach systemów i dziedzinach techniki, których dotyczyło wdrożenie, zauważono podobieństwa w samym procesie przetwarzania informacji pochodzących ze sceny. Te podobieństwa pozwoliły na abstrakcyjne zdefiniowanie problemów, które dotyczą różnych aspektów procesu śledzenia. Analiza charakteru tych problemów i wzajemnych zależności pomiędzy nimi pozwoliła opracować uogólniony modułowy system kalibracji, który w zależności od potrzeb można było modyfikować aby uzyskać:

- zwiększoną odporność na szумы,
- lepszą dokładność (mniejsze błędy pomiaru),
- mniejsze wymagania co do sceny pomiarowej.

Podział złożonego problemu na zbiór problemów składowych pozwolił w badaniach na:

- analizowanie i niezależne rozwijanie każdego z elementów składowych,
- używanie dotychczasowych wyników badań w kolejnych wdrożeniach,
- łatwiejsze utrzymanie i aktualizowanie oprogramowania,
- większą redundancję i zamienność części składowych,
- łatwiejszą lokalizację wielu spośród głównych źródeł niepewności,
- większą kontrolę nad procesem i możliwość ewaluacji wyników pośrednich.

W proponowanym schemacie ideowym oprócz elementów funkcjonalnych zdefiniowano przepływ sterowania i danych, a w szczególności informacji, którymi wymieniać się będą elementy funkcjonalne. Warto wspomnieć, że w rzeczywistych aplikacjach sukces wdrożenia zależy również od zdefiniowania nieopisywanych w pracy czynników, takich jak:

- interfejsy komunikacji między modułami (medium, w którym odbywa się przekazywanie informacji bezpośrednio związane z wykorzystywanymi urządzeniami lub typami programów komputerowych),
- typy danych i sygnałów, które przekazywane są pomiędzy modułami,
- szczegółowe wymagania dotyczące funkcjonalności i własności użytkowych każdego z modułów,

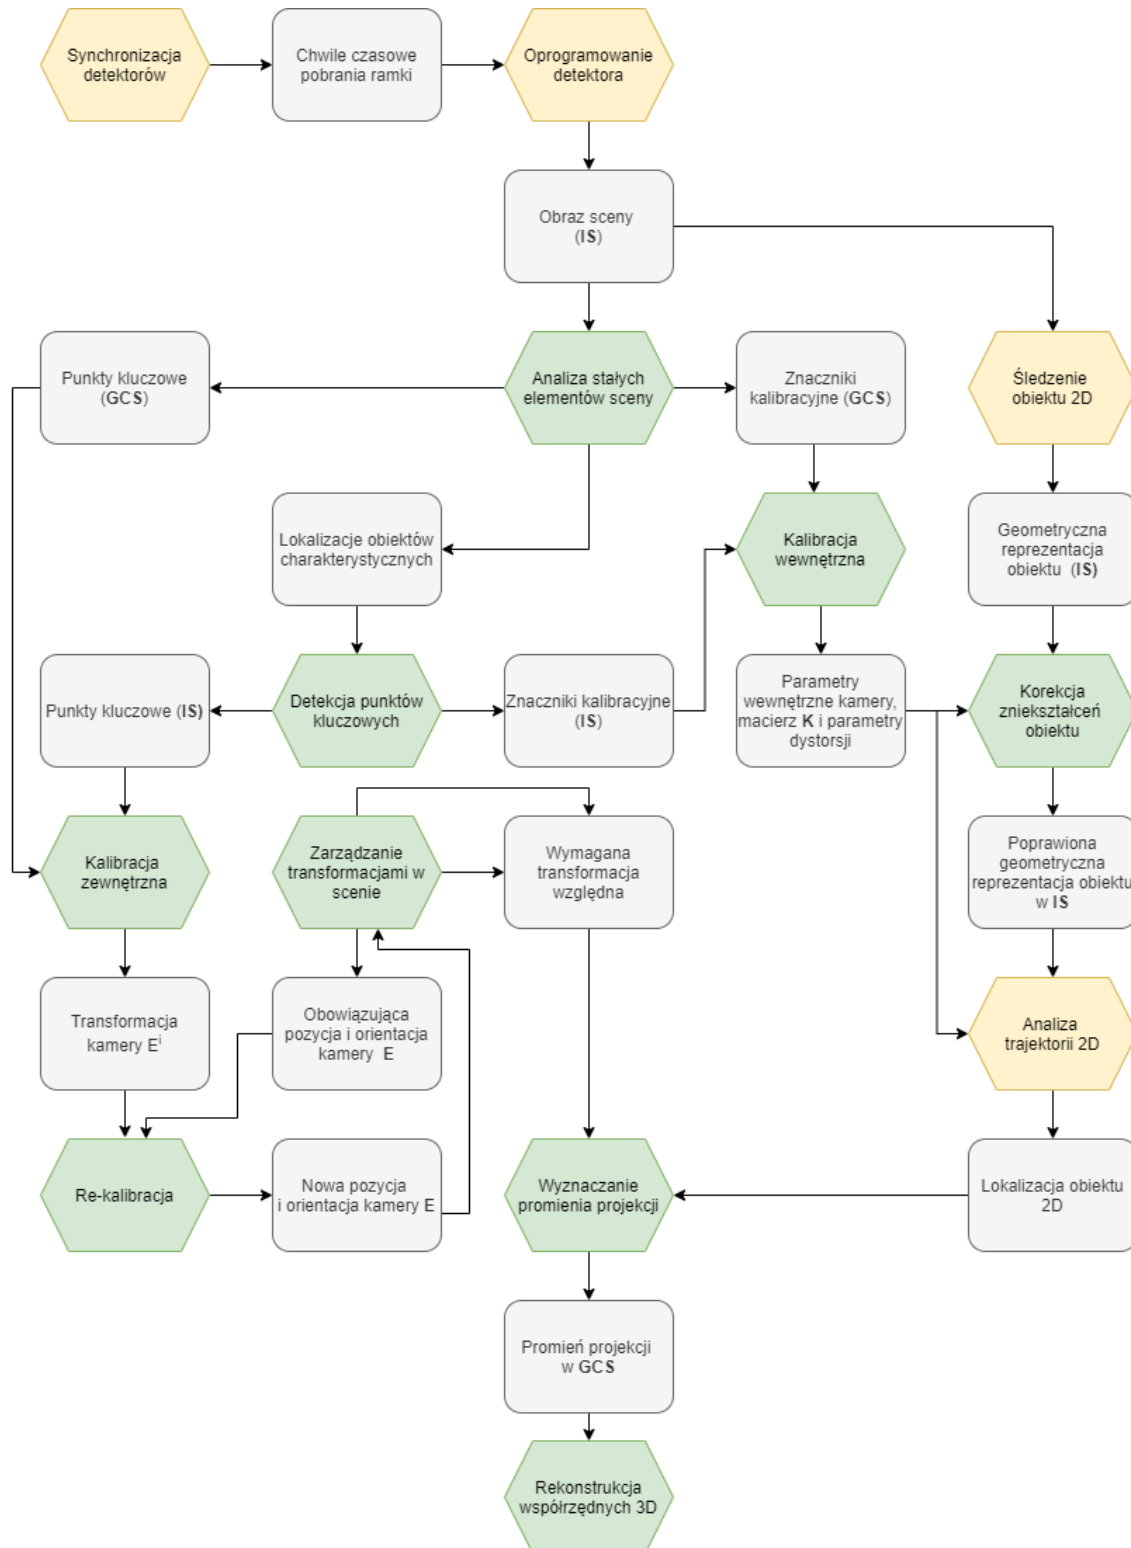
- referencyjne wyniki pośrednie – idealne wyjścia dla dobrze zdefiniowanych i przygotowanych wejść,
- środowiska i metody porównywania pośrednich wyników referencyjnych z wynikami otrzymywanymi przy użyciu implementowanych modułów.

Po uwzględnieniu tych czynników, w trakcie prowadzenia badań nad częściami składowymi systemu i wdrażania całościowych rozwiązań opracowano modułowy schemat systemu śledzenia, który pokazano na rysunku (Rysunek 3.1).

Elementy funkcjonalne tworzące system śledzenia zostały oznaczone na rysunku sześciokątami, wśród których na zielono pokolorowano te, które rozwijane były w ramach niniejszej pracy. Elementy funkcjonalne mogą być pogrupowane w następujące moduły:

1. Moduł akwizycji – jest to detektor wraz z oprogramowaniem oraz element odpowiedzialny za synchronizację zbierania ramek przez detektory.
2. Moduł zarządzania wiedzą o scenie – w jego skład wchodzi elementy odpowiedzialne za przechowywanie wiedzy a-priori o scenie i wykorzystywania jej do detekcji elementów kluczowych (najczęściej punktów) i ewaluacji wyników detekcji.
3. Moduł analizy sceny 2D – odpowiada za wykrywanie na obrazach detektora obiektów zdefiniowanych w module analizy wiedzy o scenie.
4. Moduł kalibracji wewnętrznej – odpowiadający za wyznaczenie parametrów wewnętrznych detektora, które służą do wyznaczenia przekształcenia **VPP** w **IS**.
5. Moduł kalibracji zewnętrznej i re-kalibracji – odpowiadający za wyznaczenie parametrów zewnętrznych detektora, które służą do wyznaczenia przekształcenia **GCS** w **VPP**.
6. Moduł zarządzania transformacjami – w nim zdefiniowane są układy współrzędnych i wzajemne zależności tych układów w analizowanej scenie. Dodatkowo moduł odpowiada za obsługę transformacji i transformacji odwrotnych prymitywów geometrycznych znajdujących się w scenie.
7. Moduł śledzenia obiektu 2D – odpowiadający za znalezienie geometrycznej reprezentacji (punktu, linii, elipsy) zdefiniowanej w **IS**. W skład modułu wchodzi analiza zmienności tła, wykrywania obiektu, filtracji szumów i wykrywania niepoprawnych detekcji. Działanie modułu opisane zostało w [147].

8. Moduł korekcji zniekształceń obiektu – odpowiadający za analityczną korekcję zniekształceń obiektu wynikającą z projekcji perspektywicznej. Jego działanie dotyczy zarówno zniekształceń obiektu jak i zniekształceń stałych elementów sceny.
9. Moduł analizy trajektorii 2D obiektu – ma za zadanie dopasowanie toru ruchu obiektu do znanego a-priori typu krzywej i na tej podstawie filtrowania i uzupełniania niepełnych wyników.
10. Moduł wyznaczający równanie promienia/promieni w **GCS** – moduł, który ma za zadanie integrować informacje pochodzące z kamer obecnych w systemie i na podstawie równań promieni projekcji wyznaczać równanie promienia w **GCS**.
11. Moduł integrujący dane z wielu detektorów – odpowiada za wyznaczanie szukanej lokalizacji obiektu w **GCS** w danej chwili czasowej na podstawie informacji, które pochodzą z wielu detektorów.



Rysunek 3.1 Modułowy schemat koncepcyjny systemu śledzenia. Zielonym kolorem zaznaczono elementy funkcjonalne, które były rozwijane w ramach pracy.. W blokach sześciokątnych znajdują się elementy funkcjonalne systemu, a w blokach prostokątnych typy danych, które są wymieniane.

3.2.1 Elementy systemu i wymagania

3.2.1.1 Moduł akwizycji

Moduł akwizycji składa się z dwóch elementów funkcjonalnych – części odpowiedzialnej za synchronizację wielu detektorów i części odpowiadającej za oprogramowanie detektora. Element odpowiedzialny za synchronizację ma za zadanie wysłać w odpowiednim czasie sygnał wyzwalający do detektorów w taki sposób, aby zebrały one obraz w tej samej chwili czasowej (z dokładnością do ustalonej tolerancji). Dzięki temu wiadomo, że położenie śledzonego obiektu w przestrzeni nie zmieniło się pomiędzy ujęciami kolejnych detektorów.

Element odpowiadający za obsługę pojedynczego detektora pozwala ustawić parametry detektora, zebrać ramkę / serię ramek i odczytać meta informacje (takie jak. np. temperatura matrycy) powiązane z zebrany obrazem.

Zdecydowana większość wymaganych funkcjonalności jest dostarczana w **API** (ang. application programming interface) twórców detektorów.

We wdrażanych systemach moduły zaimplementowano w następujący sposób:

- **LCS** – synchronizacja realizowana była w sposób naturalny, tj w obrazie z detektora widoczny był obraz w danej chwili wyświetlany przez projektor,
- **VBS** – synchronizacja realizowana była za pomocą dedykowanego układu elektronicznego, opracowanego przez członka zespołu badawczego. W drugiej wersji systemu wykorzystywane są sterowniki PLC.

3.2.1.2 Moduł analizy wiedzy o scenie

Procedura kalibracji, zarówno wewnętrznej jak i zewnętrznej, przeprowadzana jest w oparciu o korespondencje pomiędzy obiektami opisanymi w **GCS** a ich obrazami wykrytymi w **IS**. Co więcej, w wielu zastosowaniach wiedza a priori o obiektach, które mają być wykrywane, ich wzajemnej zależności, przybliżonym położeniu lub wzajemnych relacjach geometrycznych pozwala na szybszą i bardziej odporną na błędy sygnału wejściowego detekcję. W przypadku wzorców kalibracyjnych, których właściwości zmieniają się w czasie, konieczne są walidacja i pomiary ich geometrii. Podczas projektowania systemu przeprowadza się wiele eksperymentów, w których używa się różnych wzorców, różnych podzbiorów stałych elementów sceny i często różnych metod dopasowanych do dostępnych informacji. Moduł analizy wiedzy o scenie odpowiada za zarządzanie informacjami, które opisano powyżej.

Najczęściej przyjmuje on formę bazy danych, w której gromadzone są wszystkie informacje o scenie i wzorcach wraz z elementem, który pozwala na zdefiniowanie nowej sceny.

We wdrażanych systemach implementowany moduł przechowywał następujące informacje:

- **LCS** – przechowywanymi informacjami były: definicja geometryczna wzorca kalibracyjnego, referencyjne wartości barwne pól wzorca, definicje geometryczne przybliżonych położeń wzorca w kolejnych obrazach pomiarowych,
- **VBS** – w systemie wspierającym decyzje sędziowskie przechowywanymi informacjami były: definicje geometryczne wzorców (w trakcie badań używano dwóch wzorców kalibracyjnych), definicja geometryczna punktów charakterystycznych boiska, wstępne pozycje **ROI** dla każdego punktu charakterystycznego dla każdego z położeń kamery, położenia detektorów i przybliżone relacje geometryczne między osiami optycznymi par detektorów.

3.2.1.3 Moduł analizy 2D sceny

Opisywane w Rozdziale 2 metody kalibracyjne korzystają ze wstępnie przetworzonych informacji obecnych w obrazie sceny. Moduł analizy 2D sceny ma za zadanie przetwarzać obraz sceny w poszukiwaniu zdefiniowanej a priori wiedzy o scenie. Wynikiem takiego przetwarzania jest wyznaczenie obiektów charakterystycznych, najczęściej punktów kluczowych (**ang. keypoints**), które mogą być później analizowane w procesie kalibracji. Ważnymi cechami świadczącymi o jakości i funkcjonalności modułu są:

- dokładność wykrywania obiektów charakterystycznych (mierzona odległością między wykrytym obiektem a referencją w **IS**),
- powtarzalność,
- odporność procedury na zmienne warunki oświetlenia.

We wdrażanych aplikacjach rozwijanie metod analizy informacji w scenie realizowane było w następujący sposób:

- **LCS** – w czasie kalibracji analizowane były zdjęcia autorskiego wzorca kalibracyjnego. Konieczne było opracowanie metod mapowania wartości fazy i wyznaczania odpowiadających sobie par punkt-punkt pomiędzy pikselami kamery a projektora,

- **VBS** – w czasie działania systemu konieczne było uniezależnienie wyniku detekcji od zmiennych warunków oświetlenia. Ponadto konieczne było wykrywanie ruchu kamery i dopasowywanie położenia okna **ROI** (ang. region of interest). Opracowano algorytmy bazujące na transformacie Haara (zwiększanie kontrastu) i Hougha (adaptacja ROI).

3.2.1.4 Moduł kalibracji wewnętrznej

Niniejszy moduł ma za zadanie wyznaczyć obecną w równaniu (równanie 2.1.5) macierz **K** parametrów wewnętrznych kamery oraz towarzyszące jej współczynniki dystorsji. Moduł rozwiązuje zadanie kalibracji na podstawie wykrytych w IS obrazów znaczników kalibracyjnych. Znaczniki te odpowiadają elementom sceny, o których mamy wiedzę a priori, taką jak np. pozycja geometryczna znacznika w **GCS**. Warto zaznaczyć, że wykrywanie znaczników wykonywane jest w ramach modułu analizującego scenę w 2D. Definicja wzorca pozwalająca na wykrycie go w scenie i zawierająca wiedzę a-priori o znacznikach znajduje się jednak już w module zarządzającym kalibracją wewnętrzną. Moduł analizy obrazu sceny w razie potrzeby odpytuje moduł kalibracji o informacje konieczne do wyznaczenia położenia obrazów znaczników kalibracyjnych.

Cechami, które świadczą o spełnieniu wymagań dotyczących modułu są:

- dokładność kalibracji mierzona jako odległość algebraiczna między wykrytą a referencyjną macierzą kalibracji wewnętrznej. Dokładność ta może być sprawdzana podczas eksperymentów numerycznych, w których dla zdefiniowanych syntetycznych danych wejściowych oczekuje się określonych syntetycznych wyjść. Dokładność tak zdefiniowana nie może być sprawdzana podczas kalibracji rzeczywistych detektorów ze względu na brak danych referencyjnych. Możliwe jest natomiast określenie dokładności na podstawie porównania z inną, bardziej wyrafinowaną i wymagającą większej ilości informacji metodą kalibracyjną,
- powtarzalność kalibracji, która może być określana na podstawie analizy statystycznej rozkładów wartości poszczególnych elementów macierzy kalibracji. W systemach przenośnych i wykonujących kalibrację w czasie działania powtarzalność może być ważniejsza od dokładności. Dzieje się tak dlatego, że podczas działania systemu możliwe jest wprowadzenie dodatkowych kroków korygujących, które zbliżają wartości oczekiwane rozkładów do wartości referencyjnych,
- ilość wymaganych danych pomiarowych. Jest to cecha użytkowa, która często wyklucza możliwość zastosowania danej realizacji modułu w konkretnym

zastosowaniu. W jednej z aplikacji – **LCS** – modyfikacje istniejących algorytmów wprowadzane były w celu zmniejszenia wymaganej ilości danych kalibracyjnych i uproszczenia procedury kalibracji,

- stabilność mierzona za pomocą czułości wyników kalibracji na błędy skorelowane z poszczególnymi danymi wejściowymi. W **LCS** wyzwaniem było utrzymanie wymaganej stabilności działania modułu wraz ze zmniejszaniem ilości wymaganych danych pomiarowych.

Funkcje modułu kalibracji wewnętrznej w prezentowanych wdrożeniach realizowano w następujący sposób:

- **LCS** – w czasie kalibracji dane pomiarowe pochodziły z dwóch tylko położań autorskiego wzorca kalibracyjnego. Kalibrację wewnętrzną wykonano w oparciu o zmodyfikowaną kalibrację Zhanga (opisaną w poprzednim rozdziale). Modyfikacje miały na celu zmniejszenie ilości wymaganych danych pomiarowych przy zachowaniu założonej stabilności. Opracowane modyfikacje opisane są w dalszej części niniejszego rozdziału,
- **VBS** – w realizacji systemu wspomagającego decyzje sędziowskie możliwa była kalibracja geometryczna offline detektorów w laboratorium. Zdecydowano się na użycie pełnej metody Zhanga. Po instalacji systemu na boisku sprawdzano tylko za pomocą wzorca kalibracyjnego, czy parametry wewnętrzne detektora nie uległy zmianie.

3.2.1.5 Moduł kalibracji zewnętrznej i re-kalibracji

Wymagania co do elementów odpowiedzialnych za kalibrację wewnętrzną w przeciwieństwie do tych wyznaczających kalibrację wewnętrzną są ściśle związane z konkretnym zastosowaniem projektowanego systemu. Dzieje się tak, dlatego że informacje zawarte w kalibracji zewnętrznej określają położenie i orientację detektora w analizowanej scenie i podczas działania systemu. Podczas rozwiązywania zadania wyznaczania parametrów zewnętrznych zazwyczaj nie ma możliwości dostosowania ilości i rodzaju dostępnych danych.

Wyjątkami są:

- stacjonarne systemy laboratoryjne funkcjonujące w ściśle określonych warunkach,
- systemy w których globalny układ współrzędnych związany jest z jednym z detektorów, a wzajemne położenie detektorów jest ustalone na przykład za pomocą ograniczeń mechanicznych

W przypadku tych systemów kalibrację można wykonać w kontrolowanych warunkach laboratoryjnych. W pozostałych przypadkach trzeba brać pod uwagę charakter analizowanej sceny i zmiany położenia detektorów w trakcie działania systemu.

Podczas projektowania modułu kalibracji zewnętrznej warto brać pod uwagę następujące czynniki:

- wielkość objętości pomiarowej,
- zmienność warunków oświetlenia,
- obecność stałych, nieruchomych elementów sceny,
- możliwość wstępnego pomiaru geometrii,
- zmiany położenia detektora i czas w jakim należy dokonać korekty kalibracji,
- drgania i zakłócenia położenia występujące w pojedynczej pozycji detektora (na przykład związane z niską sztywnością obudowy urządzenia, wysokością statywu itp.).

O jakości realizacji funkcjonalności modułu świadczą, podobnie jak w przypadku modułu kalibracji wewnętrznej, następujące cechy:

- dokładność, która określa jak blisko pozycji i orientacji referencyjnej znajdują się pozycja i orientacja wyznaczone podczas kalibracji. W badaniach za miarę dokładności przyjęto odległość kartezjańską zdefiniowaną w następujący sposób (równanie 3.2.1).

$$d(\psi, \psi_{ref}) = |\psi^{-1}(P) - \psi_{ref}^{-1}(P)| \quad (\text{równanie 3.2.1})$$

gdzie ψ jest transformacją między **GCS** a lokalnym układem kamery opisaną w sekcji 2.1.3, ψ_{ref} jest transformacją referencyjną a P jest punktem znajdującym się w środku objętości pomiarowej. Podczas ewaluacji dokładności opracowywanych metod punkt P umieszczany był na osi Z lokalnego układu współrzędnych C_i kamery w odległości równej zakładanej odległości detektora od środka objętości pomiarowej. Następnie wyznaczano jego współrzędne w **GCS** z użyciem parametrów kalibracji zewnętrznej. Tak wyznaczone współrzędne były następnie porównywane z wartościami referencyjnymi. Warto zauważyć, że w przypadku danych syntetycznych referencyjna transformacja ψ_{ref} mogła być zastąpiona referencyjnym położeniem punktu P w **GCS** (P_{Gref}) (równanie 3.2.2).

$$d(\psi, P_{Gref}) = |\psi^{-1}(P) - P_{Gref}| \quad (\text{równanie 3.2.2})$$

Podobnie jak w przypadku kalibracji wewnętrznej dla danych rzeczywistych wyznaczanie dokładności możliwe jest na podstawie porównania rozpatrywanej metody z inną lub na podstawie dokładnie zmierzonej pozycji punktu referencyjnego w scenie,

- powtarzalność kalibracji, która może być określana na podstawie analizy statystycznej rozkładów współrzędnych punktów określających osie lokalnego układu współrzędnych C_i ,
- ilość wymaganych danych pomiarowych, która podobnie jak w przypadku kalibracji wewnętrznej jest ważną cechą użytkową metody,
- stabilność i odporność na zakłócenia danych wejściowych,
- czas obliczeń, który jest szczególnie istotny w zastosowaniach, gdzie kalibracja zewnętrzna wykonywana jest online w czasie rzeczywistym.

