

WOJSKOWA AKADEMIA TECHNICZNA
im. Jarosława Dąbrowskiego
WYDZIAŁ MECHATRONIKI, UZBROJENIA I LOTNICTWA



ROZPRAWA DOKTORSKA

kpt. mgr inż. Piotr Bernard TUREK

**Przetwarzanie sygnałów i danych topograficznych
w głowicy samonaprowadzania platformy latającej**

Promotor:

dr hab. inż. Jan PIETRASIŃSKI, prof. WAT

Promotor pomocniczy:

ppłk dr inż. Witold BUŻANTOWICZ

Warszawa 2024

SPIS TREŚCI

1. STRESZCZENIE	4
2. WSTĘP.....	4
3. OPIS PROBLEMU BADAWCZEGO.....	6
4. PRZEGLĄD LITERATURY	7
4.1. OPIS ALGORYTMÓW UKIERUNKOWANYCH NA WYZNACZANIE RELACJI POMIĘDZY OBRAZAMI	8
4.2. NAWIGACJA WIZUALNA I BEZWŁADNOŚCIOWA.....	16
4.3. UWARUNKOWANIA ROZMYCIA OBRAZÓW TERENU.....	31
5. ZAŁOŻENIA FUNKCJONOWANIA GŁOWICY SAMONAPROWADZANIA PLATFORMY LATAJĄCEJ	35
6. REALIZACJA BADAŃ.....	40
6.1. BADANIE WPLYWU WYSOKOŚCI OBIEKTÓW TERENOWYCH NA DOKŁADNOŚĆ OKREŚLANIA POŁOŻENIA DLA PŁASKIEGO MODELU TERENU	43
6.2. BADANIE ODPORNOŚCI METOD NAWIGACJI WIZUALNO- BEZWŁADNOŚCIOWYCH NA ZAKŁÓCENIA PASYWNE	48
6.3. BADANIE WPLYWU RUCHU PLATFORMY LATAJĄCEJ ORAZ PARAMETRÓW FILTRACJI WIENERA NA DOKŁADNOŚĆ OKREŚLANIA POŁOŻENIA	60
6.3.1. BADANIE WPLYWU ROZMYCIA NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW	72
6.3.2. BADANIE WPLYWU BŁĘDU $\Delta\theta$ NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW	76
6.3.3. BADANIE WPLYWU BŁĘDU ΔL NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW	82
7. PODSUMOWANIE.....	111
8. BIBLIOGRAFIA.....	113

1. STRESZCZENIE

W pracy przedstawiono analizę wybranych zagadnień przetwarzania sygnałów i danych topograficznych w układzie samonaprowadzania platform latających. Do skutecznej realizacji naprowadzania niezbędne jest dysponowanie danymi nawigacyjnymi o dostatecznej precyzji. Rozpatrywany układ głowicy samonaprowadzania działa w oparciu o zespół sensorów, w którego skład wchodzi kamera światła widzialnego, układ bezwładnościowy oraz wysokościomierz laserowy. W pracy zasadniczy wysiłek skupiono na układzie wizyjnym, którego zadaniem jest obserwacja i interpretacja terenu (sceny) w czasie trwania lotu. Sygnały rejestrowane w trakcie lotu przez wysokościomierz i układ bezwładnościowy wraz z obrazem cyfrowym rejestrowanym przez kamerę stanowią źródło danych wejściowych pozwalających na estymację parametrów ruchu platformy w układzie topograficznym.

W pracy przedstawiono metody poprawy odporności systemu wizyjnego na zakłócenia pasywne pochodzące od ruchomych obiektów w przestrzeni pomiędzy terenem, a platformą latającą. Poprawa odporności na te zakłócenia osiągana jest poprzez wykorzystanie w algorytmie wizyjnym danych z wysokościomierza. Istotnym aspektem pracy jest także wyznaczenie modelu minimalizacji wpływu niepewności parametrów filtra Wienera na dokładność wyznaczania transformacji pomiędzy obrazami obserwowanymi przez kamerę w ruchu i obrazami referencyjnymi.

2. WSTĘP

Naprowadzanie i nawigacja obiektów są współcześnie stosowane w wielu dziedzinach techniki. Obecnie na rynku cywilnym oraz w wojsku obserwuje się wzrost zastosowań platform autonomicznych, które do realizacji stawianych im zadań wymagają danych nawigacyjnych o odpowiedniej precyzji.

Większość współczesnych zastosowań układów nawigacji realizowana jest w oparciu o dane satelitarne, które dzięki swojej precyzji i dostępności stanowią bardzo atrakcyjną opcję. Pomimo wspomnianych zalet systemy satelitarne posiadają również istotne wady, do których można zaliczyć brak możliwości działania w środowisku o dużym tłumieniu sygnału satelitarnego, np., pod ziemią, a także możliwość łatwego ich zakłócenia. Wyklucza to ich stosowanie w warunkach konfliktu zbrojnego z przeciwnikiem dysponującym możliwościami technicznymi w tym aspekcie. W przypadku wojskowych autonomicznych platform bezzałogowych (UAV, ang. *unmanned aerial vehicle*), w szczególności rakiet manewrujących (CM, ang. *cruise missile*), dąży się zatem do nawigacji w oparciu o sensory pokładowe działające niezależnie od systemów satelitarnych.