We wdrażanych aplikacjach metody związane z modułem kalibracji zewnętrznej rozwijane były w następujący sposób:

- **LCS** – w tej realizacji kalibracja zewnętrzna przeprowadzana była w oparciu o analizę punktów charakterystycznych na wzorcu kalibracyjnym, **GCS** był jednocześnie układem lokalnym kamery (co pokazane zostanie w dalszej części rozdziału),
- **VBS** – w systemie wspomagającym decyzje sędziowskie kalibracja zewnętrzna wykonywana była w oparciu o hybrydowe podejście łączące metodę EPnP z iteracyjnym algorytmem rozwiązującym problem optymalizacji nieliniowej. W trakcie badań opracowano autorską metodę re-kalibracji, która opisana zostanie w dalszej części rozdziału.

3.2.1.6 Moduł zarządzania transformacjami

Moduł implementuje przytoczone w rozdziale drugim metody opisu geometrii sceny. Trzonem modułu jest drzewo transformacji – hierarchiczna struktura, w której każdy z węzłów odpowiada jednemu z lokalnych układów współrzędnych i może być powiązany z układem **VPP** detektorów, a każdy liść odpowiada jednej przestrzeni IS. W sytuacji, gdy sprzętowo realizowane są głowice wielokamerowe, można dołączyć transformację głowicy do hierarchii co pokazano na przykład na rysunku (Rysunek 2.10). W trakcie wdrożeń, moduł zarządzania transformacjami kolejne funkcjonalności, które są związane:

- ze składaniem transformacji - za pomocą modułu można obliczać transformację wypadkową między **GCS** a dowolną **VPP**,
- z przekształcaniem współrzędnych punktu/wektora za pomocą transformacji i wyznaczaniem współrzędnych punktu/wektora w układzie współrzędnych zdefiniowanym przez inną transformację,
- z interpolacją i ekstrapolacją transformacji - w ogólności za pomocą modułu wyznaczać kombinację liniową dowolnych n transformacji, która to cecha była wykorzystywana w algorytmie re-kalibracji zewnętrznej.

Warto wspomnieć, że opisywane w poprzednim rozdziale metody kalibracyjne często projektowane są w reprezentacji macierzowej lub hybrydowej (kwaternion-translacja), stąd moduł zarządzający transformacjami układów współrzędnych dodatkowo pozwala na przekształcanie danej transformacji do równorzędnej, opisanej za pomocą innej reprezentacji.

W każdym z opisywanych zastosowań implementowano podobną hierarchiczną strukturę transformacji. Struktury pokazane zostały w rozdziale 3.1 opisującym model matematyczny sceny jako przykłady hierarchii wielokamerowych.

3.2.1.7 Moduł śledzenia obiektu 2D

Elementem niezbędnym w procesie śledzenia znanego obiektu w trójwymiarowej przestrzeni jest informacja o położeniu obrazu obiektu w **IS**. Zadaniem opisywanego modułu jest redukcja informacji zawartej w obrazie do abstrakcyjnej reprezentacji obiektu (która to reprezentacja stanowi fragment wiedzy a-priori o scenie). Wśród cech świadczących o jakości modułu można wyróżnić:

- dokładność wykrycia obiektu, której pomiar zależny jest od specyfiki zadania, w szczególności od reprezentacji śledzonego obiektu,
- powtarzalność, mierzona na podstawie analizy statystycznej detekcji w zmiennych warunkach sceny,
- czas obliczeń – wykrywanie obiektu na obrazie detektora jest, jak pokazały badania, najbardziej złożonym obliczeniowo problemem do rozwiązania w systemie pracującym w czasie rzeczywistym.

We wdrażanych systemach śledzenie obiektu 2D było realizowane w następujący sposób:

- **LCS** – Użycie projektora światła strukturalnego pozwoliło na wyrycie cienia obiektu na podstawie analizy wartości fazy w obrazie prążkowym,
- **VBS** – członek zespołu badawczego pracującego przy projekcie **VBS**, Piotr Kurowski, opracował autorskie algorytmy śledzące piłkę w dynamicznej scenie. Algorytmy zostały opisane w pracy [147]. Rozwój metod śledzenia obiektu nie stanowi przedmiotu badań prezentowanych w niniejszej pracy.

3.2.1.8 Moduł korekcji zniekształceń obiektu

W systemach wymagających wysokich dokładności (<0,05% przekątnej objętości pomiarowej) błędy wynikające z własności geometrycznych obiektu i jego perspektywicznego zniekształcenia mogą znacząco wpływać na jakość śledzenia. Na etapie przetwarzania obrazu i detekcji obiektu lub punktów charakterystycznych w większości przypadków niemożliwa jest korekcja pozostałych błędów tylko na podstawie informacji pochodzących z obrazu detektora. Możliwa jest jednak ich kompensacja, gdy znane są parametry wewnętrzne i zewnętrzne detektora. W trakcie badań prowadzonych w niniejszej pracy opracowano autorskie algorytmy korekcji jednego z błędów wynikających ze zniekształcenia perspektywicznego – błędu ekscentryczności. Procedury korzystające z wyników kalibracji i informacji otrzymanych z modułu detekcji obiektu lub modułu detekcji punktów charakterystycznych zostały zaimplementowane w oddzielnym module. Moduł ten ma za zadanie:

- pobrać informacje o kalibracji wewnętrznej i zewnętrznej detektora
- pobrać informacje o położeniu obrazu obiektu (na przykład o konturze wykrytego obrazu sfery),
- wyznaczyć skorygowane położenie poszukiwanego punktu kluczowego (na przykład projekcji środka sfery).

Dane wyjściowe modułu są w tym samym formacie co dane wyjściowe modułu detekcji obiektu lub modułu detekcji punktów kluczowych. Dzięki temu możliwe jest budowanie ścieżek przetwarzania, które używają lub nie używają tego modułu (w zależności od potrzeb i wymagań dotyczących czasu obliczeń).

We wdrożonych aplikacjach funkcje modułu korekcji zniekształceń obiektu realizowane były w następujący sposób:

- **LCS** – w tym systemie nie korygowano zniekształceń perspektywicznych,

- **VBS** – w ramach systemu wspomagającego decyzje sędziowskie opracowano i zaimplementowano metody korygowania błędu ekscentryczności, który wpływa na dokładność detekcji środka piłki.

3.2.1.9 Moduł analizy trajektorii 2D obiektu

W dynamicznych scenach, w których obserwowany jest więcej niż jeden obiekt ruchomy, często występującym problemem są przysłonięcia. Wśród obrazów znajdują się ramki, na których obiekt (z racji ruchu lub przysłonięcia) jest zniekształcony, mało lub w ogóle nie widoczny. Dla tych ramek nie można wykonać śledzenia. W systemie wspomagającym decyzje sędziowskie taka sytuacja często miała miejsce w klatkach kluczowych, w których piłka odbijała się od boiska, siatki lub zawodnika. Podobnie w systemie wspomagającym pracę ratownika medycznego – w momencie przesunięcia fantomu znaczniki na nim były przysłonięte. Innym problemem, który występuje w systemach pracujących w scenach dynamicznych, jest przypadkowy błąd detekcji obiektu wynikający z tymczasowej zmiany warunków akwizycji (na przykład oświetlenia).

Te dwa czynniki sprawiły, że w projektowanych systemach uwzględniono moduł, który ma za zadanie:

- analizować trajektorię, po której porusza się obiekt,
- rekonstruować położenie obiektu na podstawie trajektorii w klatkach, w których detekcja jest utrudniona lub niemożliwa,
- filtrować wyniki detekcji, by zredukować wpływ przypadkowego błędu detekcji na wynik śledzenia.

Podobnie jak w przypadku modułu śledzenia obiektu 2D, tak i w tym przypadku metody opracowywane i projektowane były przez innego członka zespołu i nie są przedmiotem niniejszej pracy. Warto wspomnieć, że wyniki badań zostały opublikowane w pracy [148] oraz w pracy [147].

3.2.1.10 Moduł wyznaczający równanie promienia/promieni w GCS

Moduł ten ma za zadanie wykorzystać informacje pochodzące z modułu analizy trajektorii obiektu, który zwraca skorygowane i przefiltrowane współrzędne obiektu w **IS** do wyznaczenia równania promienia, wzdłuż którego następuje projekcja perspektywiczna. Do tego celu używa informacji o transformacjach, które są przechowywane w module zarządzającym

transformacjami. Integrując te informacje, moduł pozwala przekształcić problem śledzenia w zadanie geometrii analitycznej. W zależności od realizacji moduł wyznacza jedno lub wiele równań promieni projekcji.

We wdrożonych systemach moduł implementowano w następujący sposób:

- **LCS** – równanie promienia wyznaczone było dla wszystkich pikseli cienia obiektu,
- **VBS** – równanie promienia wyznaczone było na podstawie współrzędnych obrazu środka piłki w **IS**.

3.2.1.11 Moduł integrujący dane z wielu detektorów

Równania promieni będące wynikiem działania poprzednich modułów dają pełną możliwą do uzyskania informację o relacji pomiędzy śledzonym obiektem a jednym z detektorów. Nie są one jednak pozbawione wpływu błędów, które pochodzą z dowolnego poprzedniego etapu obliczeń. W systemach wielokamerowych, które są przedmiotem niniejszej pracy ostateczna estymacja pozycji obiektu wyznaczana jest na drodze analizy, opisanej przez promienie projekcji, relacji między obiektem a zbiorem detektorów. Zadaniem modułu integracji jest wyznaczenie ostatecznej estymacji położenia śledzonego obiektu w trójwymiarowej przestrzeni. W ramach tego zadania moduł powinien:

- analizować wzajemne położenie detektorów,
- analizować równania wiązek prostych w celu detekcji równań odstających,
- znajdować przewężenia wiązki lub wiązek,
- wyznaczać położenie obiektu mając na uwadze wiedzę a-priori o obiekcie, przeszłych pozycjach i zmianach jakie zachodzą w strukturze geometrycznej systemu w trakcie jego działania

Obecnie prowadzone są badania związane z rozwojem tego modułu. Nie są one jednak przedmiotem niniejszej pracy. We wdrożeniach, które będą są omawiane korzystano z powszechnie dostępnych metod analitycznych.

Moduł zaimplementowano w prezentowanych aplikacjach w następujący sposób:

- **LCS** – dla każdego z rekonstruowanych punktów, dany był zbiór par promieni odpowiadających pikselom cienia obiektu: jeden promień związany był z kamerą a drugi z projektorem. Dla każdej pary punkt w **GCS** zdefiniowany był jako środek

najkrótszego odcinka między prostymi skośnymi (ze względu na błędy proste nie przecinały się)

- **VBS** – w systemie znajdowało się czternaście kamer. Możliwe było wyznaczenie przewężenia wiązki (punktu, dla którego suma odległości od wszystkich promieni jest najmniejsza). Znajac punkt przewężenia, możliwa była filtracja obserwacji (promieni) odstających (ang. outliers) na podstawie wspomnianej powyżej odległości. Ostatecznie punkt był wyznaczany jako przewężenie wiązki promieni nie będących obserwacjami odstającymi.

3.3 Opracowane algorytmy i modyfikacje

3.3.1 Moduł analizy sceny 2d

3.3.1.1 Detekcja i interpretacja informacji

3.3.1.1.1 Wprowadzenie

W systemie wspomagającym decyzje sędziowskie punkty charakterystyczne wykrywane w trakcie kalibracji zewnętrznej związane są z przecięciami linii boiska. Podobnie jak w pracy [149], zdecydowano się na podejście wykrywające punkty charakterystyczne na zbiorze fragmentów obrazu – obszarów zainteresowania **ROI (ang. region of interest)**. Podejście to jest szczególnie przydatne w analizie dynamicznych scen z nieruchomymi punktami kluczowymi. Dzięki zawężeniu analizowanego obszaru możliwe jest uniezależnienie procesu wykrywania danego punktu od znacznej części zmian sceny. Na przykład, we wspomnianym w poprzedniej części systemie **VBS**, zmienność sceny w dużym stopniu powodowana jest przez poruszających się zawodników, którzy przez większość czasu nie przysłaniają linii i narożników boiska. Ponadto **ROI** w tej aplikacji można wstępnie ręcznie ustawić, a później jedynie korygować współrzędne wyznaczonych obszarów tak aby był w nich widoczny wyłącznie obszar potrzebny do wykrycia punktu charakterystycznego.

W trakcie badań prowadzonych w ramach niniejszej pracy opracowano i rozwijano następujące algorytmy wspomagające detekcję i interpretację punktów charakterystycznych:

- Algorytm przetwarzania wstępnego, który w oparciu o transformatę Haara zwiększa kontrast między obiektem a tłem przy jednoczesnej redukcji szumów w obrazie - obecne w literaturze metody poprawy kontrastu w przypadku linii namalowanych na typowym boisku działały niezadowalająco przy niejednorodnym i zmiennym oświetleniu. Szczególnie dla linii widzianych z daleka algorytmy te rozmywały obiekt i wzmacniały szum. Użycie znanych algorytmów wykrywania linii pozwalało na wykrycie punktów charakterystycznych w **~70%** przypadków, a w niektórych scenach nawet **<30%**. Po wprowadzeniu modyfikacji do algorytmu poprawy kontrastu i zastosowaniu dodatkowego etapu filtracji wykrytych linii odsetek poprawnie wykrytych punktów wzrósł do **~95%** dla analizowanego zestawu danych eksperymentalnych. Największy wzrost niezawodności odnotowano w przypadku scen nierównomiernie oświetlonych,
- Algorytm adaptacji **ROI**, który na podstawie mapy prawdopodobieństwa pochodzącej z transformaty Hougha, steruje wyborem **ROI** dla kolejnej klatki – autorskie

rozwiązanie; W przypadku dynamicznych scen, w których konieczna jest re-kalibracja zmiany geometrii często powodują przesunięcie obiektów na obrazie detektora. Jest to szczególnie niekorzystne w przypadku algorytmów wizyjnych, które w swoim działaniu wykorzystują predefiniowany **ROI**. Po przesunięciu na obrazie widoczny jest inny niż wymagany obszar sceny. Opracowane rozwiązanie pozwala na wykorzystanie wiedzy a priori o scenie i dzięki temu przesunięcie (odtworzenie poprawnego) **ROI** do pozycji, w której dalsze etapy przetwarzania mogą być skutecznie realizowane. Po zastosowaniu rozwiązania zwiększył się zakres przesunięć obrazu detektora, po których nadal można było wykryć punkt charakterystyczny: bez adaptacji **ROI** narożnik można było wykryć po przesunięciu o ~20% rozmiaru **ROI** (na przykład dla **ROI** 64x64px jest to około 13px przesunięcia) do ~60% (na przykład dla **ROI** 64x64px było to około 40px),

- Algorytm filtracji linii, który na podstawie wiedzy a priori o układzie linii w danym ROI filtruje przestrzeń Hougha w celu zwiększenia odporności rozwiązania na obecność „fałszywych” linii pochodzących na przykład z reklam na boisku, linii siatki czy nogi zawodnika – autorskie rozwiązanie wykorzystujące wiedzę a priori o scenie do wykrycia znanego i poszukiwanego układu linii wśród nadmiarowego zbioru linii wykrytych. Użycie tego algorytmu pozwoliło na wzrost skuteczności wykrycia linii w odniesieniu do algorytmu przetwarzania wstępnego. (z **70%** do **95%**)

3.3.1.1.2 Przetwarzanie wstępne


Wykrywanie na obrazie krawędzi, które posłużą w dalszych krokach do wyznaczania linii odbywa się za pomocą algorytmów wykorzystujących filtrację górnoprzepustową. Z tego powodu dokładność ich działania zależy w dużym stopniu od kontrastu pomiędzy obiektem a tłem [150]. Co więcej, obecność szumów może powodować wzrost fałszywie wykrytych krawędzi. W aplikacji wspomagającej decyzje sędziowskie, która szczegółowo zostanie opisana w Rozdziale 4.3, obrazy zbierane są z częstotliwością powyżej 180 klatek na sekundę. Wymusza to krótkie czasy akwizycji, a co za tym idzie udział szumów obrazie jest duży. Z tego powodu, opracowano algorytm który podobnie jak w pracy [151] wykorzystuje informacje o sąsiedztwie piksela lecz w odróżnieniu od niego nie wymaga akumulowania wartości danego piksela w czasie. Opracowany algorytm składa się z następujących etapów:

- przekształcenia obrazu do skali szarości i jego późniejszej filtracji medianowej - ze względu na zmienne w czasie oświetlenie sceny (w tym zmienną w czasie barwę oświetlenia), informacja o barwie nie mogła być użyta. Stąd konwersja do skali szarości.


Lokalna filtracja medianowa pozwalała na eliminację szumów typu sól-pieprz, które pogarszają działania algorytmów normalizacji i wyrównywania histogramu,

- wyrównania histogramu obrazu - jest to pierwszy etap zwiększania kontrastu na obrazie. Wyrównanie histogramu pełni dwie role – zwiększa zakres występujących w obrazie wartości (co pośrednio zwiększa różnicę między białą linią a nie-białym tłem) oraz wzmacnia lokalne niejednorodności, którymi charakteryzują się fragmenty obrazu przedstawiające linie i narożniki boiska,
- transformaty Haara - transformata falkowa pozwala na analizę obrazu w dziedzinie częstości. Ponadto ze względu na swój lokalny charakter pozwala na skuteczną analizę sąsiedztwa każdego z pikseli,
- filtracji w dziedzinie Haara - w trakcie tego etapu wykonywane są trzy czynności: składowa dolnoprzepustowa jest normalizowana, składowa dolnoprzepustowa jest wzmacniana (dla każdej sceny współczynniki wzmocnienia dobierane są doświadczalnie) a każda ze składowych górnoprzepustowych jest wygaszana zależnie od poziomu, na którym się znajduje (im wyższy poziom, tym wyższe częstotliwości dana składowa reprezentuje i tym bardziej jest wygaszana),
- Odwrotna transformata Haara - przefiltrowany obraz jest transformowany z powrotem do dziedziny obrazu. W praktycznych zastosowaniach ostatnim etapem jest jego normalizacja (w związku z możliwym przekroczeniem zakresu wartości dla pikseli i powstałymi w ten sposób artefaktami).

Wyniki działania algorytmu były sprawdzane zarówno na danych syntetycznych (Rysunek 3.2.) jak i na danych rzeczywistych (Rysunek 3.3)



Rysunek 3.2 Etapy algorytmu przetwarzania wstępnego poprawiającego kontrast i redukującego szumy na obrazie syntetycznym. 1- obraz wejściowy, 2- wynik konwersji do skali szarości, 3- wynik wyrównania histogramu, 4 – transformata Haara, 5- obraz wyjściowy



Rysunek 3.3 Etapy algorytmu przetwarzania wstępnego poprawiającego kontrast i redukującego szumy na obrazie rzeczywistym. 1- obraz wejściowy, 2- wynik konwersji do skali szarości, 3- wynik wyrównania histogramu, 4 – transformata Haara, 5- obraz wyjściowy

3.3.1.1.3 Adaptacja ROI

Algorytm wyznaczający **ROI** dla kolejnej klatki zaprojektowano jako heurystyczny algorytm iteracyjny. Opisując algorytm, można zdefiniować zbiór linii **LS** (**ang. line set**), związany z każdym punktem charakterystycznym. Dla idealnego (lub zbliżonego do idealnego) obszaru zainteresowania, możemy dla danego **LS** wyznaczyć rozkład jego prawdopodobieństwa **LD**, na przykład w przestrzeni Hougha, który jednoznacznie definiuje położenie i orientację wszystkich linii a co za tym idzie kształt **LS**. Dla linii boiska, istnieje skończony zbiór kształtów **LS** (np. L-kształtne, T-kształtne itp.), a więc i skończony zbiór prawidłowych z punktu widzenia zadania rozkładów **LD**. Co więcej, gdy początkowe obszary są wyznaczone na etapie konfiguracji systemu, **LD** z każdego obszaru pierwszej klatki może być traktowany jako referencyjny dla danego punktu kluczowego. W trakcie działania systemu w każdej klatce obliczane są rozkłady prawdopodobieństw. Porównanie ich z referencyjnym **LD** pozwala określić, czy w przetwarzanym **ROI** znajduje się wystarczająca ilość informacji a także wyznaczyć estymację kolejnego położenia **ROI**. Pojedyncza iteracja metody składa się z następujących etapów:

- wyznaczenie krawędzi obrazu – wykonywana jest na obrazie pochodzącym z etapu przetwarzania wstępnego. Realizowana jest przez klasyczny algorytm Canny opisany w pracy [152],
- obliczenie transformaty Hougha - po wykryciu krawędzi obliczana jest mapa prawdopodobieństwa Hougha zgodnie z algorytmem opisanym w sekcji 2.2.4.1.2,
- wstępna analiza **LD**,

- porównanie mapy prawdopodobieństwa z referencyjną mapą (Rysunek 3.4). Miarą podobieństwa (jakości ROI) jest korelacja **LSQ (ang. line set quality)** między dwoma obrazami (równanie 3.3.1),


$$LSQ = 1 - \frac{\sum_u \sum_v |I_1(u, v) - I_2(u, v)|}{\sum_u \sum_v |I_1(u, v) + I_2(u, v)|} \quad (\text{równanie 3.3.1})$$

Dla **LSQ** większej niż 0,9 uznaje się, że ROI jest poprawny, adaptacja zostaje przerwana. Dla **LSQ**<0,9 wykonywane są kolejne kroki,

- analiza zakresów kątowych. W tym etapie na obrazie w przestrzeni Hougha szukane są piki wartości dla zakresów kątów charakterystycznych dla **LS** danego punktu charakterystycznego. Jeżeli wartości w pikach są większe niż próg, uznaje się, że linie są widoczne pod dobrym kątem i potrzeba tylko przesunięcia **ROI**. Jeżeli wartości w pikach są mniejsze niż założony próg, to może to świadczyć o trzech sytuacjach:
 - obraz z kamery został obrócony – w tej sytuacji szukane piki znajdują się w sąsiednich obszarach,
 - obraz z kamery został przesunięty o tyle, że jedna z linii nie mieści się w **ROI** – w tej sytuacji na mapie prawdopodobieństwa nie ma szukanych pików. W tej sytuacji, należy zwiększyć wielkość ROI,
 - obraz z kamery został przesunięty o tyle, że obszar, który zajmują linie jest niewielki i nie miarodajny – w tej sytuacji piki są obecne ale ich wartości są mniejsze od progu.

Gdy obraz z kamery został obrócony (przypadek pierwszy), następuje aktualizacja **LD**,

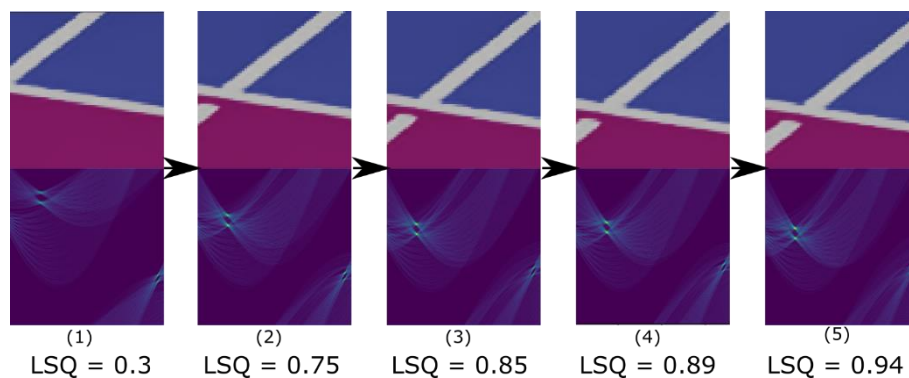
- analiza przesunięć. Dla wyznaczonych pików znajdowane są współrzędne (Θ, ρ) . Następnie wartości ρ dla pików odpowiadających każdej parze linii są porównywane z wartościami referencyjnymi. Wartość ρ jednej z par wyznacza przesunięcie ROI w osi x, wartość ρ drugiej pary wyznacza przesunięcie ROI w osi y. Grupowanie linii, zakresy i sposób wyznaczania przesunięć jest pokazany na rysunku (Rysunek 3.4)



Rysunek 3.4 Mapy prawdopodobieństw w algorytmie dostrajania ROI. 1a – referencyjny ROI z zaznaczonymi czterema krawędziami, 1b – referencyjna mapa prawdopodobieństw na której przerywanymi liniami zaznaczono zakresy kątowe i docelowe odległości dwóch grup linii, 2a – niepoprawny widok przesunięty; żółta i biała strzałka pokazują kierunki przesunięcia ROI, 2b – mapa prawdopodobieństw dla widoku 2a; na mapie zaznaczono żółtą i białą strzałkę – odpowiadają one przesunięciom grup (pierwsza grupa odpowiada za przesunięcie w y, druga za przesunięcie w x).

Dodatkowo w algorytmie wprowadzone zostały dwa warunki stopu – liczba iteracji z rzędu w których spada **LSQ** oraz maksymalna liczba iteracji. Po spełnieniu jednego z tych warunków adaptacja jest przerywana, współrzędne ROI są resetowane do ustawień początkowych, a punkt charakterystyczny nie jest wykrywany w tej klatce.


Gdy **LSQ** osiągnie wymaganą wartość, **LD** jest uznawany za prawidłowy a linie wchodzące w skład **LS** są wykorzystywane do obliczenia współrzędnych punktu charakterystycznego. Przykład działania algorytmu został pokazany na rysunku (Rysunek 3.5).



Rysunek 3.5 Obszary zainteresowania i mapy prawdopodobieństw w kolejnych iteracjach adaptacji ROI dla przykładowego **LS** wraz z odpowiadającymi im wartościami **LSQ**

3.3.1.1.4 Filtracja linii na podstawie referencyjnego rozkładu

W rzeczywistym zastosowaniu z uwagi na dynamikę sceny i zmienne warunki oświetlenia możliwe jest wykrycie „falszywych” krawędzi czyli krawędzi reklam, fragmentów siatki lub wzorów na koszulkach zawodników. Przy założeniu poprawnej lokalizacji ROI (co jest osiągnięte za pomocą opisywanego w sekcji 3.3.1.1.3 algorytmu), można filtrować wykryte linie maskując mapę prawdopodobieństwa w przestrzeni Hougha. Na podstawie tej idei zaprojektowano algorytm filtracji linii, który poprzez maskowanie i odwrotną transformatę Hougha zwraca zaszumiony obraz, na którym znajdują się tylko pożądane linie. Ten obraz w połączeniu wyjściowym obrazem krawędzi pozwala utworzyć przefiltrowany obraz krawędzi, na którym można wykryć poprawne linie. Przykładowe działanie algorytmu pokazano na rysunku (Rysunek 3.6).




Rysunek 3.6 Filtracja linii w przestrzeni Hougha. 1 – obraz krawędzi, 2- mapa prawdopodobieństw dla obrazu 1, 3 – odwrotna transformata obrazu 2 – mapa prawdopodobieństw pikseli w przestrzeni obrazu, 4- zamaskowana mapa prawdopodobieństw obrazu 1, 5 – transformata odwrotna obrazu 4; tylko cztery (poprawne) linie są widoczne

3.3.2 Moduł kalibracji wewnętrznej

Projektowana modyfikacja była dostosowaniem znanej metody Zhanga do sytuacji, występującej w systemie LCS, w której występuje niedostatek danych kalibracyjnych. W zaproponowanej modyfikacji wykorzystano wiedzę o scenie, wzorcu i systemie żeby wprowadzić dodatkowe „więzy”, które zmniejszają wymiarowość problemu przy zachowaniu dokładności metody bazowej. Dzięki modyfikacjom możliwe było zastosowanie odpornej metody, dla której znana jest prosta procedura kalibracji i dostępne są wzorce o niskim koszcie. Warto dodać, że metoda bez modyfikacji nie mogłaby zostać użyta w opisywanej aplikacji. Po wprowadzeniu uproszczeń osiągnięto niepewność skanowania 3D na poziomie 0,4 mm co stanowiło 0,13% wiodącego wymiaru objętości pomiarowej.

3.3.2.1 Wymagania użytkowe jako ograniczenia dla procedury kalibracji.

W systemie realizującym LCS [37] moduł kalibracji wewnętrznej został zmodyfikowany, tak by móc działać przy ograniczonej liczbie punktów kluczowych. W procesie kalibracji znane były współrzędne 64 punktów charakterystycznych, które znajdowały się w środkach znaczników wzorca kalibracyjnego. Dla każdego z punktów, znane były jego współrzędne przestrzenne w układzie współrzędnych obiektu (wzorca). W trakcie procedury kalibracji zbierano wyłącznie dwa obrazy położeń wzorca pokazane na rysunku (Rysunek 3.7)



Rysunek 3.7 Położenia wzorca kalibracyjnego w nisko-kosztowym skanerze światła strukturalnego

Wymaganiem użytkowym systemu była procedura kalibracji używająca stolika obrotowego, przez co środki geometryczne wzorców nie mogły być przesunięte względem siebie, a obrócone tylko wokół jednej osi. W związku z niskim kosztem systemu, użyte w kamerze i projektorze obiektywy cechowały się zauważalną dystorsją zarówno radialną, jak i styczną, przez co kalibracje analityczne w których nie uwzględnia się wpływu dystorsji nie mogły zostać użyte. Wzajemne położenie wzorców, a dokładniej przecinanie się płaszczyzn, które wyznaczały, uniemożliwiało zastosowanie modeli n-płaszczyznowych. Ostatecznie zdecydowano się na użycie modelu kamery otworkowej i hybrydowej techniki kalibracji Zhanga [53]. Niestety, ilość danych kalibracyjnych, jaka była dostępna nie wystarczała na stabilne wyznaczenie pełnego, nieliniowego modelu kamery otworkowej z dystorsją. W związku z tym należało zredukować liczbę wyznaczanych parametrów i wprowadzić dodatkowe ograniczenia w algorytmie bazując na wiedzy o projektowanych skanerze.

3.3.2.2 Uproszczenia modelu wynikające ze struktury systemu – dyskusja

Liczba punktów charakterystycznych na wzorcu kalibracyjnym jest wystarczająca do przeprowadzenia pierwszego etapu kalibracji i rozwiązania równania (równanie 2.2.12). Niewystarczająca jest natomiast liczba pozycji wzorca. W równaniu (równanie 2.2.17) każda z

pozycji wzorca dostarcza dwóch równań. Niestety, macierz **B** jest macierzą symetryczną o sześciu (pięciu jeśli wziąć pod uwagę nieznaną skalę) stopniach swobody, należy więc wprowadzić dodatkowe ograniczenia. Każde z ograniczeń może posłużyć do wprowadzenia jednego dodatkowego równania. W aplikacji rozważano następujące uproszczenia:

1. Rotacja wzorca następuje wyłącznie względem jego osi Y. Stąd równanie (równanie 2.2.15) możemy uzupełnić o zależność dotyczącą kolumny r_2 (równanie 3.3.2)

$$\begin{aligned} r_2 &= [0,1,0] \\ K^{-1} \cdot h_2 &= [0,1,0] \end{aligned} \quad (\text{równanie 3.3.2})$$

2. Proponowana w pracy Zhanga założona zerowa skośność układu optycznego. Na podstawie równania (równanie 2.2.17), przyjmująca postać pokazaną w równaniu (równanie 3.3.3).

$$b_{12} = 0 \quad (\text{równanie 3.3.3})$$

3. Ustawienie środka projekcji **CP** w środku matrycy detektora. Przy znanych wartościach CP_x i CP_y , możemy zdefiniować równanie (równanie 3.3.4).

$$CP_y \cdot b_{12} - CP_x \cdot b_{11} - b_{13} = 0 \quad (\text{równanie 3.3.4})$$

4. Założenie kwadratowego kształtu piksela matrycy, co skutkuje warunkiem $f_x = f_y$, skąd można wyprowadzić równanie (równanie 3.3.5).

$$b_{11} - b_{22} = 0 \quad (\text{równanie 3.3.5})$$

W omawianej aplikacji do układu równań dołączono ograniczenia (równanie 3.3.3) oraz (równanie 3.3.4). Ograniczenie (równanie 3.3.2) odrzucono z powodów praktycznych – każde drobne obrócenie kamery wokół jej osi optycznej względem wzorca byłoby źródłem błędu, a kalibracja miała być możliwa do wykonania przez niewykwalifikowanego użytkownika. Ograniczenie (równanie 3.3.5) odrzucono z uwagi na niski koszt użytych w projekcie detektorów, w których piksele detektora były zniekształcone.

Na etapie wyznaczania parametrów dystorsji zdecydowano się na pominięcie parametrów k_3, k_5 i k_6 , pozostawiając pozostałe pięć. Rozważano odrzucenie parametru k_4 i rozwiązanie równia

liniowego (równanie 2.2.21), ale eksperymenty pokazały istotny wpływ parametru k_4 na dokładność kalibracji.

Jak wspomniano wcześniej, po wprowadzeniu pokazanych powyżej uproszczeń osiągnięto niepewność pomiaru na poziomie 0,4 mm co stanowiło 0,13% wiodącego wymiaru objętości pomiarowej.

Opis objętości pomiarowej, przykładowe wyniki i szacowanie niepewności pomiaru znajduje się w rozdziale poświęconym wdrożeniu LCS (Rozdział 4.1).

3.3.3 Moduł automatycznej re-kalibracji

W ramach niniejszej pracy opracowano metodę dostrajania kalibracji zewnętrznej on-line. Metoda ta była szczególnie pomocna w aplikacji wspomagającej decyzje sędziowskie, w której na skutek zdarzenia losowego kamera mogła zostać przesunięta. Po włączeniu metody automatycznej re-kalibracji możliwe było zachowanie funkcjonalności systemu po wystąpieniu takiego zdarzenia.

W przypadku większości rozwiązań literaturowych dostrajanie wykorzystuje wyznaczenie nowych parametrów kalibracji wewnętrznej i zewnętrznej, a następnie filtrowanie ich za pomocą filtra dolnoprzepustowego, np. Kalmana [153]. W przypadku rozważanego zastosowania, w którym zmiany są nagłe, a sam detektor przez większość czasu jest nieruchomy, filtry dolnoprzepustowe nie pozwalały na szybką adaptację przy jednoczesnej filtracji szumów. Opracowany algorytm pokazany w pracy [58] (Rysunek 3.8). pozwala na dwuetapową re-kalibrację, w której najpierw sprawdzane jest wystąpienie zdarzenia losowego, a gdy ono nastąpi parametry kalibracji zewnętrznej są aktualizowane. W pozostałych przypadkach stosowana jest filtracja pozwalająca na redukcję wpływu szumów i błędów numerycznych na końcowy wynik kalibracji.

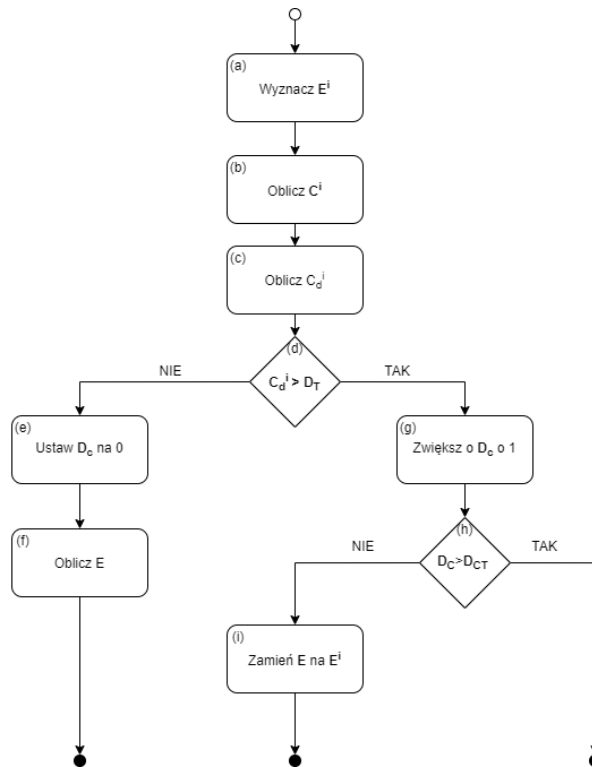
Zastosowanie algorytmu pozwoliło na utrzymanie wielkości błędu wyznaczania pozycji detektora na poziomie ~1mm po wystąpieniu zdarzenia losowego, co stanowiło 0,08% przekątnej prostopadłościanu (18 m x 9 m x 3m) wyznaczającego objętość pomiarową.

3.3.3.1 Opis algorytmu

W trakcie wykonywania algorytmu automatycznej re-kalibracji aktualizowany jest zestaw parametrów pomocniczych. Zdefiniujmy:

- E^i – obecna kalibracja zewnętrzna: macierz $[R|T]$ lub kwaternion dualny przekształcenia bryły sztywnej zdefiniowane w sekcji 2.1.3 i obliczone dla obecnej chwili czasowej (obecnej ramki),
- E – obowiązująca kalibracja zewnętrzna E – ostatnia wyznaczona przez algorytm poprawna kalibracja będąca jednocześnie wyjściem algorytmu,
- K - macierz kalibracji wewnętrznej zdefiniowana w (równanie 2.1.5) i odpowiadająca za przekształcenie punktów z wirtualnej rzutni **VPP** do **IS** obliczona w poprzednim etapie kalibracji,
- d_T – stała równa odległości kamery od środka założonej objętości pomiarowej wyznaczana w oparciu o głębnię ostrości na etapie kalibracji wewnętrznej. Na przykład w aplikacji opisywanej w pracy [77], odległość d_T wynosiła 6,56m
- T – punkt na który patrzy kamera (**ang. target**). Punkt ten leży na osi optycznej kamery w odległości d_T od ogniska jej obiektywu.
- C_G^i – obecna pozycja punktu T w globalnym układzie współrzędnych **GCS**.
- C_G - obowiązująca pozycja punktu T w globalnym układzie współrzędnych. Jest to ostatnia wyznaczona przez algorytm poprawna pozycja.
- C_d^i – przemieszczenie celu kamery – odległość pomiędzy punktami C_G^i i C_G
- D_T – próg przemieszczenia (**ang. dislocation threshold**). Wartość progu jest wyznaczana eksperymentalnie i określa zakres przemieszczeń celu kamery, które pochodzą z drgań, szumów i błędów detekcji.
- D_C^i - licznik przemieszczeń (**ang. dislocation counter**) i -tej klatki – liczba kolejnych klatek w przeszłości, w której $C_d^i > D_T$
 D_{CT} - próg licznika przemieszczeń (**ang. dislocation counter threshold**) – wyznaczana eksperymentalnie liczba następujących po sobie błędów grubych, które wynikają z szumów i błędów detekcji

Metoda re-kalibracji jest nadal rozwijana. Dokonano kilku zmian w stosunku do wersji prezentowanej w publikacji [77]. W opisie algorytmu dodane etapy zostaną wyróżnione *kursywą*. Schemat procedury pokazano na rysunku (Rysunek 3.8).



Rysunek 3.8 Algorytm sterujący procesem aktualizacji kalibracji zewnętrznej

W czasie działania algorytmu wykonywane są następujące kroki:

- wyznaczenie kalibracji zewnętrznej E^i (Rysunek 3.8 (a))
- Kalibracja zewnętrzna w i -tym kroku wyznaczana jest za pomocą hybrydowego podejścia łączącego algorytmy opisywane w poprzednich podrozdziałach:
 - wykonanie kalibracji z wykorzystaniem algorytmu **EPnP** z użyciem relacji punkt-punkt w zbiorze punktów kluczowych,
 - wykonanie n kalibracji z użyciem **EPnP** dla podzbiorów punktów kluczowych pomniejszonych o jeden punkt,
 - porównanie wyników kalibracji pełnego zbioru z kalibracjami podzbiorów. Pozwala to na wykrycie błędu grubego detekcji pojedynczego punktu. W przypadku wykrycia błędu grubego kalibracja pełnego zbioru jest zamieniana na kalibrację dla podzbioru, a zbiór punktów zamieniony jest na podzbiór w dalszych krokach (o ile jest dostępna wystarczająca liczba punktów, w przeciwnym razie algorytm jest przerywany dla tej klatki i zwracana jest informacja o niemożności wyznaczenia pozycji w tej chwili czasowej)

- Użycie iteracyjnego algorytmu optymalizacji Levenberga-Marquardta. Warunkami początkowymi algorytmu są wyniki poprzedniego kroku kalibracji. Zostaje wyznaczona macierz $[R|T]$
- *Konwersja macierzy przekształcenia bryły sztywnej do kwaterniona dualnego. Użycie kwaterniona dualnego poprawia możliwości interpolacji i ekstrapolacji. Zmniejsza błędy numeryczne związane z odwracaniem transformacji i pozwala użyć dodatkowej pętli optymalizacji zarówno dla rotacji, translacji jak i położenia kamery (o ile zajdzie taka potrzeba).*
- obliczenie współrzędnych C^i celu kamery (Rysunek 3.8 (b))
W tym kroku transformacja E jest odwracana i otrzymywana jest transformacja E^{-1} za pomocą której można przedstawić współrzędne punktu T w globalnym układzie współrzędnych,
- obliczenie przesunięcia C_a pomiędzy obowiązującym a obecnym położeniem celu kamery (Rysunek 3.8 (c)),
W ramach badań testowane były różne metryki opisujące odległość. Wybór metryki nie wpływał znacząco na działanie algorytmu. Zdecydowano się na użycie intuicyjnej metryki kartezjańskiej.
- porównanie przesunięcia z doświadczalnie wyznaczonym progiem D_T (Rysunek 3.8 (d))
W trakcie badań przeanalizowano wartości i rozkłady błędów detekcji punktów charakterystycznych oraz rozkłady kalibracji wewnętrznych kamer. Na tej podstawie zaproponowano eksperyment z użyciem danych syntetycznych, w których zamodelowano występowanie błędów pochodzących z dwóch wymienionych powyżej źródeł. Na tej podstawie wyznaczono średnią μ i odchylenie standardowe σ błędu wyznaczania celu kamery. Założono, że w aplikacjach wykorzystujących algorytm możliwe będzie podobne modelowanie, a próg D_T wyznaczany będzie za pomocą równania (równanie 3.3.6)

$$D_T = \begin{cases} \mu + 3\sigma, & \text{dla } 3\sigma < \mu \\ 6\sigma, & \text{dla } 3\sigma > \mu \end{cases} \quad (\text{równanie 3.3.6})$$

Na przykład w aplikacji przedstawionej w [77] $D_T \approx 2\text{mm}$

- ustawienie licznika przesunięć na 0 (Rysunek 3.8 (e))

Gdy przesunięcie D_T jest małe uznaje się, że wynika z błędów kalibracji, zmian oświetlenia i drgań statywu kamery. W tej sytuacji licznik przesunięć jest zerowany – zakłada się że kamera jest w tej samej pozycji co dla kalibracji obowiązującej,

- obliczenie nowej obowiązującej transformacji E (Rysunek 3.8 (f))

Ten etap algorytmu pełni rolę filtracji dolnoprzepustowej wyznaczanych transformacji E^i . Filtrację można przeprowadzić na wiele sposobów jak na przykład obliczając średnią kroczącą, używając popularnego w zastosowaniach robotyki mobilnej filtru Kalmana [153] lub za pomocą metod statystycznych tak jak w pracy [154]. W proponowanej metodzie zdecydowano się na podejście wyznaczające transformację E na podstawie interpolacji liniowej (sferycznej dla kwaternionów) z doświadczalnie dobranymi wagami ze względu na prostotę, czas obliczeń i stabilność.

- zwiększenie licznika przesunięć o 1 (Rysunek 3.8 (g))

Gdy przesunięcie D_T jest duże, uznaje się że wynika albo z wystąpienia błędu grubego albo ze znacznego przesunięcia kamery.

- Porównanie licznika przesunięć z progiem przesunięć (Rysunek 3.8 (h))

Dwie sytuacje opisane w poprzednim podpunkcie są rozróżniane na podstawie liczby kolejnych klatek, w których wyznaczone kalibracje znacznie różnią się od obowiązującej.

- Zamiana transformacji (Rysunek 3.8 (i))

Gdy wykryta zostaje zmiana pozycji kamery, transformacja E jest nadpisywana i proces zaczyna się od początku dla kolejnych klatek.

3.3.4 Uogólniony moduł zarządzania transformacjami

W ramach niniejszej pracy opracowano uogólnioną formę modułu zarządzania transformacjami. Opracowano narzędzie pozwalające na spójny matematyczny opis dowolnie złożonego układu wielokamerowego. W przeciwieństwie do istniejącego oprogramowania, które skupia się na opisie dobrze zdefiniowanego przypadku (stereopara, struktura akceleracji w renderingu, lokalny układ robota) i ma ograniczone możliwości konfiguracyjne, opracowane rozwiązanie aplikacyjne pozwala na przejrzysty opis, transformacje dostosowane do kalibracji i częstego przechodzenia między układami współrzędnych. Pozwala to na szybkie projektowanie i prototypowanie wielokamerowych systemów pomiarowych lub śledzenia.

3.3.4.1 Opis modułu

Trzonem modułu jest drzewo transformacji – hierarchiczna struktura złożona z kwaternionów dualnych i macierzy projekcji, w której każda macierz projekcji K_i jest liściem (w systemach śledzenia opartych o globalny układ współrzędnych 3D nie definiuje się transformacji 2D-2D), każda transformacja Psi_i jest dzieckiem korzenia – globalnego układu współrzędnych. W sytuacji, gdy sprzętowo realizowane są głowice wielokamerowe, można dołączyć transformację głowicy do hierarchii, jak na przykład w systemie **VBS** (Rysunek 2.10) Moduł połączony jest z innymi częściami systemu i pozwala:

- składać transformację - obliczać transformację wypadkową,
- obliczać transformację odwrotną,
- przekształcać współrzędne punktu/wektora za pomocą transformacji,
- wyznaczać współrzędne punktu/wektora w układzie współrzędnych zdefiniowanym przez inną transformację,
- wyznaczać transformację odwrotną,
- interpolować i ekstrapolować transformacje - w ogólności wyznaczać kombinację liniową dowolnych n transformacji.