Podstawę funkcjonowania takich systemów stanowią zwykle układy naprowadzania bezwładnościowego (INS, ang. *inertial navigation system*), wykorzystujące akcelerometry, żyroskopy prędkościowe i magnetometry. Precyzja nawigacji układów tego typu zwiększa się w ostatnim czasie dzięki postępowi technologicznemu. Jednak układy te narażone są na wpływ

błędów systematycznych czujników, które w miarę upływu czasu lotu powodują narastające błędy nawigacji i samonaprowadzania.

W związku z tym w rozwiązaniach przeznaczonych dla platform latających typu UAV/CM stosuje się zasadniczo dwa typy układów nawigacji pozwalające na korekcję położenia obiektu względem zadanej trajektorii. Do pierwszej grupy zaliczyć można układy, których zadaniem jest określanie położenia na podstawie danych pozyskiwanych z radiowysokościomierzy, odnoszonych do referencyjnych map wysokościowych. Do takich systemów należą np.: TERCOM (ang. *terrain contour matching*), stosowany w rakietach manewrujących typu Tomahawk, SITAN (ang. *Sandia inertial terrain-aided navigation*), wykorzystujący gradienty nachylenia terenu jako dane wejściowe dla zmodyfikowanego filtru Kalmana (EKF, ang. *extended Kalman filter*) estymującego położenie obiektu, oraz VATAN (ang. *Viterbi-algorithm terrain-aided navigation*), wersja systemu działająca w oparciu o algorytm Viterbiego [1-5]. Drugą grupę stanowią systemy kojarzące referencyjne mapy terenu z informacją obrazową, pozyskaną za pomocą kamer światła widzialnego, szcztkowego lub podczerwonego [6, 7]. Takimi systemami są np. amerykański DSMAC (ang. *digital scene matching area correlator*), wykorzystywany w innym wariantcie rakiety Tomahawk [8, 9], a także jego rosyjski odpowiednik stosowany w rakietach Kalibr (Club). Ich zaletą jest zarówno dokładność ustalania położenia, jak i skrytość (rozumiana jako pasywność) działania.

Na rynku cywilnym rozwój w zakresie nawigacji i naprowadzania dotyczy dużej grupy zastosowań przemysłowych i telekomunikacyjnych. Prym stanowią tu rozwiązania przeznaczone dla robotów przemysłowych, pojazdów autonomicznych oraz bezzałogowych platform latających, najczęściej w postaci platform wielowirnikowych. Układy nawigacji tych urządzeń działają najczęściej w oparciu o dane satelitarne, jak i wizyjno-bezwładnościowe.

Dynamiczny rozwój konstrukcji UAV/CM wyposażanych w układy nawigacji działające niezależnie od systemów satelitarnych generuje szereg problemów, które według wiedzy autora, nie są w pełni rozwiązane lub nieujawnione. Stąd w pracy podjęto badania nad oceną wrażliwości wybranych metod przetwarzania w systemach nawigacji i samonaprowadzania, na uwarunkowania środowiskowe i ograniczenia występujące w torze obserwacyjnym.

Istotą pracy są rozważania związane z przetwarzaniem danych obrazowych pozyskiwanych z sensorów optycznych głowic samonaprowadzania oraz ich asocjacja z informacjami otrzymywanymi z innych sensorów. Dodatkowe źródło danych stanowią obrazy referencyjne terenu, które są dowiązane topograficznie.

3. OPIS PROBLEMU BADAWCZEGO

W literaturze zagadnienie przetwarzania danych i sygnałów w układach naprowadzania, a także nawigacyjnych jest obecnie tematem często podejmowanym. Związane jest to z szybkim rozwojem technologii mikroprocesorowej oraz platform autonomicznych, w tym bezpilotowych platform latających. Współczesne układy przetwarzania realizują fuzję danych pomiarowych z różnych czujników, co samo w sobie stanowi problem złożony. Dodatkowo wspomniane elementy pomiarowe operują w różnych domenach sygnałowych związanych z wieloma aspektami fizycznymi środowiska i obiektu nawigacji. Przytoczone uwarunkowania powodują, że poruszane zagadnienie badawcze ma charakter multidyscyplinarny i wymaga nawet w aspekcie analizy literatury szerokiego kontekstu. Holistyczne podejście w rozwiązywaniu problematyki związanej z poruszonym zagadnieniem przetwarzania wymagałoby bardzo obszernego zakresu badań podejmowanych w różnych dyscyplinach, stąd w pracy zdecydowano się na ukierunkowanie analizy na dwóch problemach badawczych, których rozwiązania, według wiedzy autora, nie są dostępne w literaturze. Oba zagadnienia związane są z wpływem ruchu rozpatrywanej platformy na dokładność określania jej położenia.