Metody wyznaczające położenie (kalibrację zewnętrzną) kamery często projektowane są w reprezentacji macierzowej lub hybrydowej (kwaternion-translacja) (sekcja 2.1.3.1). Stąd moduł zarządzający transformacjami układów współrzędnych dodatkowo pozwala na:

- przekształcanie reprezentacji macierzowej do reprezentacji hybrydowej kwaternion-translacja i odwrotnie,
- przekształcanie reprezentacji macierzowej do reprezentacji w oparciu o kwaternion-kwaternion i odwrotnie
- przekształcanie reprezentacji hybrydowej do reprezentacji kwaternionów kwaternion-kwaternion i odwrotnie.

Dodatkowo algorytmy wyznaczanie pozycji i orientacji kamery wykorzystują do obliczania funkcji celu informację o błędzie projekcji i reprojekcji. Wynikają stąd dodatkowe wymagania dotyczące modułu - wykonywanie projekcji perspektywicznej 3D w 2D na podstawie współrzędnych punktu w globalnym układzie współrzędnych, kwaterniona transformacji oraz macierzy projekcji kamery.

Stożek elipstyczny styczny do sfery S jest osiowo-symetryczny dzięki czemu odcinki utworzone z NP i przecięć z dowolną płaszczyzną prostopadłą do osi stożka k mają równą długość. Wykorzystując tę własność możemy wyznaczyć równanie płaszczyzny Π używając wersorów wektorów v_i . Po zaczepieniu wersorów v_{wi} w punkcie NP uzyskamy współrzędne n punktów c_i leżących na płaszczyźnie Π . Zadanie odnalezienia wektora n sprowadza się w tej sytuacji do wyznaczenia równania płaszczyzny przechodzącej przez punkty c_i . Można to osiągnąć definiując macierz A złożoną ze współrzędnych punktów c_i (równanie 3.3.7).

$$A = \begin{bmatrix} c_{1x} & c_{nx} \\ c_{1y} & \dots & c_{ny} \\ c_{1z} & & c_{nz} \end{bmatrix} \quad (\text{równanie 3.3.7})$$


Najlepiej dopasowaną płaszczyznę możemy wyznaczyć używając twierdzenia Eckarta-Younga [155]. Na jego podstawie wiadomo, że wektor normalny do płaszczyzny na której znajdują się punkty c_i jest wektorem własnym macierzy A odpowiadającym najmniejszej wartości własnej. Można go wyznaczyć na przykład, stosując dekompozycję **SVD** (ang. **singular value decomposition**). Wyznaczony wektor n jest wektorem kierunkowym prostej k . Prowadząc prostą k z punktu NP i przecinając ją z PP uzyskamy współrzędne obrazu środka sfery ze skompensowanym błędem ekscentryczności.

Zaproponowana metoda wymaga przeprowadzenia dekompozycji SVD jednej macierzy, dzięki czemu ma mniejszą złożoność obliczeniową niż metody parametryczne wymienione w przeglądzie literatury. Skuteczność kompensacji rośnie wraz ze wzrostem liczby punktów, które biorą udział w wyznaczaniu równania płaszczyzny. Punkty mogą należeć do losowo wybranego podzbioru punktów leżących na konturze elipsy, dzięki czemu możliwe jest wykorzystywanie metod **RANSAC** [65], co poprawia odporność algorytmu na szумы.

3.3.5.3 Metoda wykorzystująca dopasowanie równania okręgu

Głównym źródłem niepewności związanych z opisywaną powyżej metodą jest dokładność wyznaczenia punktów leżących na konturze obrazu sfery w **IS**. Jeżeli detekcja konturu nie jest obarczona błędem systematycznym, możliwe jest wykorzystanie dodatkowego warunku w celu zmniejszenia wpływu dokładności detekcji na skuteczność kompensacji. Wiadomo, że dla idealnie wyznaczonego wektora n punkty c_i leżą na okręgu znajdującym się na płaszczyźnie Π , którego środek jest współliniowy z punktami O i O' . W przypadku, gdy rozważamy zaburzenia

wynikające z niedokładnej detekcji punkty c_i nie są współpłaszczyznowe. Możemy jednak analizować przecięcia c_i' prostych l_i z płaszczyzną Π (Rysunek 3.10).



Rysunek 3.10 Dopasowanie okręgu na płaszczyźnie Π . c_i' – przecięcia prostych l_i z płaszczyzną Π , O''' – środek dopasowanego okręgu, n – wektor normalny do płaszczyzny, q wektor kierunkowy prostej przechodzącej przez środek projekcji i środek dopasowanego okręgu

Do punktów c_i' możemy dopasować równanie okręgu. Aby to osiągnąć, należy zdefiniować układ współrzędnych, którego środkiem jest środek geometryczny zbioru punktów, oś Z jest równoległa do wektora n a osie X i Y, prostopadłe do siebie leżą na płaszczyźnie Π . W tak zdefiniowanym układzie współrzędnych można następnie wyrazić współrzędne c_i' używając formuły rotacji Rodriguesa ([156]). To przekształcenie sprowadza problem dopasowania okręgu do problemu dwuwymiarowego (współrzędne Z transformacji punktów c_i są równe 0), który rozwiązać można stosując na przykład metodę najmniejszych kwadratów ([157]). Po wykonaniu dopasowania, środek wyznaczonego przekształcany jest do GCS za pomocą transformacji odwrotnej (znowu korzystając z formuły Rodriguesa).

Tak wyznaczony środek O''' tworzy ze środkiem projekcji prostą, której wektor kierunkowy q (Rysunek 3.10) równoległy do wektora kierunkowego prostej łączącej NP i O

3.3.5.4 Walidacja

Walidacja metody i stopień redukcji wartości błędu ekscentryczności sprawdzano w trakcie dwóch scenariuszy eksperymentalnych: scenariusza wykorzystującego dane numerycznie zamodelowane i scenariusza wykorzystującego syntetyczne obrazy.

3.3.5.4.1 Dane numeryczne

Analizę numeryczną rozpoczyna analiza przypadku idealnego, w którym korygowana ekscentryczność jest jedynym występującym źródłem błędu w układzie. W opisywanym scenariuszu wyeliminowano takie źródła błędów jak: błędy detekcji na obrazie 2D, szумы, niewłaściwe wartości parametrów wewnętrznych, niepewności wartości referencyjnych czy wreszcie błędy wynikające z mechanizmów powstawania obrazu na dyskretnej macierzy

detektora. W tym celu przygotowano zestaw danych wyznaczanych za pomocą równań projekcji i wartości referencyjnych. W tym celu:

1. zdefiniowano i zaimplementowano prosty model kamery otworkowej i projekcji perspektywicznej dany za pomocą równania (równanie 2.1.5), w którym nie ma dystorsji. Wartości parametrów w modelu przyjmowały stałe, znane wartości. Dzięki temu wyeliminowano błędy kalibracyjne,
2. zdefiniowano idealną sferę, której promień i środek były znane. Użycie idealnej sfery pozwoliło uniknąć błędów wynikających ze zniekształcenia obiektu.
3. wyznaczono płaszczyznę prostopadłą do prostej \mathbf{k} , przechodzącej przez ognisko stożka i środek sfery,
4. wyznaczono przecięcie sfery z wyznaczoną w poprzednim kroku płaszczyzną.
5. powstały w ten sposób okrąg próbkowano tj. wyznaczono zestaw 100 punktów równomiernie rozmieszczonych na okręgu,
6. wyznaczono projekcje c_i zestawu punktów na **VPP**,
7. do wyznaczonych projekcji dopasowano elipsę i wyznaczono jej geometryczny środek (przecięcie małej i wielkiej osi).
8. dla projekcji wyznaczono równania promieni (prostych przechodzących przez ognisko detektora i daną projekcję punktu)

Opisane powyżej kroki pozwoliły (dla jednej sfery) wyznaczyć równania prostych l_i stycznych do sfery i prostej k' przechodzącej przez środek elipsy.

W opisywanym, pierwszym scenariuszu zdefiniowano zbiór sfer rozmieszczonych równomiernie w przestrzeni (równanie 3.3.8) i o promieniu dwóch jednostek.

$$\begin{aligned}x &\in [-30,30] \\y &\in [-40,40] \\z &\in [-20,20]\end{aligned}\tag{równanie 3.3.8}$$

Następnie zdefiniowano metrykę błędu wyznaczania środka śledzonego obiektu. Spośród dwóch rozważanych metryk: opartej o kąt między prostymi i odległość między punktami równoodległymi od ogniska, wybrano tę bazującą na odległości (równanie 3.3.9). Powodem takiego wyboru było większe znaczenie położenia śledzonego obiektu oraz sposób definiowania błędu śledzenia e .

$$\vec{k}_n = \frac{\|\vec{k}\|}{\|\vec{k}'\|} \cdot \vec{k}' \quad (\text{równanie 3.3.9})$$

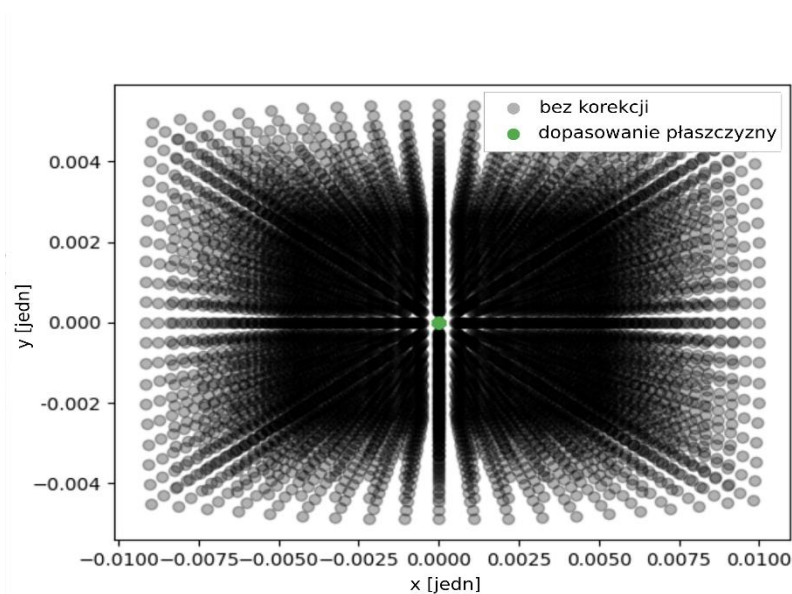
$$e = \|\vec{k}_n - \vec{k}\|$$

gdzie \vec{k} to referencyjny wektor łączący ognisko stożka i środek sfery, \vec{k}' to wyznaczony wektor projekcji środka sfery, a \vec{k}_n to wektor równoległy do \vec{k}' o długości równej długości wektora \vec{k} . Dodatkowo zdefiniowano pomocnicze błędy e_x , e_y , e_z , które obliczane były jako różnice pomiędzy współrzędnymi (odpowiednio x,y,z) wektorów \vec{k}_n i \vec{k}

Tak zdefiniowany błąd e obliczono dla każdej ze sfer dla trzech przypadków:


- Niekorygowanego wyznaczania środka projektowanej elipsy na **VPP** (co odpowiada środkowi konturu wyznaczonego na obrazie)
- Wyznaczania po zastosowaniu korekcji opartej o dopasowanie płaszczyzny
- Wyznaczania po zastosowaniu korekcji opartej o dopasowanie okręgu.

Wartości błędów e_x i e_y w powyższych przypadkach pokazano na rysunku (Rysunek 3.11).



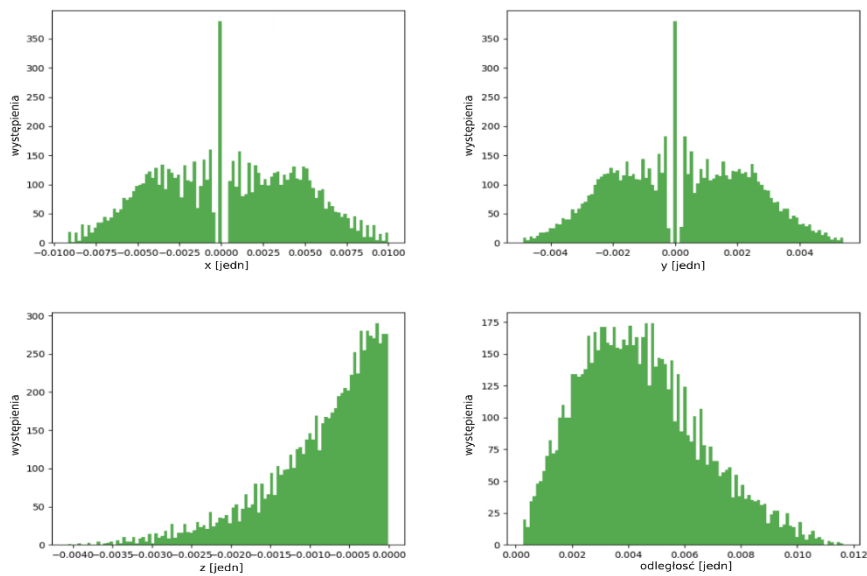
Rysunek 3.11 Wartości pomocniczych błędów e_x i e_y w scenariuszu wykorzystującym symulację numeryczną

Sam zaś rozkład błędów pomocniczych w wybranej metodzie pokazano poniżej (Rysunek 3.12)




Rysunek 3.12 Wartości pomocniczych błędów e_x i e_y w scenariuszu wykorzystującym symulację numeryczną. Z lewej po korekcji błędu metodą dopasowania płaszczyzny, z prawej po korekcji błędu metodą dopasowania okręgu.

Wyznaczono również histogramy rozkładu błędu. Na rysunku (Rysunek 3.13) pokazano histogramy w przypadku bez korekcji oraz po korekcji z wykorzystaniem dopasowania płaszczyzny (Rysunek 3.14)



Rysunek 3.13 Histogramy rozkładu błędów detekcji środka śledzonego obiektu w przypadku niekorygowanym.



Rysunek 3.14 Histogramy rozkładu błędów detekcji środka śledzonego obiektu w przypadku korygowanym za pomocą metody opartej o dopasowanie równania płaszczyzny.

Wartości liczbowe błędów uzyskane w obu metodach pokazano w tabeli (Tabela 3.1)


	Bez korekcji	Dopasowanie płaszczyzny	Dopasowanie okręgu
e_x średnia [jednostka]	3.5 e-4	-5.94e-11	-5.94e-11
e_x odch. std. [jednostka]	4.2 e-4	2.74e-07	2.74e-07
e_y średnia [jednostka]	1.8 e-4	-4.12e-09	-4.12e-09
e_y odch. std. [jednostka]	2.2 e-3	2.65e-07	2.65e-07
e_z średnia [jednostka]	-8 e-4	7.40e-10	7.40e-10
e_z odch. std. [jednostka]	7 e-4	4.64e-08	4.64e-08
e średnia [jednostka]	4.4 e-3	3.39e-07	3.39e-07
e odch. std. [jednostka]	2.1 e-3	1.8e-07	1.8e-07

Tabela 3.1 Wartości średnie i odchylenia standardowe błędów wyznaczania środka śledzonego obiektu oraz błędów pomocniczych uzyskane w pierwszym scenariuszu.

Jak widać, błąd ekscentryczności, będący jedynym źródłem błędu w rozważanym scenariuszu został w znacznym stopniu wyeliminowany.


3.3.5.4.2 Syntetyczne obrazy

W drugim scenariuszu analizę przeprowadzono przy użyciu syntetycznych obrazów. Tak jak w pierwszym przypadku, tak i tutaj scena obrazowana była przez kamerę opisaną za pomocą modelu otworkowego, lecz tym razem z uwzględnieniem dystorsji. W środowisku symulacyjnym *Blender*, w pierwszej kolejności przygotowano zestaw obrazów płaskiego wzorca kalibracyjnego widzianego przez kamerę o rozdzielczości 1920x1080 px, rozmiarze matrycy 36 mm x 24 mm i ogniskowej 8 mm. Przykładowy obraz pokazano na rysunku (Rysunek 3.15).



Rysunek 3.15 Syntetyczny obraz wzorca kalibracyjnego – idealny, bez zakłóceń


Następnie do tak przygotowanych obrazów dodano szumy: szum Perlina nałożony został na składową intensywność, a szum o rozkładzie jednorodnym na składowe odcieni. Później obraz został rozmyty dwukierunkowym filtrem Gaussa. Dzięki dodanym zniekształceniom, środki znaczników stały się trudniejsze do wykrycia, co było źródłem dodatkowego błędu. Przykładowy obraz po dodaniu zniekształceń pokazano na rysunku (Rysunek 3.16)



Rysunek 3.16 Syntetyczny obraz wzorca pomiarowego – po dodaniu zakłóceń

Za pomocą tak przygotowanych obrazów wykonano kalibrację używającą metody Zhanga [53], dzięki czemu uzyskano zaburzone macierze parametrów wewnętrznych (używane w metodzie korekcji błędu ekscentryczności).

Następnie przygotowano zestaw obrazów sfery (w położeniach tożsamy z położeniami z poprzedniego scenariusza). Aby nie wprowadzać błędów związanych z detekcją obiektu, obrazy sfery były maskami binarnymi (Rysunek 3.17)



Rysunek 3.17 Binarna maska odwzorowująca położenie śledzonego obiektu na obrazie detektora


Następnie dla każdego obrazu:

1. Wykryto kontur obrazu obiektu,
2. Dopasowano elipsę do konturu obrazu i wyznaczono jej środek,
3. Wyznaczono równania promieni przechodzących przez punkty konturu (styczne do sfery),
4. Wyznaczono równanie promienia przechodzącego przez wyznaczony środek elipsy.

Dla tak przygotowanych danych wyznaczono błąd e oraz błędy pomocnicze e_x , e_y , e_z , podobnie jak poprzednio, w przypadku:

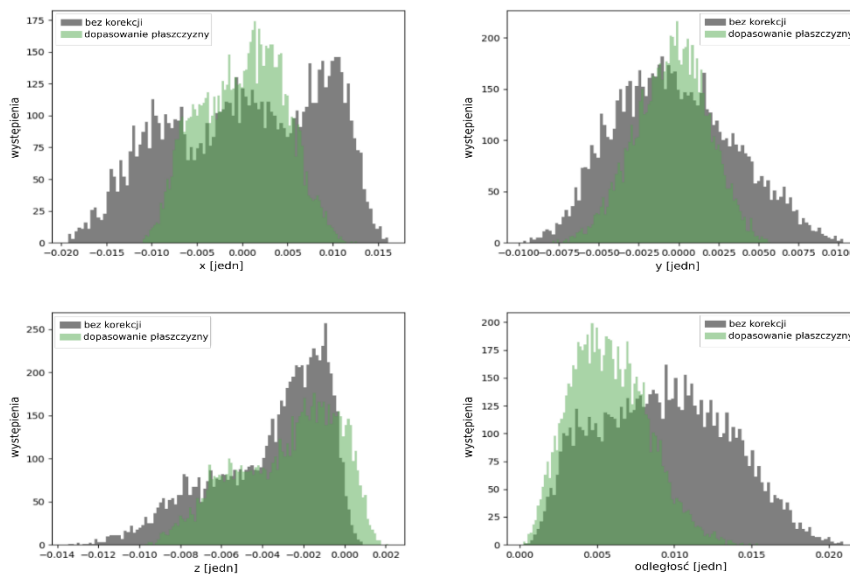
- Niekorygowanego wyznaczania środka projektowanej elipsy na **VPP** (co odpowiada środkowi konturu wyznaczonego na obrazie)
- Wyznaczania po zastosowaniu korekcji opartej o dopasowanie płaszczyzny
- Wyznaczania po zastosowaniu korekcji opartej o dopasowanie okręgu.

Przykładowe porównanie rozkładu błędów e_x i e_y w przypadku bez korekcji i po korekcji metodą dopasowania płaszczyzny na rysunku (Rysunek 3.18).



Rysunek 3.18 Wartości pomocniczych błędów e_x i e_y w scenariuszu wykorzystującym syntetyczne obrazy – bez korekcji i po korekcji z dopasowanie płaszczyzny

Następnie wyznaczono histogramy rozkładu błędów. Porównanie rozkładów przypadku niekorygowanego i przypadku z korekcją opartą o dopasowanie płaszczyzny pokazano na rysunku (Rysunek 3.19)



Rysunek 3.19 . Porównanie rozkładów przypadku niekorygowanego i przypadku z korekcją opartą o dopasowanie płaszczyzny

Wartości liczbowe uzyskane w opisywanym scenariuszu pokazano w tabeli (Tabela 3.2).

	Bez korekcji	Dopasowanie płaszczyzny	Dopasowanie okręgu
e_x średnia [jednostka]	0,00033	-0,0000245	-0,0000245
e_x odch. std. [jednostka]	0,0083	0,0045	0,0045
e_y średnia [jednostka]	-0,00026	-0,00044	-0,00043
e_y odch. std. [jednostka]	0,0037	0,0022	0,0022
e_z średnia [jednostka]	-0,0036	-0,0028	-0,0028
e_z odch. std. [jednostka]	0,0028	0,0025	0,0023
e średnia [jednostka]	0,009	0,0058	0,0057
e odch. std. [jednostka]	0,0042	0,0025	0,0024

Tabela 3.2 Wartości średnie i odchylenia standardowe błędów wyznaczania środka śledzonego obiektu oraz błędów pomocniczych uzyskane w drugim scenariuszu.

Jak widać, błąd wyznaczania środka śledzonego obiektu w porównaniu do przypadku bez korekcji zmniejszył się, a jego rozkład bardziej przypominał rozkład normalny (wynikający z superpozycji losowych błędów obecnych w scenariuszu).

4 Zastosowania praktyczne

4.1 Wprowadzenie

Poniższy rozdział poświęcony jest, wdrożeniom dokonany w trakcie prowadzenia badań będących przedmiotem niniejszej pracy. Pokazane są w nim również praktyczne zastosowania autorskich algorytmów prezentowanych w Rozdziale 3.

4.2 Niskokosztowy skaner światła strukturalnego

Opisywane wdrożenie realizowane było we współpracy z firmą SMARTTECH3D w ramach projektu ACTPHAST (Access Center for Photonics Innovation Solutions and Technology Support) o nazwie „A low-cost 3D scanner with calibrated color measurement”. Celem projektu było opracowanie skanera światła strukturalnego, który podczas pojedynczego pomiaru zbierałby jednocześnie informację geometryczną i barwną o obiekcie. Osiągnięcie celu możliwe było dzięki opracowaniu uproszczonej procedury kalibracji, która jednocześnie wyznaczałaby parametry wewnętrzne, zewnętrzne i kolorymetryczne systemu. Procedura została szczegółowo opisana we wspomnianej w poprzednich rozdziałach pracy [37].

4.2.1 Wzorzec kalibracyjny

W ramach prac zaprojektowano nowy układ wzorca kalibracyjnego, który pokazano na rysunku (Rysunek 3.7). Układ geometryczny znaczników odpowiadał jednemu z układów analizowanych w pracy [158]. W zaprojektowanym wzorcu zastosowano znaczniki okrągłe, które pozwalają na dokładniejsze niż w przypadku wzorców z szachownicą wyznaczenie punktu charakterystycznego – środka znacznika. Warto wspomnieć, że istotną wadą wzorców ze znacznikami okrągłymi jest obecny w detekcji błąd ekscentryczności, opisany w rozdziale 2.4, który jednak może być kompensowany przy użyciu metod opracowanych w ramach niniejszej pracy.


Aby możliwa była jednoczesna kalibracja geometryczna i barwna, znaczniki zostały wypełnione kolorami, które pokrywały możliwie szeroki zakres barw możliwych do zarejestrowania przez kamerę. Badania związane z doбором kolorów znaczników i przestrzeni barwnej, w której były one analizowane przeprowadzone zostały przez Grzegorza Mączkowskiego – członka zespołu pracującego nad projektem – i nie są elementem nowości niniejszej pracy.

4.2.2 Układ detektorów

W projektowanym systemie zastosowano hierarchię równoważną hierarchii stereopary (Rysunek 2.6). W odniesieniu do geometrii systemu, firma SMARTTECH3D sformułowała następujące wymagania:

- objętość pomiarowa powinna mieć wymiary co najmniej 300 mm x 300 mm x 150 mm,
- system powinien być kompaktowy i mieścić się w obudowie 600mmx100mmx100mm,
- odległość obiektu od systemu powinna być nie większa niż 500 mm.
- przeprowadzenie procesu kalibracji powinno odbywać się na podstawie co najwyżej dwóch położeń wzorca,
- ustawianie położeń wzorca powinno być automatycznie przeprowadzane z użyciem stolika obrotowego,
- system powinien utrzymywać dokładność bezwzględną pomiaru odległości poniżej 0,5 mm przy jednoczesnym zachowaniu dokładności względnej poniżej 0,15% objętości pomiarowej.

Na podstawie wymagań opracowano układ pokazany na rysunku (Rysunek 4.1).



Rysunek 4.1 Układ urządzeń wykorzystywanych w systemie . Po prawej – projektor światła strukturalnego, po lewej – kamera. D – odległość między urządzeniami, α – kąt między osiami optycznymi

W skład systemu wchodziły kamera barwna PointGrey Flea 2 o rozdzielczości 2Mpx, do której dołączony stało-ogniskowy obiektyw Fujinon oraz projektor DLP firmy Optoma. Urządzenia umieszczone były w odległości ok 0,5 m od siebie. Osie optyczne urządzeń były ustawione tak, aby przechodzić możliwie blisko siebie (w przybliżeniu przecinać się w jednym punkcie) i

tworzyć ze sobą kąt $\alpha \approx 40^\circ$. Punt najbliższy dwóm prostym był traktowany jako środek objętości pomiarowej.

4.2.3 Pozycje wzorca kalibracyjnego

Jak wspomniano powyżej, wymaganiem projektu związanym z prostotą procedury kalibracyjnej było przeprowadzanie całego procesu kalibracji na podstawie wyłącznie dwóch położzeń wzorca. W trakcie badań pokazano, że dokładności kalibracji wymagane w projekcie można było osiągnąć umieszczając wzorzec w pozycjach, pokazanych na rysunku (Rysunek 3.7). W każdym położeniu płaszczyzna utworzona przez osie optyczne urządzeń była możliwie blisko czwartego rzędu znaczników, a linia, wzdłuż której przecinają się płaszczyzny wzorców była możliwie blisko środka objętości pomiarowej.


Przy takim umiejscowieniu wzorca, każdy środek znacznika można było potraktować jak punkt w trójwymiarowym układzie współrzędnych **GCS**. Geometryczny prostopadłościan ograniczający (**ang. bounding box**) zbioru środków znaczników dwóch położzeń wzorca określał objętość pomiarową (**ang. measurement volume**) systemu.

4.2.4 Ewaluacja działania systemu

Testy dokładności systemu zostały opracowane na podstawie zaleceń norm ISO 10360-2 ([159]) oraz Vdi/Vde 2617-6 [160]. Przeprowadzono następujące eksperymenty:

1. pomiar płaszczyzny referencyjnej w centrum objętości pomiarowej dla różnych kątów (Rysunek 4.2). Błąd pomiaru szacowany był na podstawie błędu dopasowania płaszczyzny do wynikowej chmury punktów,
2. pomiar płaszczyzny referencyjnej umieszczonej prostopadle do dwusiecznej kąta między osiami optycznymi detektorów w trzech pozycjach w objętości pomiarowej (Rysunek 4.2),
3. pomiar referencyjnych znaczników sferycznych umieszczonych w 18 losowych miejscach objętości pomiarowej. Błąd pomiaru szacowany był na podstawie błędu dopasowania sfery do wynikowego fragmentu chmury punktów odpowiadającemu mierzonej sferze,

4. pomiar odległości pomiędzy środkami dwóch sfer wzorca odległości umieszczonego w 18 losowych miejscach objętości pomiarowej. Błąd pomiaru szacowany był na podstawie różnicy pomiędzy referencyjną a obliczoną odległością między środkami znaczników wzorca odległości,
5. pomiar geometryczny złożonego obiektu „Gargulec” (Rysunek 4.3) Dokładność pomiaru szacowana była na podstawie błędu dopasowania chmur punktów obliczanego podczas składania pomiarów kierunkowych.
6. ewaluacja jakościowa na podstawie pomiarów barwnych złożonych rzeczywistych obiektów (Rysunek 4.3).



Rysunek 4.2 Położenia płaszczyzny referencyjnej w trakcie eksperymentów




Rysunek 4.3 Obiekty testowe wykorzystywane podczas eksperymentów: gargulec, para łowicka, model statku i figurka „Rumcajs”

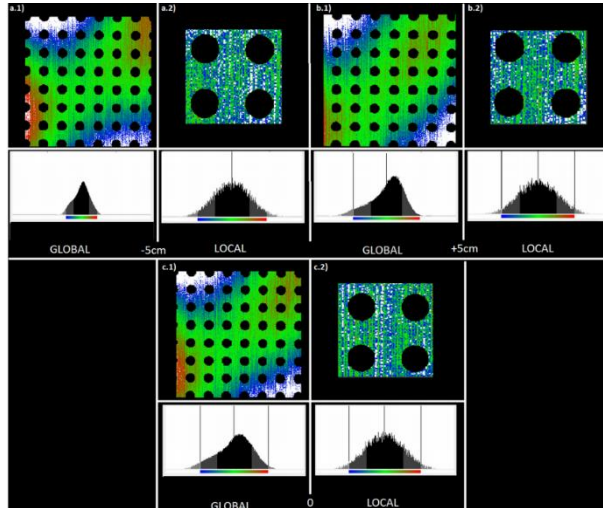
4.2.4.1 Pomiary płaszczyzny referencyjnej

Pomiar w pierwszym i drugim scenariuszu testowym przeprowadzono używając wzorca płaskości. Posłużył za niego wzorec kalibracyjny, który wykonano naklejając wysokiej jakości wydruk na tafłę szkła o grubości 5 mm. Tak przygotowany wzorec charakteryzował się płaskością na poziomie 1 μm , którą zweryfikowano w laboratorium współrzędnościowym na Wydziale Mechatroniki Politechniki Warszawskiej. Podczas pierwszego scenariusza testowego badano błędy związane z globalnym i lokalnym dopasowaniem płaszczyzny (Rysunek 4.4). Zauważono, że dla większych wartości kąta nachylenia wzorca, otrzymany błąd dopasowania

ma rozkład cylindryczny. Charakter błędu prawdopodobnie związany był z uproszczeniami, jakich dokonano w procedurze kalibracyjnej (sekcja 3.3.2), przede wszystkim zaś z pominięciem współczynników dystorsji radialnej wyższych rzędów. W drugim scenariuszu testowym błędy globalne miały rozkład hiperboliczny (Rysunek 4.5). Charakter ten prawdopodobnie związany był z ustaleniem środka projekcji C_p w środku obrazu i wyłączeniem tej współrzędnej z procesu optymalizacji, co opisano w (sekcja 3.3.2.2).



Rysunek 4.4 Rozkłady globalne i lokalne błędów dopasowania płaszczyzny dla różnych kątów.



Rysunek 4.5 Rozkłady globalne i lokalne błędów dopasowania płaszczyzny dla różnych położeń w objętości pomiarowej

Wyniki ilościowe opisywanego eksperymentu zostały przedstawione w tabelach (Tabela 4.1, Tabela 4.2)

Kąt pomiaru	Lokalne dopasowanie punktów 3σ [mm]	Globalne dopasowanie punktów 1σ [mm]	Globalne dopasowanie punktów 2σ [mm]	Lokalne dopasowanie punktów 3σ [mm]
-10°	0,078	0,139	0,292	0,39
-5°	0,084	0,112	0,239	0,327
5°	0,072	0,103	0,224	0,309
10°	0,089	0,1547	0,3007	0,4


Tabela 4.1 Błędy dopasowania pomiarów wzorca płaskiego dla różnych kątów pomiaru

Odległość od środka objętości pomiarowej	Lokalne dopasowanie punktów 3σ [mm]	Globalne dopasowanie punktów 1σ [mm]	Globalne dopasowanie punktów 2σ [mm]	Lokalne dopasowanie punktów 3σ [mm]
-5 cm	0,074	0,0804	0,164	0,204
0	0,084	0,078	0,157	0,2
5 cm	0,087	0,074	0,161	0,216

Tabela 4.2 Błędy dopasowania pomiarów wzorca płaskiego dla różnych odległości wzorca od środka objętości pomiarowej

4.2.4.2 Pomiary sfer referencyjnych

Podobnie jak w przypadku eksperymentów związanych z dopasowaniem płaszczyzny, tak i tutaj przeprowadzono testy zgodnie z dwoma scenariuszami. Jako wzorca użyto wzorca odległości dostarczonego przez firmę SMARTTECH3D złożonego z dwóch sfer o promieniu $18,750 \pm 0,01$ mm oddalonych od siebie o $108,8 \pm 0,01$ mm. W pierwszym scenariuszu testowym dopasowywano sferę do wynikowej chmury punktów, a następnie wyznaczano błąd dopasowania sfery do sfery o zadanym promieniu. Przykładowy wynik dopasowania został pokazany na rysunku (Rysunek 4.6). Dla wszystkich położenia sfery referencyjnej osiągnięto błąd $3\sigma < 0,09$ mm. Warto zauważyć, że w związku z małymi wymiarami znaczników sferycznych rozkład błędów ma charakter zbliżony do rozkładu lokalnego błędów dopasowania płaszczyzny.



Rysunek 4.6 Przykładowe rozkłady błędu dopasowania sfery

W drugim scenariuszu porównywano odległości pomiędzy środkami sfer dopasowanych do fragmentów chmury punktów z wartością referencyjnej odległości, a także promieni sfer z referencyjnymi wartościami promieni. Wyniki ilościowe pokazano w tabelach (Tabela 4.3, Tabela 4.4).

x-x ₀ [mm]	y-y ₀ [mm]	z-z ₀ [mm]	D [mm]	Dopasowanie punktów 3σ [mm]
8.13	-71,68	-14,32	73,55	0,08
4.47	36,92	-9,11	38,29	0,1
-51.67	-70,56	-29,34	92,25	0,08
-55.54	38,04	-23,74	71,38	0,1
114.04	-71,75	-27,39	137,49	0,01
110,29	36,83	-21,99	118,34	0,01
6.02	-72,78	4,12	73,14	0,09
2.09	35,79	9,71	37,15	0,1
-81.58	-72,5	9,59	109,56	0,09
-85.55	36,12	15,53	94,15	0,1
118.16	-73,38	0,33	139,09	0,01
114.32	35,16	5,56	119,73	0,1
24.06	-74,62	48,41	92,14	0,1
20,28	33,91	53,95	66,87	0,09
-72.56	-72,94	32,06	107,76	0,09
-76.26	35,73	37,33	92,12	0,1
122.54	-75,28	46,47	151,13	0,09
118.53	33,17	51,73	133,51	0,09


Tabela 4.3 Błąd dopasowania sfery w zależności o położenia w obrębie objętości pomiarowej. (x,y,z) – współrzędne środka sfery, (x₀,y₀,z₀) – współrzędne środka objętości pomiarowej, D -odległość od środka objętości pomiarowej.

x-x ₀ [mm]	y-y ₀ [mm]	z-z ₀ [mm]	D [mm]	D _{sr} [mm]	R [mm]	R _{err} [mm]	d [mm]	d _{err} [mm]
8,13	-71,68	-14,32	73,55	55,92	18,73	0,02	108,79	0,01
4,47	36,92	-9,11	38,29	–	18,724	0,03	–	–
-51,67	-70,56	-29,34	92,25	81,81	18,644	0,11	108,81	0,01
-55,54	38,04	-23,74	71,38	–	18,64	0,11	–	–
114,04	-71,75	-27,39	137,49	127,91	18,84	0,09	108,78	0,02
110,29	36,83	-21,99	118,34	–	18,83	0,08	–	–
6,02	-72,78	4,12	73,14	55,14	18,73	0,03	108,79	0,01
2,09	35,79	9,71	37,15	–	18,72	0,03	–	–
-81,58	-72,5	9,59	109,56	101,86	18,63	0,12	108,86	0,06
-85,55	36,12	15,53	94,15	–	18,61	0,14	–	–
118,16	-73,38	0,33	139,09	129,41	18,86	0,11	108,4	0,06
114,32	35,16	5,56	119,73	–	18,84	0,089	–	–
24,06	-74,62	48,41	92,14	79,51	18,76	0,01	108,74	0,065
20,28	33,91	53,95	66,87	–	18,8	0,05	–	–
-72,56	-72,94	32,06	107,76	99,94	18,64	0,107	108,86	0,06
-76,26	35,73	37,33	92,12	–	18,63	0,12	–	–
122,54	-75,28	46,47	151,13	142,32	18,86	0,139	108,65	0,15
118,53	33,17	51,73	133,51	–	18,87	0,115	–	–

Tabela 4.4 Błąd wyznaczenia odległości między sferami referencyjnymi oraz błąd wyznaczenia promienia sfery referencyjnej w zależności od położenia wzorca odległości w objętości pomiarowej. (x,y,z) – współrzędne środka sfery, (x₀,y₀,z₀) – współrzędne środka objętości pomiarowej, D -odległość od środka objętości pomiarowej, D_{sr} – średnia odległość środków sfer we wzorcu odległości od środka objętości pomiarowej, R – promień dopasowanej sfery, r_{err} błąd wyznaczenia promienia, d – odległość między dopasowanymi sferami wzorca, d_{err} błąd wyznaczenia odległości.

4.2.4.3 Pomiar złożonego obiektu geometrycznego

W trakcie tego scenariusza testowego wykonano 12 pomiarów kierunkowych rzeźby gipsowej „Gargulec” (Rysunek 4.3). Z pomiarów kierunkowych złożono wynikową chmurę punktów osiągając wymagane dokładności dopasowania <1 mm. Na podstawie chmury punktów wykonano gęstą siatkę trójkątów, która pokazana została na rysunku (Rysunek 4.7). Możliwość złożenia chmury jednorodnej punktów składającej się z pomiarów kierunkowych jest cechą, która dodatkowo potwierdzała spełnienie wymagań projektowych.



Rysunek 4.7 Przykładowe wyniki wynikowej siatki trójkątów obiektu „Gargulec”

4.2.4.4 Pomiary geometryczno-barwne prostych obiektów

Ostatni scenariusz testowy zakładał jakościową ocenę działania systemu na podstawie analizy skanów kierunkowych obiektów „Para łowicka”, „Statek” i „Rumcajs”. Na rysunku (Rysunek 4.8) pokazano wynikowe chmury punktów z uwzględnieniem korekcji barwnej.



Rysunek 4.8 Wynik pomiaru geometryczno-barwnego prostych obiektów.

4.2.5 Porównanie z innymi dostępnymi metodami

W trakcie wdrożenia dokonano porównania ilościowego i jakościowego zaprojektowanego systemu z rozwiązaniami aktualnie dostępnymi: kamerą Kinect [161], systemem time-of-flight z pracy [158] i laboratoryjnym skanerem światła strukturalnego pokazanym w pracy [162]. Wyniki porównania zebrano w tabeli (Tabela 4.5). Dokładności uzyskane przez system spełniały wymagane założenia, co w połączeniu z niską ceną ostatecznego rozwiązania przyczyniło się do sukcesu wdrożenia.

Metoda	Dane wejściowe	Sprzęt	Dokładność bezwzględna	Wymiar przekątnej objętości pomiarowej	Dokładność względna
Kinect 1.0 i kalibracja Zhanga	10 obrazów płaskiego wzorca	Kamera IR, projektor IR, kamera RGB	~4cm	5m	0,8%
Kamera i sensor time-of-floght	5 obrazów płaskiego wzorca	Dwie kamery RGB, sensor TOF	~2cm	~3m	0,6%-1,8%
Skaner światła strukturalnego z projekcją prążków	6 obrazów płaskiego wzorca + 4 serie obrazów prążkowych	Kamera RGB, projektor DLT	~0,04 mm	1,2m	0,036%
LCS	Obrazy z dwóch położeń wzorca płaskiego	Kamera RGB, projektor DLT	0,4 mm	0,3m	0,13%

Tabela 4.5 Zestawienie dokładności i wymagań proponowanego rozwiązania z metodami dostępnymi w chwili wdrażania systemu.

4.3 System wspomagający decyzje sędziowskie

4.3.1 Wprowadzenie

Opisywane wdrożenie realizowane było w ramach zleconego przez Polską Fundację Piłki Nożnej projektu o nazwie: „Wykonanie prac badawczo-rozwojowych dotyczących śledzenia trajektorii piłki w grach sportowych z wykorzystaniem systemów wizyjnych–OGX|BallTracking”. Celem projektu było zaprojektowanie systemu wspierającego sędziego piłki siatkowej w podejmowaniu decyzji w trakcie trwania meczu. Aby to osiągnąć konieczne było opracowanie metod, które pozwalały na wyznaczanie pozycji środka piłki w układzie współrzędnych boiska na podstawie obrazu z dwunastu szybkich kamer rozmieszczonych wokół niego. Spełnienie tego celu możliwe było po spełnieniu następujących wymagań:

1. System powinien umożliwiać zbieranie obrazów z częstotliwością powyżej 180 Hz. Wynika to z konieczności rejestracji i analizy trajektorii piłki poruszającej się z prędkością nawet 120 km/h.
2. System powinien umożliwiać wykrywanie środka piłki z niepewnością mniejszą niż 10 mm. Pozwala to na określenie miejsca odbicia z precyzją, która została określona przez zleceniodawcę jako wystarczająca do podejmowania decyzji czy odbicie nastąpiło w boisku czy poza nim. Co więcej, biorąc pod uwagę grubość ludzkiej dłoni, możliwe stało się także określenie czy odbicie nastąpiło od płaszczyzny boiska czy od podłożonej ręki zawodnika.
3. System powinien umożliwiać wykrywanie i automatyczną re-kalibrację po zmianie geometrii sceny (na przykład po przesunięciu jednej z kamer).
4. System powinien być przenośny i możliwy do instalacji w dniu obsługiwanego meczu.
5. Obecność systemu nie może ingerować w boisko, siatkę i piłkę. Oznacza to dyskwalifikację rozwiązań, które umieszczają nadajniki w piłce lub siatce, a także takich, które zakładają naklejanie dodatkowych znaczników kalibracyjnych na boisku.

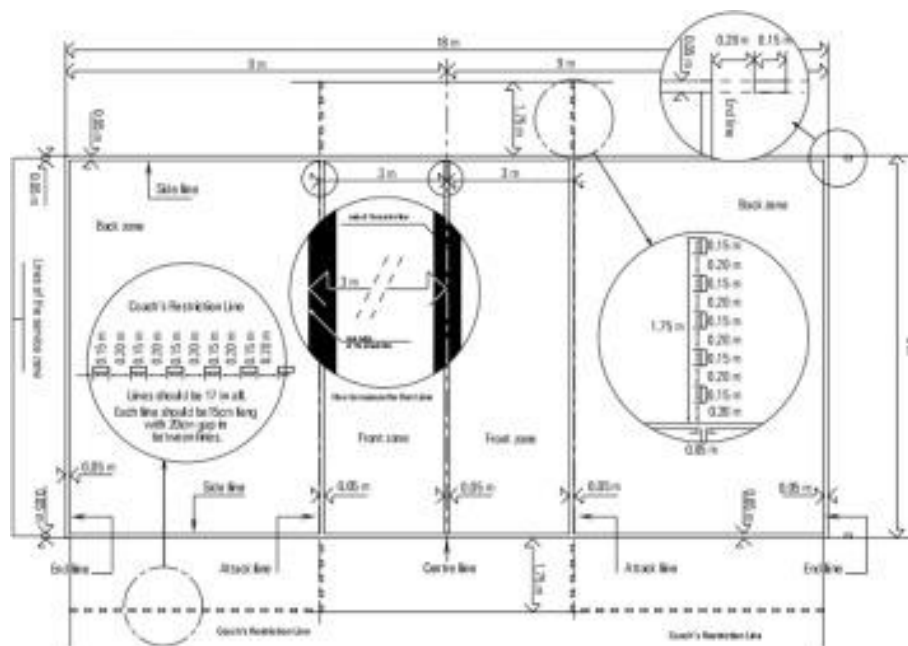
W trakcie prac nad systemem opracowano metody wyznaczania punktów charakterystycznych w scenie, autorską metodę re-kalibracji zewnętrznej oraz metodę kompensacji błędu ekscentryczności, które opisywane były w poprzednim rozdziale niniejszej pracy. Opis rozwiązania ze szczególnym naciskiem na re-kalibrację został przedstawiony w pracy [58].

4.3.2 Układ współrzędnych i punkty kluczowe

Wybór charakterystycznych punktów kluczowych, pozwalających na lokalizację kamer w układzie współrzędnych boiska, jest jednym z najważniejszych etapów projektowania rzeczywistego systemu śledzenia. By spełniać swoją rolę punkty te powinny:

- być dobrze zdefiniowane w globalnym układzie współrzędnych w każdej z klatek zbieranych przez kamerę. Dokładne wyznaczenie współrzędnych w **GCS** możliwe jest dzięki wcześniejszemu, wstępnemu pomiarowi sceny lub związaniu **GCS** ze znanym obiektem
- być łatwo wykrywalne w przewidywanych widokach z kamery
mieć nieruchome obrazy w **IS** przy zmiennych warunkach oświetlenia.

W projektowanym systemie punktami, spełniającymi te założenia są narożniki boiska, których rozmieszczenie pokazano na rysunku (Rysunek 4.9).




Rysunek 4.9 Układ linii i narożników na boisku do piłki siatkowej. [163]

Wykrywanie punktów kluczowych przeprowadzono używając autorskiej metody pokazanej w sekcji 3.3.1.1.

4.3.3 Układ kamer

Jak pokazano w rozdziale drugim (Rysunek 2.10), w projektowanym rozwiązaniu kamery traktowane są niezależnie. Dzięki temu znaczne przesunięcie, które uniemożliwia re-kalibrację

(na przykład wywrócenie statywu) lub uszkodzenie pojedynczej kamery nie przerywa pracy systemu. Co więcej, traktowanie kamer niezależnie pozwala na analizowanie pozycji śledzonego obiektu w docelowym, globalnym układzie współrzędnych. Geometryczny układ kamer w opracowywanym systemie pokazano na rysunku (Rysunek 4.10).



Rysunek 4.10 Układ kamer w systemie wspomagającym decyzje sędziowskie. Po lewej pokazany jest rzut z góry systemu. Kamery reprezentowane są przez okręgi z numerami. Przybliżone pola widzenia kamer oznaczono czerwonymi przerywanymi liniami. Po prawej pokazany jest widok pojedynczej kamery z zaznaczonymi odległościami od linii i płaszczyzny boiska. Pole widzenia kamery oznaczono czerwoną przerywaną linią.


Dwanaście jednakowych detektorów umieszczono równomiernie wokół boiska. Kamery 1-4 oraz 7-10 wyposażone zostały w obiektywy o ogniskowej 6 mm, a kamery 5, 6, 11, 12 wyposażone zostały w obiektywy o ogniskowej 8mm. Orientacje kamer oznaczono na rysunku czerwonymi, przerywanymi liniami. Pochylenie (**ang. tilt**) kamer zostało tak dobrane aby górna krawędź ostrosłupa projekcji była w przybliżeniu równoległa do płaszczyzny boiska. Ze względu na zastosowaną metodę kalibracji zewnętrznej – opartą na punktach kluczowych związanych z narożnikami boiska – podczas dobierania orientacji kamer dbano o to, by w każdym z widoków było widocznych przynajmniej pięć punktów charakterystycznych. Przykładowy widok z pojedynczej kamery pokazano na rysunku (Rysunek 4.11). W projekcie używano kamer IDS UI-3060CP Rev.2 z sensorem SONY IMX174 CMOS o rozdzielczości 1920x1080 i częstotliwości akwizycji ramki 180 Hz.



Rysunek 4.11 Przykładowy widok z kamery nr 2 umieszczonej przy dłuższej linii boiska.

4.3.4 Synchronizacja akwizycji

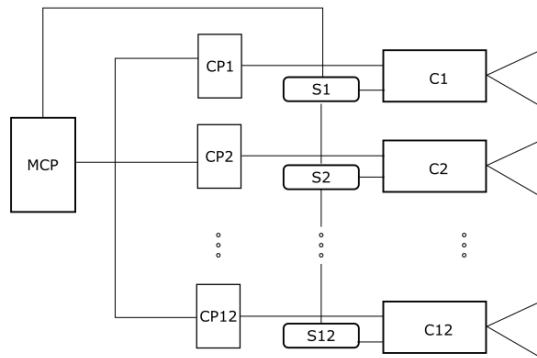
Formułowanie wniosków dotyczących dynamicznych scen na podstawie informacji pozyskanej z niezależnych kamer możliwy jest jedynie wtedy, gdy kontrolowane są momenty zbierania ramek. Jedną z metod sprawowania kontroli nad chwilami czasowymi, w których zbierane są ramki, jest synchronizacja kamer. W projektowanym systemie do synchronizacji użyto systemu złożonego z dwunastu dedykowanych układów elektronicznych, którego autorem był jeden z członków zespołu – Kajetan Nadolski. Pojedynczy układ synchronizatora pokazano na rysunku (Rysunek 4.12), na którym widać urządzenie po zdjęciu obudowy. Opisywany element systemu nie jest elementem niniejszej pracy – został przedstawiony, by pokazać, że problem synchronizacji został zaadresowany w opisywanym wdrożeniu.



Rysunek 4.12 . Dedykowany synchronizator wysyłający sygnały łączem światłowodowym.

4.3.5 Przetwarzanie danych – realizacja sprzętowa

W omawianej aplikacji do przetwarzania danych użyto trzynastu komputerów, które z kamerami i układem synchronizacji powiązane były tak jak pokazano na rysunku (Rysunek 4.13).



Rysunek 4.13 Realizacja sprzętowa ścieżki przetwarzania danych. C1-C12 – detektory użyte w systemie VBS. S1-S12 – elementy modułu synchronizacji. CP1-CP12 – komputery realizujące obliczenia związane z przetwarzaniem obrazu. MCP – komputer realizujący obliczenia związane z kalibracją, re-kalibracją, analizą trajektorii, rekonstrukcją 3D i podejmowaniem decyzji sędziowskiej.

Konieczność wykonywania szybkich obliczeń związanych z detekcją piłki i re-kalibracją w czasie rzeczywistym spowodowała, że do każdego z detektorów systemu dołączono jednostkę obliczeniową, której jedynym zadaniem było przetwarzanie każdego z obrazów zarejestrowanych przez odpowiadający jej detektor, m. in:

- przetwarzanie wstępne obrazów,
- wykrycie piłki,
- adaptacyjne dopasowanie ROI,
- wykrycie skorygowanych współrzędnych punktów kluczowych.

Tak zredukowane informacje wysyłane były do komputera głównego, który odpowiedzialny był za interpretację wyników detekcji i realizację pozostałej części ścieżki przetwarzania aż do wyniku, którym była sugestia decyzji sędziowskiej. Poza wymienioną funkcją główną, komputer dodatkowo:

- komunikował się z układem synchronizacji
- zarządzał konfiguracjami sprzętowymi kamer i komunikacją z nimi
- zarządzał bazą parametrów zewnętrznych kamer
- tworzył animację poglądową i obsługiwał komunikację z użytkownikiem

4.3.6 Środowisko symulacyjne


Ewaluacja poszczególnych części systemu przy użyciu rzeczywistych danych zbieranych podczas eksperymentów w przypadku systemów takich jak opisywany bywa trudna, a w niektórych przypadkach niemożliwa. Dzieje się tak ze względu na:

- trudno dostępne systemy o dokładności o rząd wielkości lepszej niż projektowane rozwiązanie pozwalającego na pomiar położenia lecącej piłki w warunkach zbliżonych do rzeczywistych. Z tego powodu możliwości uzyskania wyników referencyjnych są ograniczone,
- trudności w powtarzalnym generowaniu analizowanego zdarzenia losowego, takiego jak na przykład poruszenie kamery po zderzeniu z piłką. Trudności związane są z ograniczonymi możliwościami zadawania piłce określonej trajektorii i kosztem elementów systemu, które zużywałyby lub niszczyłyby się podczas testów,
- trudności z wyznaczeniem dokładnego położenia i orientacji **CPP** detektora w **GCS** w związku z różnicami w budowie kamer i obiektywów. Podobnie jak w przypadku śledzenia, tak i tu ogranicza to możliwość generowania danych referencyjnych,
- obecność błędów operatora podczas generowania danych referencyjnych dla algorytmów wykrywających punkty charakterystyczne w **IS**.

W związku z pokazanymi powyżej trudnościami zdecydowano się na uzupełnienie ewaluacji o eksperymenty używające danych syntetycznych. W trakcie badań opracowano sceny testowe pozwalające badać efekty działania poszczególnych modułów.

4.3.6.1 Badanie kalibracji wewnętrznej


W opisywanym systemie do kalibracji wewnętrznej używano algorytmu Zhanga [53]. Analiza dokładności metody w aplikacji związanej z piłką siatkową nie była wymagana, gdyż kalibracja wewnętrzna przeprowadzana była w warunkach laboratoryjnych. W trakcie badań sprawdzano natomiast wpływ jakości wykonania wzorca na wyniki kalibracji zewnętrznej. W tym celu przygotowano zestaw syntetycznych danych kalibracyjnych. Były to obrazy tworzone w środowisku Blender. Dane kalibracyjne przygotowywane były w dwóch wersjach: prostych jednokolorowych bez tła i szumów oraz imitujących papierowy wzorec naklejony na tafłę szkła z dodanymi szumami występującymi w obrazach używanych detektorów (Rysunek 4.14).



Rysunek 4.14 Przykładowe obrazy wzorca kalibracyjnego. Po lewej obraz w wersji uproszczonej; po prawej obraz w wersji imitującej rzeczywisty wzorec

4.3.6.2 Badanie kalibracji zewnętrznej

Wykrywanie punktów charakterystycznych i kalibracja zewnętrzna sprawdzane były w dwóch środowiskach. W początkowej fazie projektu wykorzystywano obrazy syntetyczne wygenerowane na podstawie prostej sceny przygotowanej w oprogramowaniu Autodesk 3DSMax 2016. W scenie nie znajduje się nic prócz banerów, siatki i boiska, a wszystkie elementy są równomiernie oświetlone. Przykładowy obraz syntetyczny z naniesionym wynikiem wykrywania punktu charakterystycznego pokazano na rysunku (Rysunek 4.15).



Rysunek 4.15 Przykładowy obraz syntetyczny na którym zaznaczono referencyjne położenie punktu charakterystycznego (na niebiesko) i położenie wykryte przez algorytm (na czerwono).

W dalszych badaniach silnik 3DSMax został zastąpiony rozwiązaniem firmy Sky Engine, które dostosowane jest do zastosowań naukowych i pozwala kontrolować cały proces generowania danych z poziomu kodu skryptu. W scenie przygotowanej w środowisku Sky Engine znajdują się zawodnicy, trybuny i pozostałe elementy hali. Dobrane są także materiały, które imitują te spotykane w rzeczywistości. Przykładowy obraz generowany w opisany powyżej sposób pokazano na rysunku (Rysunek 4.16).



Rysunek 4.16 Przykładowy obraz syntetyczny uzyskany przy użyciu środowiska Sky Engine.

Dodatkową zaletą wynikającą z użycia środowiska Sky Engine jest możliwość zdefiniowania scenariuszy testowych. W ramach tych scenariuszy możliwe było:

- definiowanie trajektorii piłki na podstawie równania,
- definiowanie parametrów wewnętrznych i zewnętrznych kamer w formie macierzowej,
- zdefiniowanie charakteru i zakresu losowych zmian w scenie tj. np. zmiana koloru boiska lub układu reklam,
- zdefiniowanie charakteru zmian oświetlenia.

Przykładowy zestaw obrazów generowanych w ramach jednego scenariusza pokazano na rysunku (Rysunek 4.17).



Rysunek 4.17 Przykładowe obrazy syntetyczne będące częścią jednego ze scenariuszy testowych wykorzystywanych do ewaluacji działania komponentów systemu.


4.3.7 Ewaluacja poprawności działania systemu

Badanie jakości działania systemu przeprowadzono z użyciem danych numerycznych generowanych za pomocą skryptu (ilościowe badanie dokładności bezwzględnej) i danych syntetycznych (jakościowe badanie dokładności w scenariuszu odpowiadającym rzeczywistej sytuacji w trakcie meczu). W trakcie ewaluacji wykonano następujące eksperymenty:

1. Wykrywanie pozycji punktów charakterystycznych – narożników boiska - w **IS** dla zmiennych pozycji detektora względem boiska na obrazach syntetycznych.
2. Wykonywanie kalibracji zewnętrznej i porównywanie pozycji środka objętości pomiarowej z referencyjną pozycją środka otrzymaną na podstawie wiedzy o geometrii syntetycznej sceny.
3. Rekonstrukcja współrzędnych w **GCS** dla piłki poruszającej się po zadanej trajektorii na obrazach syntetycznych.
4. Eksperyment imitujący rzeczywistą sytuację w trakcie meczu z użyciem armatki do piłek i fantomu ludzkiej dłoni

4.3.7.1 Wykrywanie punktów charakterystycznych


W opisywanym scenariuszu testowym badano dokładność wyznaczania pozycji obrazów punktów charakterystycznych w **IS** dla 120 pozycji detektorów rozmieszczonych tak jak pokazano na rysunku (Rysunek 4.18).




Rysunek 4.18 Pozycje kamer w trakcie badania dokładności wykrywania punktów charakterystycznych. I – widok z góry, II – widok z boku, A – środek geometryczny połowy boiska [58].

Detektory rozmieszczone były w odległości 5 m od boiska, na trzech wysokościach: 5 m, 5,5 m, 6 m. Dla każdej z wysokości detektor umieszczano w jednej z 40 pozycji równomiernie rozłożonych wzdłuż osi X pomiędzy linią końcową a linią środka boiska. W każdej z pozycji oś optyczna kamery skierowana była na punkt A, który reprezentuje środek geometryczny połowy boiska.

Dla każdej z pozycji kamer generowano obraz, na którym wykrywane były punkty charakterystyczne. Następnie porównywano wartości wykrytych współrzędnych z wartościami referencyjnymi. Obliczano różnice dla każdej ze współrzędnych (Rysunek 4.19) oraz odległość kartezyjską pomiędzy dwoma punktami – wykrytym i referencyjnym – w **IS** (Rysunek 4.20).



Rysunek 4.19 Histogram rozkładu błędów detekcji wyrażonych jako różnica między wykrytymi a referencyjnymi współrzędnymi X (niebieski) i Y (czerwony) punktu kluczowego w IS.



Rysunek 4.20 Histogram rozkładu błędów detekcji wyrażonych jako odległość kartezjańska między wykrytymi a referencyjnymi punktami kluczowymi w IS

Dla tak wyznaczonych błędów obliczono wartość średnią i odchylenie standardowe. Wyniki zostały pokazane w tabeli (Tabela 4.6).


X [px]		Y [px]		Odległość [px]	
Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe
-0,011	0,226	-0,033	0,164	0,253	0,123

Tabela 4.6 Średnie wartości i odchylenia standardowe niepewności detekcji punktów charakterystycznych

4.3.7.2 Kalibracja zewnętrzna

Eksperyment wykonano w dwóch wersjach: przy założeniu idealnej detekcji i przy założeniu detekcji obciążonej wartościami niepewności obliczonymi w poprzednim eksperymencie.

Podobnie jak w przypadku ewaluacji algorytmów detekcji punktów charakterystycznych tak i tu detektory rozmieszczone były równomiernie wzdłuż dłuższej krawędzi w sposób pokazany na rysunku (Rysunek 4.21).



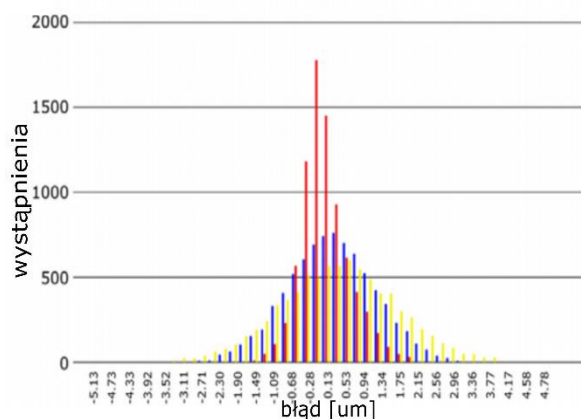
Rysunek 4.21 Rozkład pozycji detektora w trakcie ewaluacji dokładności kalibracji zewnętrznej [5]. Po lewej – widok z góry, po prawej widok z boku

W pierwszej wersji eksperymentu sprawdzano poprawność algorytmu i numeryczne uwarunkowanie problemu. Do metody kalibracji opisywanej w poprzednim rozdziale użyto referencyjnych wartości współrzędnych punktów charakterystycznych widocznych w danej pozycji kamery. W drugiej wersji do referencyjnych wartości współrzędnych dodawano szum imitujący rozkład pokazany na rysunku (Rysunek 4.19) i w tabeli (Tabela 4.6). przybliżony rozkładem normalnym o wartości średniej 0,25px i odchyleniu standardowym 0,125px.

Analizę dokładności wyznaczania pozycji i orientacji detektora przeprowadzono analizując położenie dodatkowego wirtualnego punktu – punktu na który patrzy kamera **T** (ang. target). Znajduje się on na osi optycznej detektora (osi **Z** lokalnego układu współrzędnych) w odległości 6,56 m od **NP**. Odległość ta jest średnią odległością **NP** od punktu w którym oś optyczna przecina płaszczyznę boiska obliczaną dla pozycji detektorów w systemie. Na podstawie parametrów zewnętrznych wyznaczonych w procesie kalibracji możliwe jest wyznaczenie położenia **T** w **GCS**. Po wyznaczeniu położenia zarówno za pomocą danych eksperymentalnych, jak i danych referencyjnych, przesunięcie pomiędzy dwoma powstałymi punktami pozwala ilościowo mierzyć dokładność wyznaczania zarówno położenia jak i orientacji detektora.

Wyniki osiągnięte po przeprowadzeniu pierwszej wersji eksperymentu pokazano na rysunku (Rysunek 4.22 Przesunięcia między transformacjami punktu **T** wykonanymi za pomocą wyznaczonych i referencyjnych parametrów zewnętrznych w pierwszej wersji eksperymentu. Czerwony – współrzędna **X**, niebieski – współrzędna **Y**, żółty – współrzędna **Z**). Przesunięcia między transformacjami punktu **T** wykonanymi za pomocą wyznaczonych i referencyjnych

parametrów zewnętrznych w pierwszej wersji eksperymentu. Czerwony – współrzędna X, niebieski – współrzędna Y, żółty – współrzędna Z.



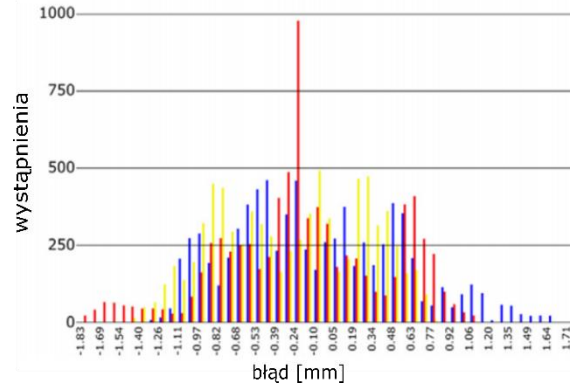
Rysunek 4.22 Przesunięcia między transformacjami punktu T wykonanymi za pomocą wyznaczonych i referencyjnych parametrów zewnętrznych w pierwszej wersji eksperymentu. Czerwony – współrzędna X, niebieski – współrzędna Y, żółty – współrzędna Z.

Dla przesunięć wyznaczono wartości średnie i odchylenia standardowe. Wyniki pokazano w tabeli (Tabela 4.7).

X [μm]		Y [μm]		Z [μm]	
Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe
0,013	0,6	-0,091	0,33	0,013	0,6

Tabela 4.7 Średnie wartości i odchylenia standardowe przesunięć współrzędnych transformacji punktu T w wersji bez dodanego szumu.

Wartości przesunięć rzędu 10^{-6} m, rozkład zbliżony do normalnego i brak punktów odstających pokazał, że dla badanego zakresu położen detektorów, dokładność metody zależy wyłącznie od dokładności wyznaczenia punktów charakterystycznych. Wyniki osiągnięte w drugiej wersji eksperymentu pokazano na rysunku (Rysunek 4.23).



Rysunek 4.23 Przesunięcia między transformacjami punktu T wykonanymi za pomocą wyznaczonych i referencyjnych parametrów zewnętrznych w drugiej wersji eksperymentu. Czerwony – współrzędna X , niebieski – współrzędna Y , żółty – współrzędna Z .

Dla przesunięć wyznaczono wartości średnie i odchylenia standardowe. Wyniki pokazano w tabeli (Tabela 4.8).


X [mm]		Y [mm]		Z[mm]	
Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe	Wartość średnia	Odchylenie standardowe
0,007	0,63	-0,16	0,61	0,013	0,6

Tabela 4.8 Średnie wartości i odchylenia standardowe przesunięć współrzędnych transformacji punktu T w wersji z dodanym szumem

Pomiary wykonywane były w objętości pomiarowej 9mx9mx3m, błąd 1,03 mm stanowi zatem 0,08% przekątnej prostopadłościanu wyznaczającego objętość pomiarową.

4.3.7.3 Rekonstrukcja współrzędnych 3D

W trakcie ewaluacji dokładności rekonstrukcji współrzędnych 3D utworzono stereopary z detektorów umieszczonych w położeniach 1 i 2 z rysunku położen kamer (Rysunek 4.10) na trzech różnych wysokościach pokazanych na rysunku (Rysunek 4.18). Sprawdzano wpływ dokładności detekcji środka piłki na ostateczny wynik śledzenia. Wykonano dwie wersje eksperymentu: dla dwóch nieruchomych kamer i w sytuacji, gdy w trakcie ruchu piłki jedna z kamer została przesunięta o 0,1m. W obu przypadkach analizowano trajektorię ruchu piłki w postaci parabol utworzonych przez rzut ukośny z trzema odbiciami, którego pozycje pokazano na rysunku (Rysunek 4.24). Rzut wykonano równoległe do dłuższej krawędzi boiska w połowie jego szerokości.




Rysunek 4.24 Trajektoria ruchu piłki analizowana w trakcie ewaluacji dokładności rekonstrukcji 3D.

W trakcie eksperymentu wyznaczano współrzędne środka piłki w **GCS** na podstawie jego obrazu w **IS**. Współrzędne w dziedzinie obrazu wyznaczano dodając szum normalny o wartości średniej 0,5 px i odchyleniu standardowym 0,25 px (imitujący rozkład błędów detekcji środka piłki) do referencyjnych wartości współrzędnych środka piłki. Referencyjne współrzędne

środku piłki wyznaczono analitycznie stosując równanie projekcji (równanie 2.1.5) do przekształcania kolejnych położeń 3D piłki w GCS.

Następnie dla każdej klatki porównywano referencyjne współrzędne środka piłki z wartościami otrzymanymi za pomocą algorytmu rekonstrukcji. Porównanie wykonywano tak samo jak w przypadku eksperymentu sprawdzającego dokładność wykrywania punktów charakterystycznych. Histogramy różnic współrzędnych otrzymane dla przykładowej pary pokazano na rysunku (Rysunek 4.25).



Rysunek 4.25 Przykładowe histogramy różnic referencyjnych i wyznaczonych współrzędnych środków piłki w GCS. Czerwony – współrzędna X, niebieski – współrzędna Y, żółty – współrzędna Z

Dla rozkładów różnic wyznaczono wartości średnie i odchylenia standardowe. Wyniki zestawiono w tabeli (Tabela 4.9).

Wysokość 5m; Bez przesunięcia	wartość średnia X [mm]	-0,06	Odchylenie standardowe X [mm]	2,33
	wartość średnia Y [mm]	-0,01	Odchylenie standardowe Y [mm]	6,33
	wartość średnia Z [mm]	0,10	Odchylenie standardowe Z [mm]	2,84
	średnia odległość [mm]	6.17	Odchylenie standardowe odległości [mm]	3,91
Wysokość 5,5m; Bez przesunięcia	wartość średnia X [mm]	-0,07	Odchylenie standardowe X [mm]	2,38
	wartość średnia Y [mm]	-0,01	Odchylenie standardowe Y [mm]	6,44
	wartość średnia Z [mm]	0,11	Odchylenie standardowe Z [mm]	3,17
	średnia odległość [mm]	6,36	Odchylenie standardowe odległości [mm]	4,06
Wysokość 6m; Bez przesunięcia	wartość średnia X [mm]	-0,07	Odchylenie standardowe X [mm]	2,44
	wartość średnia Y [mm]	-0,02	Odchylenie standardowe Y [mm]	6,56
	wartość średnia Z [mm]	0,12	Odchylenie standardowe Z [mm]	3,52

	średnia odległość [mm]	6,58	Odchylenie standardowe odległości [mm]	4,24
Wysokość 5m; Przesunięcie	wartość średnia X [mm]	-0,06	Odchylenie standardowe X [mm]	2,3
	wartość średnia Y [mm]	-0,01	Odchylenie standardowe Y [mm]	6,22
	wartość średnia Z [mm]	0,10	Odchylenie standardowe Z [mm]	2,80
	średnia odległość [mm]	6,08	Odchylenie standardowe odległości [mm]	3,82
Wysokość 5,5m; Przesunięcie	wartość średnia X [mm]	-0,07	Odchylenie standardowe X [mm]	2,35
	wartość średnia Y [mm]	-0,01	Odchylenie standardowe Y [mm]	6,32
	wartość średnia Z [mm]	0,11	Odchylenie standardowe Z [mm]	3,12
	średnia odległość [mm]	6,27	Odchylenie standardowe odległości [mm]	3,97
Wysokość 6m; Przesunięcie	wartość średnia X [mm]	-0,07	Odchylenie standardowe X [mm]	2,41
	wartość średnia Y [mm]	-0,01	Odchylenie standardowe Y [mm]	6,44
	wartość średnia Z [mm]	0,12	Odchylenie standardowe Z [mm]	3,46
	średnia odległość [mm]	6,47	Odchylenie standardowe odległości [mm]	4,14

Tabela 4.9 Wyniki ewaluacji rekonstrukcji współrzędnych 3D w GCS

Wyniki zestawione w tabeli 4.9 pokazują, że błąd śledzenia detektora jest powiązany z pozycją detektora w GCS. Z jednej strony kalibracja zewnętrzna jest przeprowadzana w oparciu o wykryte pozycje punktów charakterystycznych (narożników boiska), a te wykrywane są lepiej, gdy detektor znajduje się na większej wysokości. Z drugiej strony błąd wyznaczenia pozycji piłki w danej osi zależy od kąta pomiędzy tą osią, a osią optyczną detektora. O ile błędy w osiach X i Y mogą być kompensowane (kamery znajdują się dookoła boiska), to dla błędów w osi Z, które są tym większe im wyżej znajduje się detektor, nie jest to możliwe. Analiza obu zależności doprowadziła do ustalenia optymalnej (w sensie minimalizacji średniego błędu reprojekcji) wysokości – 5,5m.

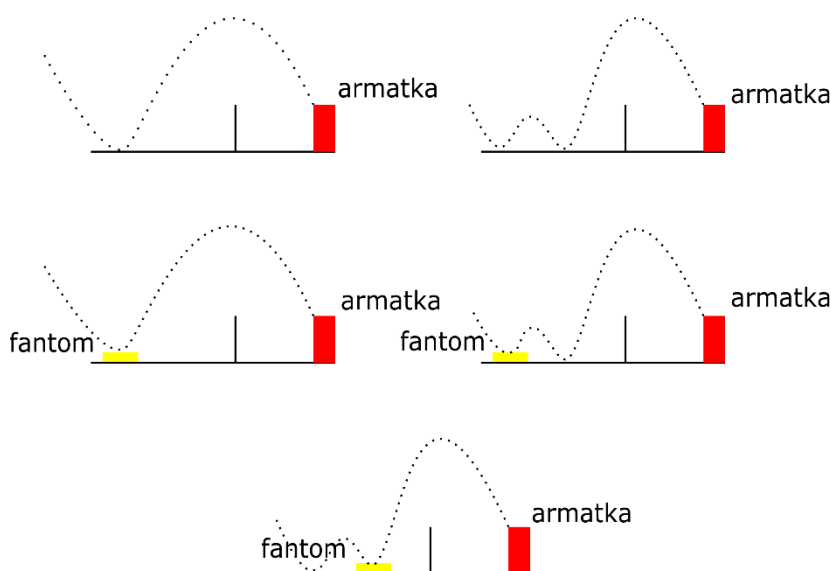
4.3.7.4 Symulacja rzeczywistej sytuacji meczowej

W celu ostatecznej weryfikacji systemu, przeprowadzony został eksperyment symulujący rzeczywistą sytuację meczową – podłożenie ręki. Sytuację odtworzono w trakcie eksperymentu przeprowadzonego na prawdziwym boisku. W trakcie jego przeprowadzania używano armatki aby wystrzeliwać piłkę z prędkością 100-120 km/h po trajektorii zbliżonej do tej obserwowanej podczas serwisów. Po drugiej stronie boiska piłka odbijała się od płaszczyzny boiska lub od fantomu ludzkiej ręki o średniej grubości 20 mm zamocowanego na powierzchni boiska. Całość

obserwowana była przez VBS, który na podstawie analizy trajektorii wyznaczał wysokość na której odbiła się piłka. Rozważano pięć scenariuszy:

1. Pojedyncze odbicie od płaszczyzny boiska
2. Wielokrotne odbicia od płaszczyzny boiska
3. Pojedyncze odbicie od fantomu ręki
4. Wielokrotne odbicia z których pierwsze było od fantomu ręki a pozostałe od płaszczyzny boiska
5. Wielokrotne odbicia z których drugie było od fantomu ręki a pozostałe od płaszczyzny boiska


Schematyczny przebieg prezentowanych scenariuszy pokazano na rysunku (Rysunek 4.26).



Rysunek 4.26 Scenariusze testowe eksperymentu z użyciem fantomu ludzkiej ręki

W każdym z pięciu scenariuszy wykonano 15 powtórzeń. Zarejestrowaną wysokość odbicia oznaczano na podstawie wiedzy a priori jako odbicie od płaszczyzny boiska lub od fantomu ręki. Następnie dla tak przygotowanych danych przeanalizowano rozkłady wysokości odbić dla dwóch opisanych powyżej klas. Dla rozkładów sporządzono histogramy (Rys 29) oraz policzono średnią wysokość i odchylenie standardowe. Dla odbić od płaszczyzny boiska średnia wysokość wynosiła 113.33 mm a jej odchylenie standardowe 3.8 mm. Dla odbić od fantomu średnia wysokość była równa 133.62 mm a odchylenie standardowe 3.8 mm. Różnica między wartościami średnimi odpowiadała grubości fantomu. Jak widać na rozkładach pokazanych na rysunku (Rysunek 4.27) odległość między rozkładami pozwala na opracowanie

i rozwój algorytmów decyzyjnych, które pozwolą na wsparcie sędziego w czasie analizowanej sytuacji.



Rysunek 4.27 Histogramy wartości obliczonej wysokości odbicia. Niebieski – odbicia od płaszczyzny boiska, czerwony – odbicia od fantomu ręki

5 Podsumowanie

5.1 Wypełnienie celów badawczych

Na początku niniejszej rozprawy postawiono naukowe cele badawcze, które zostały osiągnięte. Sformułowano również tezę, która została udowodniona. Poniższe sekcje w sposób szczegółowy podsumowują wykonane prace. .

5.1.1 Opracowanie metody kalibracji i re-kalibracji pozycji i orientacji kamery

W trakcie realizacji powyższego celu zbadano problem wzajemnych relacji geometrycznych obiektów w scenie oraz modeli matematycznych opisujących te relacje (Rozdział 2.1). Następnie dokonano przeglądu literatury metod wyznaczania pozycji i orientacji kamery (Rozdział 2.2) pod kątem dokładności, ograniczeń i możliwości re-kalibracji. Następnie opracowano autorskie metody, rozszerzające możliwości istniejących, które pozwalają na wykrycie zdarzenia losowego (Rozdział 3.3.3), adaptację ROI (Rozdział 3.3.1), i aktualizację pozycji i orientacji kamery. Metody te została zaimplementowana w systemie wspierającym podejmowanie decyzji sędziowskich (Rozdział 4.4) i zweryfikowana doświadczalnie, co pokazano w publikacji:

K. Szelaż, P. Kurowski, P. Bolewicki i R. Sitnik, „Real-time camera pose estimation based on volleyball court view.,” *Opto-Electronics Review*, pp. 59-66, 2019.

5.1.2 Opracowanie metody analitycznej kompensacji błędów projekcji perspektywicznej związanych z charakterem wybranych modeli kamer

Realizację celu rozpoczęto od identyfikacji matematycznego charakteru błędów projekcji. Zidentyfikowano je jako błąd ekscentryczności, który następnie poznano i przeanalizowano podczas przeglądu literatury (Rozdział 2.3). Ze względu na ograniczenia istniejących metod i charakter rozważanych zastosowań, realizacja celu wymagała opracowania nowej, autorskiej metody analitycznej kompensacji tego błędu (Rozdział 3.3.5). Rezultaty osiągnięte przez metodę pozwoliły na skuteczną, w rozumieniu projektowanych aplikacji, kompensację tego błędu.

5.1.3 Opracowanie modyfikacji algorytmu kalibracji wewnętrznej w sytuacji niedoboru danych kalibracyjnych.

Realizację celu badawczego rozpoczęto od analizy problemu kalibracji wewnętrznej w systemach wizyjnych (Rozdział 2.2). W trakcie przeglądu analizowano skuteczność metod w odniesieniu do ograniczonej liczby danych pomiarowych i prostoty procedury kalibracyjnej. Jako metodę bazową, której modyfikacja spełniałaby założenia celu badawczego, wybrano hybrydową metodę kalibracji Zhanga, którą zbadano i przeanalizowano (Rozdział 2.1.10,2.1). Następnie opracowano autorską modyfikację, która na podstawie wiedzy a priori o scenie redukowałą złożoność problemu (Rozdział 3.3.2). Rozwinięta metoda została zaimplementowana w niskokosztowym skanerze światła strukturalnego (Rozdział 4.3), a zastosowanie jej pozwoliło na osiągnięcie błędu pomiarowego $<0,4$ mm co stanowiło 0,13% wymiaru przekątnej objętości pomiarowej.

Opis metody, systemu oraz metod weryfikacji zawarty jest w publikacji:

K. Szelağ, G. Mączkowski, R. Gierwiało, A. Gębarska i R. Sitnik, „Robust geometric, phase and colour structured light projection system calibration.,” *Opto-Electronics Review*, pp. 326-336, 2017.

5.2 Realizacja celów użytkowych

Równoległe z realizacją celów badawczych w trakcie projektów aplikacyjnych rozwijano praktyczne implementacji opracowywanych metod, co pozwoliło na realizację celów użytkowych.

5.2.1 Opracowanie uogólnionego modelu wizyjnego systemu śledzenia obiektu w przestrzeni trójwymiarowej

Realizację celu rozpoczęto od analizy problemu śledzenia jako złożonego systemu składającego się z wielu współpracujących ze sobą elementów realizujących pojedyncze zadania. W wyniku analizy powstał schemat koncepcyjny pokazany w Rozdziale 3.2. Następnie dla każdego z elementów sformułowano wymagania użytkowe, cele, informacje wejściowe i wyjściowe i przeanalizowano je w odniesieniu do już zaimplementowanych aplikacji (pokazanych w rozdziałach 4.2 oraz 4.3).

Rozwój algorytmów i wprowadzanie autorskich modyfikacji przeprowadzane w trakcie badań dotyczyło problemów rozważanych w kontekście zdefiniowanych modułów funkcjonalnych. W trakcie prac zaprojektowany został moduł zarządzania transformacjami, który pozwalał na matematyczny opis dowolnie złożonego układu wielokamerowego. To, wraz z dekompozycją problemu na podproblemy pozwalało na rozważanie każdej z aplikacji w ramach uogólnionego modelu, co pozwala twierdzić, że zrealizowano postawiony cel.

5.2.2 Projekt i implementacja nisko-kosztowego skanera światła strukturalnego

W trakcie badań zaprojektowano i wdrożono nisko-kosztowy skaner światła strukturalnego, który znalazł się w ofercie firmy SMARTTECH3D, z którą prowadzono prace w ramach projektu ACTPHAST (Access Center for Photonics Innovation Solutions and Technology Support) o nazwie „A low-cost 3D scanner with calibrated color measurement”.

5.2.3 Projekt i implementacja systemu wspomagającego podejmowanie decyzji sędziowskich w piłce siatkowej

W trakcie badań zaprojektowano i przetestowano dokładność systemu wspomagającego decyzje sędziowskie. W ramach prowadzonych badań ukończono prototyp systemu (proof-of-concept), a w czasie pisania niniejszej pracy prowadzone są komercyjne działania wdrożeniowe, których celem jest osiągnięcie gotowości produkcyjnej.

5.3 Udowodnienie postawionej tezy pracy

W pracy postawiono tezę, że możliwe jest opracowanie metody umożliwiającej pozycjonowanie kamery w znanym środowisku w czasie rzeczywistym z dokładnością wyrażoną przez średni błąd wyznaczenia pozycji kamery mniejszy niż 0,01 % wymiaru przekątnej objętości pomiarowej, która umożliwia wspieranie decyzji sędziowskich, a tak wyznaczone pozycje kamery pozwalają na śledzenie środka geometrycznego piłki w przestrzeni z dokładnością wyrażoną przez średnią niepewność wyznaczania jego środka mniejszą niż 0,1% wymiaru przekątnej objętości pomiarowej. Podczas badań opracowano metody, które pozwoliły zaimplementować system wspomagania decyzji sędziowskich, w którym oba te parametry zostały spełnione. Dzięki temu udowodniono postawioną tezę.

5.4 Kierunki dalszych prac

W czasie badań zrealizowano zarówno cele badawcze jak i użytkowe. Powstałe algorytmy i modyfikacje spełniały postawione im wymagania. Opracowano również uogólniony model systemu śledzenia, w ramach którego zaimplementowano dwa systemy, których działanie sprawdzono, co pokazano we wskazanych powyżej publikacjach.

Pomimo tego, w badanym obszarze wciąż istnieją zagadnienia, które mogą być rozwinięte i poprawione. Są to:

1. Opracowanie dodatkowego etapu kalibracji układu kamer, który pozwoli na kompensację błędów wynikających z kalibracji pojedynczych detektorów. Efektem działania etapu byłaby poprawa dokładności wyznaczania względnej transformacji między detektorami przy zachowaniu dokładności wyznaczania transformacji bezwzględnej.
2. Opracowanie hybrydowej metody re-kalibracji, która wykorzystuje informacje zawarte w sekwencji obrazów i łączy zalety algorytmów wyznaczania transformacji względnej i bezwzględnej (rozdział 2.3.2, 2.3.3).
3. Badania nad metodami odtwarzania trajektorii śledzonego obiektu na podstawie informacji z wielu detektorów, jak na przykład metody wykorzystujące otoczkę wizyjną (ang. **visual hull**), lub metody wykorzystujące równania analityczne stożków, których tworzące przechodzą przez ognisko detektora i zbiór wykrytych położeń śledzonego obiektu.
4. Opracowanie metody poprawy dokładności kalibracji detektora na podstawie wiedzy o położeniach innych detektorów (w sytuacji gdy są one widoczne na obrazach).

Obecnie autor prowadzi prace badawcze w kierunkach wskazanych powyżej. Metody pokazane w pracy są wciąż rozwijane, a ich dokładność i niezawodność poprawiane.

6 Bibliografia

- [1] „Forum pasji informatyki,” [Online]. Available: <https://forum.pasja-informatyki.pl/1256/co-to-jest-api>. [Data uzyskania dostępu: 15 grudzień 2020].
- [2] F. Wehnekamp, G. Plucińska, R. Thong, T. Misgeld i D. C. Lamb, „Nanoresolution real-time 3D orbital tracking for studying mitochondrial trafficking in vertebrate axons in vivo,” *Elife*, 2019.
- [3] D. Cafolla, „A 3D visual tracking method for rehabilitation path planning,” *New Trends in Medical and Service Robotics*, pp. 264-272, 2019.
- [4] H. V. Nguyen, M. Chesser, L. P. Koh, H. S. Rezatofighi i D. C. Ranasinghe, „TrackerBots: Autonomous unmanned aerial vehicle for real-time localization and tracking of multiple radio-tagged animals,” *Journal of Field Robotics*, pp. 617-635, 2019.
- [5] J. Kwon i K. M. Lee, „ Visual tracking decomposition,” w *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2010.
- [6] E. Ristani, F. Solera, R. Zou, C. R. i C. Tomasi, „Performance measures and a data set for multi-target, multi-camera tracking,” w *European conference on computer vision*, 2016.
- [7] G. R. Müller i J. Conradt, „A miniature low-power sensor system for real time 2D visual tracking of LED markers,” w *2011 IEEE International Conference on Robotics and Biomimetics*, 2011.
- [8] Y. Liu, M. Storrington, T. B. Moeslund, C. B. Madsen i E. Granum, „Computer vision based head tracking from re-configurable 2d markers for ar,” w *The Second IEEE and ACM International Symposium on Mixed and Augmented Reality, 2003. Proceedings*, 2003.
- [9] E. Stoykova, A. Ayd, P. Benzie, N. Grammalidis, S. Malassiotis, J. Ostermann i X. Zabulis, „3-D time-varying scene capture technologies—A survey,” *IEEE Transactions on Circuits and Systems for Video Technology*, 2007.

- [10] F. B. Sufi, J. D. D. Gazzano, F. R. Calle i J. C. L. Lopez, „Multi-Camera Tracking System Applications Based on Reconfigurable Devices: A Review.,” w *In 2019 International Conference on Computer, Communication, Chemical, Materials and Electronic Engeneering*, 2019.
- [11] Y. Huang, H. Ding, Y. Zhang, H. Wang, D. Cao, N. Xu i C. Hu, „A Motion Planning and Tracking Framework for Autonomous Vehicles Based on Artificial Potential Field Elaborated Resistance Network Approach.,” *IEEE Transactions on Industrial Electronics*, pp. 1376-1386, 2019.
- [12] X. Cheng, Y. Zhao i T. Ikenaga, „Representative Spatial Selection and Temporal Combination for 60fps Real-Time 3D Tracking of Twelve Volleyball Players on GPU.,” *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, pp. 1882-1890, 2019.
- [13] P. R. Kamble, A. G. Keskar i K. M. Bhurchandi, „Ball tracking in sports: a survey.,” *Artificial Intelligence Review*, 52(3), , pp. 1655-1705., 2019.
- [14] T. D’Orazio i M. Leo, „A review of vision-based systems for soccer video analysis.,” *Pattern Recognition*, p. 2911–2926, 2010.
- [15] X. Zhao, Y. Zhang i B. Luo, „Energy Minimization Based Alternate Sampling and Clustering for Geometric Model Fitting.,” w *2019 IEEE International Conference on Image Processing* , 2019.
- [16] C. C. Huang i M. H. Nguyen, „Robust 3D Skeleton Tracking based on OpenPose and a Probabilistic Tracking Framework.,” w *2019 IEEE International Conference on Systems, Man and Cybernetics (SMC)*, 2019.
- [17] J. C. Núñez, R. Cabido, J. F. Vélez, A. S. Montemayor i J. J. Pantrigo, „Multiview 3D human pose estimation using improved least-squares and LSTM networks.,” *Neurocomputing*, pp. 335-343, 2019.
- [18] L. Kang, Y. Wei, Y. Xie, J. Jiang i Y. Guo, „Combining convolutional neural network and photometric refinement for accurate homography estimation.,” *IEEE Access* 7, pp. 109460-109473., 2019.

- [19] J. Bernasik, *Elementy fotogrametrii i teledetekcji*, Kraków: Wydawnictwo AGH, 2003.
- [20] P. Sturm, „Pinhole Camera Model,” w *Computer Vision*, Boston, MA, Springer, 2014.
- [21] M. M. Fleck, „Perspective projection: the wrong imaging model.,” *Department of Computer Science, University of Iowa*, pp. 1-27, 1995.
- [22] T. J. Herbert, „Area projections fo fisheye photographic lenses.,” *Agriculture and Forest Meteorology*, pp. 215-223, 1987.
- [23] V. Usenko, N. Demmel i D. Cremers, „The Double Sphere Camera Model,” w *2018 International Conference on 3D Vision (3DV). IEEE*, 2018.
- [24] R. Sitnik, „New method of structure light measurement system calibration based on adaptive and effective evaluation of 3D-phase distribution.,” *Optical Measurement System for Industrial Inspection IV*, pp. 109-117, June 2005.
- [25] Q. Zhang i R. Pless, „Extrinsic calibration of a camera and raser range finder (improves camera calibration),” w *2004 IEEE/RSI International Conference on Intelligent Robots and Systems (IROS)*, 2004.
- [26] K. Shoemake, „Animating rotation with quaternion curves.,” w *Proceedings of the 12th annual conference on Computer graphics and interactive techniques.*, 1985.
- [27] L. Kavan, S. C. Collins i J. Zara, „Dual quaternions for rigid transformation blending.,” Trinitiy College Dublin, Tech. Rep, 2006.
- [28] S. Li, G. Zhang i Z. Wei, „The determination of the intrinsic and extrinsic camera parameters of virtual camera based on OpenGL.,” w *Sixth International Symposium on Instrumentation and Control Technology: Sensors, Automatic Measurement, Control and Computer Simulation.*, 2006.
- [29] R. Liu, H. Zhang, M. Liu, X. Xia i T. Hu, „Stereo cameras self-calibration based on sift,” w *2009 International Conference on Measuring Technology and Mechatronics Automation*, 2009.
- [30] Z. Lv i Z. Zhang, „Build 3D scanner system based in binocular stereo vision.,” *Journal of computers*, pp. 399-404, 2012.

- [31] R. Mukundan, „Quaternions: From classical mechanics to computer graphics, and beyond,” w *Proceedings of the 7th Asian Technology conference in Mathematics*, 2002.
- [32] E. B. Dam, M. Koch i M. Lillholm, „Quaternions, interpolation and animation,” Copenhagen: Datalogisk Institut, Københavns Universitet, Copenhagen, 1998.
- [33] G. R. Veldkamp, „On the use of dual numbers, vectors and matrices in instantaneous, spatial kinematics.,” *Mechanism and Machine Theory*, pp. 141-156, 1976.
- [34] D. B. Gennery, „Stereo-camera calibration,” w *Proceedings ARPA IUS Workshop*, 1979.
- [35] Y. Furukawa i J. Ponce, „Accurate camera calibration from multi-view stereo and bundle adjustment,” *International Journal of Computer Vision*, pp. 257-268, 2009.
- [36] C. Strecha, W. Von Hansen, L. Van Gool, P. Fua i U. Thoennessen, „On benchmarking camera calibration and multi-view stereo for high resolution imagery.,” w *2008 IEEE conference on computer vision and pattern recognition*, 2008.
- [37] K. Szelaǳ, G. Mączkowski, R. Gierwiało, A. Gębarska i R. Sitnik, „Robust geometric, phase and colour structured light projection system calibration.,” *Opto-Electronics Review*, pp. 326-336, 2017.
- [38] D. Burschkal, S. Lee i G. Hager, „Stereo-based obstacle avoidance in indoor environments with active sensor re-calibration.,” w *Proceedings 2002 IEEE International Conference on Robotics and Automation*, 2002.
- [39] B. Lamprecht, „Extrinsic camera calibration for an on-board two-camera system without overlapping field of view.,” w *2007 IEEE Intelligent Transportation Systems Conference*, 2007.
- [40] D. C. Brown, „Close-range camera calibration.,” *Photogramm. Eng.*, pp. 855-866, 1971.
- [41] K. W. Wong, „Mathematical formulation and digital analysis in close-range photogrammetry.,” *Photogrammetric Engineering and Remote Sensing*, 1975.
- [42] Y. I. Abdel-Aziz i H. M. Karara, „Direct linear transformation from comparator coordinates into object space coordinates in close range photogrammetry,” w *Symposium on Close Range Photogrammetry*, 1971.

- [43] D. Claus i A. W. Fitzgibbon, „A rational function lens distortion model for general cameras.,” w *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2005.
- [44] I. E. Sutherland, „Three-dimensional data input by tablet.,” w *Proceedings of the IEEE*, 1974.
- [45] S. Ganapathy, „Decomposition of transformation matrices for robot vision.,” *Pattern Recognition Letters*, pp. 401-412.
- [46] G. H. Golub i C. F. Van Loan, *Matrix computations*, The Johns Hopkins University Press Baltimore, 1989.
- [47] L. O. U. Yan, „Linear Algorithm of Camera Self-Calibration Based on Null Space Projection and RQ Decomposition.,” *Computer Knowledge and Technology*, 2008.
- [48] N. Guilbert, A. Bartoli i A. Heyden, „Affine approximation for direct batch recovery of euclidian structure and motion from sparse data.,” *International Journal of Computer Vision*, pp. 317-333, 2006.
- [49] R. Tsai, „A versatile camera calibration technique for high-accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses.,” *IEEE Journal on Robotics and Automation*, pp. 323-344, 1987.
- [50] A. Izaguirre, P. Pu i J. Summers, „A new development in camera calibration: Calibrating a pair of mobile cameras.,” *The international journal of robotics research.*, pp. 104-116, 1987.
- [51] H. A. Martins, J. R. Birk i R. B. Kelley, „Camera models based on data from two calibration planes.,” *Computer Graphics and Image Processing*, pp. 173-180, 1981.
- [52] R. Sitnik, „Phase scalling using characteristic polynomials.,” *Interferometry XII: Applications*, pp. 211-217, 2004.
- [53] Z. Zhang, „A flexible new technique for camera calibration.,” *IEEE Transactions on pattern analysis and machine intelligence*, pp. 1330-1334, 2000.

- [54] J. Salvi, J. Batlle i E. Mouaddib, „A robust-coded pattern projection for dynamic 3D scene measurement.,” *Pattern Recognition Letters*, pp. 1055-1065, 1998.
- [55] J. J. Dongarra, C. B. Moler, J. R. Bunch i G. W. Stewart, „LINPACK users' guide,” *Society for Industrial and Applied Mathematics*, 1979.
- [56] J. J. Moré, „The Levenberg-Marquardt algorithm: implementation and theory,” *Numerical analysis*, pp. 105-116, 1978.
- [57] T. Shimizu, R. Hachiuma, H. Saito, T. Yoshikawa i C. Lee, „Prediction of future shot direction using pose and position of tennis player.,” w *Proceedings of the 2nd International Workshop on Multimedia Content Analysis in Sports*, 2019.
- [58] K. Szelag, P. Kurowski, P. Bolewicki i R. Sitnik, „Real-time camera pose estimation based on volleyball court view.,” *Opto-Electronics Review*, pp. 59-66, 2019.
- [59] V. Fremont i R. Chellali, „Direct camera calibration using two concentric circles from a single view,” w *International Conference on Artificial Reality and Teleexistence*, 2002.
- [60] N. Homayounfar, S. Fidler i R. Urtasun, „Sports field localization via deep structured models.,” w *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [61] M. Dawood, C. Cappelle, M. E. El Najjar, M. Khalil i D. Pomorski, „Harris, SIFT and SURF features comparison for vehicle localization based on virtual 3D model and camera.,” w *2012 3rd International Conference on Image Processing Theory, Tools and Applications*, 2012.
- [62] D. G. Lowe, „Distinctive image features from scale-invariant keypoints.,” *International journal of computer vision*, pp. 91-110, 2004.
- [63] H. Bay, A. Ess, T. Tuytelaars i L. Van Gool, „Speeded-up robust features (SURF).,” *Computer Vision and Image Understanding*, pp. 346-359, 2008.
- [64] P. Siekański, J. Michoński, E. Bunsch i R. Sitnik, „CATCHA: Real-Time Camera Tracking Method for Augmented Reality Applications in Cultural Heritage Interiors.” *ISPRS International Journal of Geo-Information*.

- [65] M. A. Fischler i R. C. Bollers, „Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography.,” *Communications of the ACM*, pp. 381-395, 1981.
- [66] R. Gierwiało, „System rzeczywistości wzbogaconej do wspomagania procesu uczenia na potrzeby zabiegu termoablacji wątroby.,” Doctoral dissertation, The Institute of Micromechanics and Photonics, Warsaw University of Technology., 2011.
- [67] N. Payet i S. Todorovic, „From contours to 3d object detection and pose estimation.,” w *2011 International Conference on Computer Vision*, 2011.
- [68] W. Jiang, J. C. G. Higuera, B. Angles, W. Sun, M. Javan i K. M. Yi, „Optimizing through learned errors for accurate sports field registration.,” w *The IEEE Winter Conference on Applications of Computer Vision*, 2020.
- [69] S. Liu, J. Chen, C. H. Chang i Y. Ai, „A new accurate and fast homography computation algorithm for sports and traffic video analysis.,” *IEEE Transactions on Circuits and Systems for Video Technology*, pp. 2993-3006, 2017.
- [70] M. Magee i J. K. Aggarwal, „Determining vanishing points from perspective images,” *Computer Vision and Image Processing*, pp. 256-267, 1984.
- [71] W. Mou, H. Wang, G. Seet i L. Zhou, „Robust homography estimation based in non-linear least squares optimization,” w *2013 IEEE International Conference on Robotics and Biomimetics*, 2013.
- [72] M. Ozuysal, M. Calonder, V. Lepetit i P. Fua, „Fast keypoint recognition using random terms,” *IEEE transactions on pattern analysis and machine intelligence*, pp. 448-461.
- [73] J. A. Grunert, „Das pothenotische Problem in erweiterter Gestalt nebst uber seine Anwendungen.,” *Grunerts Archiv fur Mathematik und Phusik*, 1841.
- [74] R. M. Haralick, C. N. Lee, K. Ottenburg i M. Nolle, „Analysis and solutions of the three point perspective pose estimation problem.,” *CVPR*, pp. 592-598, 1991.

- [75] D. DeMenthon i L. S. Davis, „Exact and approximate solutions of the perspective-three-point problem.,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 1100-1105, 1992.
- [76] X. S. Gao, X. R. Hou, J. Tang i H. F. Cheng, „Complete solution classification for the perspective-three-point problem.,” *IEEE transactions on pattern analysis and machine intelligence*, pp. 930-943, 2003.
- [77] L. Kneip, D. Scaramuzza i R. Siegwart, „A novel parametrization of the perspective-three-point problem for a direct computation of absolute camera position and orientation.,” *CVPR*, pp. 2969-2976, 2011.
- [78] M. Bujnak, Z. Kukelova i T. Pajdla, „A general solution to the P4P problem for camera with unknown focal length.,” w *2008 IEEE Conference on Computer Vision and Pattern Recognition*, 1-8, 2008.
- [79] B. Triggs, „Camera pose and calibration from 4 or 5 known 3d points.,” w *Proceedings of the Seventh IEEE International Conference on Computer Vision*, 1999.
- [80] L. Quan i Z. Lan, „Linear n-point camera pose determination.,” *IEEE Transactions on pattern analysis and machine intelligence.*, pp. 774-780, 1999.
- [81] P. D. Fiore, „Efficient linear solution of exterior orientation.,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, pp. 140-148., 2001.
- [82] V. Lepetit, F. Moreno-Noguer i P. Fua, „Epnnp: An accurate o (n) solution to the pnp problem.,” *International journal of computer vision*, 2009.
- [83] S. Li, C. Xu i M. Xie, „A robust O (n) solution to the perspective-n-point problem.,” *IEEE transactions on pattern analysis and machine intelligence*, pp. 1444-1450, 2012.
- [84] Y. Zheng, Y. Kuang, S. Sugimoto, K. Astrom i M. Okutomi, „Revisiting the pnp problem: A fast, general and optimal solution.,” w *Proceedings of the IEEE International Conference on Computer Vision*, 2013.
- [85] D. G. Lowe, „Three-dimensional object recognition from single two-dimensional images.,” *Artificial intelligence*, pp. 355-395.

- [86] R. W. Wedderburn, „Quasi-likelihood functions, generalized linear models, and the Gauss—Newton method.,” *Biometrika*, pp. 439-447..
- [87] H. Araujo, R. Carceroni i C. Brown, „A fully projective formulation for Lowe's tracking algorithm.,” 1996.
- [88] J. Weng, N. Ahuja i T. S. Huang, „Optimal motion and structure estimation.,” *IEEE Transactions on pattern analysis and machine intelligence*, pp. 864-884.
- [89] C. P. Lu, G. D. Hager i E. Mjolsness, „Fast and globally convergent pose estimation from video images.,” *IEEE transactions on pattern analysis and machine intelligence*, pp. 610-622, 2000.
- [90] P. Chen i G. D. Hu, „ A simple algorithm for camera pose estimation.,” w *2012 IEEE International Conference on Mechatronics and Automation*, 2012.
- [91] C. L. Zitnick i P. Dollár, „Edge boxes: Locating object proposals from edges.,” w *In European conference on computer vision*, 2014.
- [92] C. Xu, L. Zhang, L. Cheng i R. Koch, „Pose estimation from line correspondences: A complete analysis and a series of solutions.,” *IEEE transactions on pattern analysis and machine intelligence.*, pp. 1209-1222, 2016.
- [93] H. H. Chen, „Pose determination from line-to-plane correspondences: Existence condition and closed-form solutions.,” *IEEE Transactions on Pattern Analysis & Machine Intelligence*, pp. 530-541, 1991.
- [94] M. Dhome, M. Richetin, J. T. Lapreste i G. Rives, „Determination of the attitude of 3D objects from a single perspective view.,” *IEEE transactions on pattern analysis and machine intelligence.*, pp. 1265-1278, 1989.
- [95] V. Caglioti, „The planar three-line junction perspective problem with application to the recognition of polygonal patterns.,” *Pattern recognition*, pp. 1603-1618, 1993.
- [96] N. Navab i O. Faugeras, „Monocular pose determination from lines: Critical sets and maximum number of solutions.,” w *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*.

- [97] R. Kumar i A. R. Hanson, „Robust methods for estimating pose and a sensitivity analysis,” *CVGIP: Image understanding*, , pp. 313-342.
- [98] Y. Liu, T. S. Huang i O. D. Faugeras, „Determination of camera location from 2-D to 3-D line and point correspondences,” *IEEE Transactions on pattern analysis and machine intelligence*, pp. 28-37, 1990.
- [99] S. Christy i R. Horaud, „Iterative pose computation from line correspondences,” *Computer vision and image understanding*, pp. 137-144, 1998.
- [100] F. Dornaika i C. Garcia, „Pose estimation using point and line correspondences,” *Real-Time Imaging*, pp. 215-230, 1999.
- [101] H. S. M. Coxeter, „Non-euclidean geometry,” Cambridge University Press., 1998.
- [102] B. Příbyl, P. Zemčík i M. Čadík, „Camera Pose Estimation from Lines using Plücker Coordinates,” arXiv preprint, 2016.
- [103] Y. Cao, H. Tan i F. Zhou, „Minimal Non-Linear Camera Pose Estimation Method Using Lines for SLAM Application,” w *2018 IEEE Winter Conference on Applications of Computer Vision (WACV)*, 2018.
- [104] A. Vakhitov, J. Funke i F. Moreno-Noguer, „Accurate and linear time pose estimation from points and lines,” w *European Conference on Computer Vision*, 2016.
- [105] S. Ramalingam, S. Bouaziz i P. Sturm, „Pose estimation using both points and lines for geo-localization,” w *2011 IEEE International Conference on Robotics and Automation*, 2011.
- [106] Y. He, C. Jiang, C. Hu, J. Xin, Q. Wu i F. Wang, „Linear pose estimation algorithm based on quaternion,” w *International Conference on Intelligent Computing*, 2011.
- [107] T. D. Barfoot, „Online visual motion estimation using fastslam with sift features,” w *2005 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2005.
- [108] J. L. Charco, B. X. Vintimilla i A. D. Sappa, „Deep learning based camera pose estimation in multi-view environment,” w *2018 14th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, 2018.

- [109] D. DeTone, T. Malisiewicz i A. Rabinovich, „Deep image homography estimation.,” arXiv preprint , 2016.
- [110] S. Belongie, J. Malik i J. Puzicha, „Shape matching and object recognition using shape contexts.,” *IEEE transactions on pattern analysis and machine intelligence*, pp. 509-522., 2002.
- [111] L. Citraro, Márquez-Neila, P., S. Savarè, V. Jayaram, C. Dubout, F. Renaut i P. Fua, „Real-time camera pose estimation for sports fields.,” *Machine Vision and Applications*, pp. 1-13, 2020.
- [112] H. C. Longuet-Higgins, „A computer algorithm for reconstructing a scene from two projections.,” *Nature*, pp. 133-135, 1981.
- [113] O. D. Faugeras i S. Maybank, „Motion from point matches: multiplicity of solutions.,” *International Journal of Computer Vision*, pp. 225-246, 1990.
- [114] D. Nistér, „An efficient solution to the five-point relative pose problem.,” *IEEE transactions on pattern analysis and machine intelligenc*, pp. 756-770.
- [115] D. Batra, B. Nabbe i M. Hebert, „An alternative formulation for five point relative pose problem.,” w *2007 IEEE Workshop on Motion and Video Computing*.
- [116] K. Fathian i N. R. Gans, „A new approach for solving the five-point relative pose problem for vision-based estimation and control.,” w *2014 American Control Conference* , 2014.
- [117] K. Fathian, J. P. Ramirez-Paredes, E. A. Doucette, J. W. Curtis i N. R. Gans, „Quest: A quaternion-based approach for camera motion estimation from minimal feature points.,” *IEEE Robotics and Automation Letters.*, pp. 857-864, 2018.
- [118] K. Fathian, J. Jin, S. G. Wee, D. H. Lee, Y. G. Kim i N. R. Gans, „Camera relative pose estimation for visual servoing using quaternions.,” *Robotics and Autonomous Systems*, pp. 45-62, 2018.
- [119] A. Kipnis i A. Shamir, „Cryptanalysis of the HFE public key cryptosystem by relinearization. In,” w *Annual International Cryptology Conference*, 1999.

- [120] A. Krizhevsky, I. Sutskever i G. E. Hinton, „Imagenet classification with deep convolutional neural networks.,” *Advances in neural information processing systems*, pp. 1097-1105, 2012.
- [121] A. Elqursh i A. Elgammal, „Line-based relative pose estimation.,” w *CVPR 2011*, 2011.
- [122] H. Abdellali, R. Frohlich i Z. Kato, „Robust Absolute and Relative Pose Estimation of a Central Camera System from 2D-3D Line Correspondences.,” w *Proceedings of the IEEE International Conference on Computer Vision Workshops*, 2019.
- [123] R. S. Stanković i B. J. Falkowski, „The Haar wavelet transform: its status and achievements.,” . *Computers & Electrical Engineering*, pp. 25-44, 2003.
- [124] S. G. Mallat, „Multiresolution approximations and wavelet orthonormal bases of $L^2(R)$.,” *Transactions of the American mathematical society*, pp. 69-87, 1989.
- [125] C. Mulcahy, „Image compression using the Haar wavelet transform.,” *Spelman Science and Mathematics Journal*, pp. 22-31, 1997.
- [126] „OpenCV,” [Online]. Available: www.opencv.org. [Data uzyskania dostępu: 11 Grudzień 2020].
- [127] J. Illingworth i J. Kittler, „A survey of the Hough transform.,” *Computer vision, graphics, and image processing*, pp. 87-116.
- [128] S. R. Deans, „The Radon transform and some of its applications.,” Courier Corporation., 2007.
- [129] „<https://scikit-image.org>,” [Online]. Available: https://scikit-image.org/docs/stable/_images/sphx_glr_plot_line_hough_transform_001.png. [Data uzyskania dostępu: 11 grudzień 2020].
- [130] R. Hartley i A. Zisserman, „Multiple view geometry in computer vision.,” Cambridge university press, 2003.
- [131] S. Wold, K. Esbensen i P. Geladi, „Principal component analysis.,” *Chemometrics and intelligent laboratory systems*, pp. 37-52, 1987.

- [132] A. Ansar i K. Daniilidis, „Ansar, Adnan, and Konstantinos Daniilidis. "Linear pose estimation from points or lines.," *IEEE Transactions on Pattern Analysis and Machine Intelligence* , pp. 578-589, 2003.
- [133] H. K. Zhang, W. K. i G. Zhang, „Camera calibration from images of spheres.," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, nr 499-502, 2007.
- [134] A. Murgia, P. J. Kyberd, P. H. Chappell i C. M. Light, „Marker placement to describe the wrist movements during activities of daily living in cyclical tasks.," *Clinical biomechanics*, pp. 248-254, 2004.
- [135] Z. Yu, S. Lincheng, Z. Dianle, Z. Daibing i Y. Chengping, „Camera calibration of thermal-infrared stereo vision system.," w *2013 Fourth International Conference on Intelligent Systems Design and Engineering Applications*, 2013.
- [136] G. Pingali, A. Opalach i Y. Jean, „Ball tracking and virtual replays for innovative tennis broadcasts.," w *Proceedings 15th International Conference on Pattern Recognition*, 2000.
- [137] J. Liao, B. Buchholz, J. M. Thiery, P. Bauszat i E. Eisemann, „Indoor scene reconstruction using near-light photometric stereo.," *IEEE Transactions on Image Processing*, pp. 1089-1101, 2016.
- [138] S. J. Ahn, H. Warnecke i R. Kotowski, „Ahn, S. J., Warnecke, H. J., & Kotowski, R. (1999). Systematic geometric image measurement errors of circular object targets:Mathematical formulation and correction.," *The Photogrammetric Record*, pp. 485-502, 1999.
- [139] T. Luhmann, „Eccentricity images of circular and spherical targets and its impact to 3D object recognition.," *Remote Sensing & Spatial Information Sciences*, p. 45, 2014.
- [140] J. Heikkila i O. Silven, „A four-step camera calibration procedure with implicit image correction.," w *Proceedings of iee computer society conference on computer vision and pattern recognition*.

- [141] Y. Yin, X. Liu, A. Li, C. Zhang, D. He i X. Peng, „Center location error correction of circular targets.,” *Applications of Digital Image Processing* , tom XXXIII , nr 7798, p. 779824, 2010.
- [142] J. Liao, B. Buchholz, J. M. Thiery, P. Bauszat i E. Eisemann, „(2016). Indoor scene reconstruction using near-light photometric stereo.,” *IEEE Transactions on Image Processing*, pp. 1089-1101, 2016.
- [143] L. Guan i M. Pollefeys, „A unified approach to calibrate a network of camcorders and tof cameras.,” 2008.
- [144] G. G. Mateos, „A camera calibration technique using targets of circular features.,” w *In 5th Ibero-America Symposium On Pattern Recognition (SIARP)*.
- [145] R. Shen, I. Cheng i A. Basu, „Multi-camera calibration using a globe,” 2008.
- [146] J. Sun, H. He i D. Zeng, „Global calibration of multiple cameras based on sphere targets.,” *Sensors*, 2016.
- [147] P. Kurowski, K. Szelag, W. Zaluski i R. Sitnik, „Accurate ball tracking in volleyball actions to support referees.,” *Opto-Electronics Review*, pp. 296-306, 2018.
- [148] P. Kurowski, „Research and development of algorithms determining the volleyball ball trajectory basing on 2D image data. Diss. Instytut Mikromechaniki i Fotoniki, 2016.,” Instytut Mikromechaniki i Fotoniki, Warsaw University of Technology, 2016.
- [149] D. Ding, C. Lee i K. Lee, „An adaptive road ROI determination algorithm for lane detection.,” w *2013 IEEE International Conference of IEEE Region*, 2013.
- [150] T. Peli i D. Malah, „A study of edge detection algorithms.,” *Computer graphics and image processing*, pp. 1-21, 1982.
- [151] E. P. Bennett i L. McMillan, „Video enhancement using per-pixel virtual exposures.,” w *ACM SIGGRAPH 2005 Papers*, 2005.
- [152] L. Ding i A. Goshtasby, „On the Canny edge detector.,” *Pattern Recognition*, 2001.
- [153] G. Welch i G. Bishop, *An introduction to the Kalman filter.*, 1995.

- [154] J. J. LaViola, „Double exponential smoothing: an alternative to Kalman filter-based predictive tracking,,” w " *Proceedings of the workshop on Virtual environments*, 2003.
- [155] C. Eckart i G. Young, „The approximation of one matrix by another of lower rank,,” *Psychometrika*, 1936.
- [156] H. Cheng i K. C. Gupta, „An historical note on finite rotations,,” 1989.
- [157] K. Levenberg, „A method for the solution of certain non-linear problems in least squares,,” *Quarterly of applied mathematics*, pp. 164-168., 1944.
- [158] J. Mallon i W. P. F., „Mallon, John, and Paul F. Whelan. "Which pattern? Biasing aspects of planar calibration patterns and detection methods,," *Pattern recognition letters*, pp. 921-930.
- [159] *ISO 10360–2:2009 geometrical product specifications (gps) – acceptance and reverification tests for coordinate measuring machines (cmm) – part 2: Cmms used for measuring linear dimensions*, 2009.
- [160] *Vdi/vde 2617–6, accuracy of cmms – guideline for the application of iso 10360 to cmms with optical distance sensors*.
- [161] K. Khoshelham i S. O. Elberink, „ Accuracy and resolution of kinect depth data for indoor mapping applications,,” *Sensors*, 2012.
- [162] R. Sitnik, M. Kujawinska i J. Woznicki, „Digital fringe projection system for large-volume 360-deg shape measurement,,” *Opt. Eng.*, p. 443–449., 2002.
- [163] „Oficjalne reguły piłki siatkowej według FIVB,,” [Online]. Available: http://www.fivb.org/EN/Refereeing-Rules/documents/FIVB-Volleyball_Rules2013-EN_20121214.pdf. [Data uzyskania dostępu: 17 12 2020].
- [164] D. B. Gennery, „Stereo-camera calibration,,” w *Proceedings ARPA IUS Workshop*, 1979.
- [165] J. L. Charco, B. X. Vintimilla i A. D. Sappa, „Deep learning based camera pose estimation in multi-view environment,,” w *2018 14th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, 2018.

- [166] M. Kujawinska, „Use of phase-stepping automatic fringe analysis in moire interferometry.,” *Applied Optics*, 1987.
- [167] M. A. Fischler i R. C. Bolles, „Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography.,” *Communications of the ACM*, pp. 381-395., 1981.
- [168] J. Zhu, R. L. Wang, Yang i J. Davis, „Fusion of time-of-flight depth and stereo for high accuracy depth maps.,” : *Computer Vision and Pattern Recognition*, pp. 1-8, 2008.
- [169] J. L. Charco, B. X. Vintimilla i A. D. Sappa, „Deep learning based camera pose estimation in multi-view environment.,” w *2018 14th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, 2018.
- [170] K. Fathian, J. Jin, S. G. Wee, D. H. Lee, Y. G. Kim i N. R. Gans, „Camera relative pose estimation for visual servoing using quaternions.,” *Robotics and Autonomous Systems*, pp. 45-62, 2018.
- [171] K. Fathian i N. R. Gans, „A new approach for solving the five-point relative pose problem for vision-based estimation and control.,” w *2014 American Control Conference*, 2014.
- [172] K. Fathian, J. P. Ramirez-Paredes, A. E. Doucette, J. W. Curtis i N. R. Gans, „Quest: A quaternion-based approach for camera motion estimation from minimal feature points.,” *IEEE Robotics and Automation Letters*, pp. 857-864.