W pracy rozpatrywane są następujące problemy związane z przetwarzaniem sygnałów i danych w układzie samonaprowadzania:

- sformułowanie formalnego opisu wpływu procesu filtracji efektu rozmycia obrazów na dokładność określania położenia obiektów przy wykorzystaniu lokalnych cech obrazowych i algorytmu estymacji modelu dopasowania wzajemnego obrazów,
- ograniczona precyzja algorytmów określania położenia stosowanych w układach nawigacji wizyjno-bezwładnościowej przy występowaniu zakłóceń związanych z ruchem obiektów w obserwowanym środowisku.

Pierwszy problem wiąże się z analizą wpływu artefaktów nakładanych na obrazy w następstwie filtracji Wienera, która bazuje na estymowanych w układzie bezwładnościowym parametrach ruchu platformy. Parametry te obarczone są błędem. Filtrowany efekt rozmycia powstaje na skutek ruchu platformy z układem wizyjnym względem układu inercjalnego związanego z terenem. Efekt ten jest niekorzystny dla procesu nawigacji. Proces filtracji Wienera pozwala na ograniczenie tego wpływu jednak skuteczność tego procesu jest zależna od znajomości modelu ruchu powodującego rozmycie. Błędy w parametrach tego modelu powodują powstanie dodatkowych niekorzystnych zjawisk – artefaktów, których rozkład przestrzenny może mieć wpływ na dopasowanie obrazów będących obiektem przetwarzania w układzie wizyjnym. Dopasowanie to pozwala na określanie położenia platformy w układzie inercjalnym.

Drugi problem odnosi się do podatności układów wizyjno-bezwładnościowych wykorzystujących pojedynczą kamerę na zakłócenia pasywne pochodzące od ruchomych obiektów terenowych, których rzuty przedstawia przetwarzany obraz cyfrowy. Obrazy te

uzyskiwane są w warunkach ruchu platformy, jak i obserwowanych obiektów względem układu inercyjnego. Precyzja wspomnianych algorytmów odnosi się do różnicy pomiędzy położeniem określanym na ich wyjściu, a położeniem rzeczywistym platformy.

W związku z wymienionymi problemami badawczymi stawia się w pracy hipotezę, którą jest stwierdzenie, że możliwa jest minimalizacja negatywnego wpływu zastosowania filtracji Wienera na dokładność dopasowania obrazów przy obciążonych błędem danych wejściowych do tego procesu.

W pracy wyróżniono także następujące pomocnicze cele naukowe i użytkowe:

- opracowanie metody kompensacji błędów określania położenia przy niepełnej informacji o głębi obserwowanej sceny przedstawiającej obraz terenu,
- sformułowanie ogólnego modelu opisu wpływu różnych filtrów Wienera na dokładność dopasowania obrazów z zastosowaniem metod statystycznych opartych o cechy lokalne obrazu terenu przy występowaniu efektu rozmycia,
- opracowanie metody minimalizacji negatywnego wpływu filtracji Wienera, bazującej na danych wejściowych obciążonych niepewnością pomiarową, na dokładność dopasowania obrazów.

4. PRZEGLĄD LITERATURY

Przegląd literatury podzielono na części, w taki sposób, aby umożliwić tematyczny kontekst w ramach poruszanych zagadnień teoretycznych, poprawić przejrzystość pracy, a także uporządkować logiczną strukturę wyводу.

W pierwszej części przeglądu opisane są uwarunkowania związane z przetwarzaniem obrazu z wykorzystaniem aktualnych osiągnięć dostępnych w literaturze w zakresie grupy algorytmów rozpatrujących obraz jako zbiór cech lokalnych. Jest to podejście polegające na dekompozycji reprezentacji i opisu obrazu, nie jako całości, ale zbioru cech o określonych parametrach i dystrybucji w jego przestrzeni.

W kolejnej części analizowane są aktualne osiągnięcia z zakresu nawigacji wizualnej i bezwładnościowej pozwalających na estymację parametrów ruchu i orientacji w ramach modeli matematycznych łączących dane z kamer, układów bezwładnościowych, a także innych sensorów.

Ostatnia część przeglądu dotyczy uwarunkowań przetwarzania sygnałów związanych z rozmyciem obrazu na skutek akwizycji obrazu w czasie ruchu platformy nad obrazowanym terenem. W tej części analizuje się dostępne metody przetwarzania ukierunkowane na minimalizację wpływu zakłóceń w postaci rozmycia w kontekście możliwości ich zastosowania w układzie nawigacji platform poruszających się z dużymi prędkościami.

4.1. OPIS ALGORYTMÓW UKIERUNKOWANYCH NA WYZNACZANIE RELACJI POMIĘDZY OBRAZAMI


Rozpatrywane w rozdziale obrazy są dwuwymiarowymi sygnałami zawierającymi informację o obserwowanym z powietrza terenie. W pracy jako dopasowanie obrazów rozumie się wyznaczenie relacji logicznych oraz geometrycznych pomiędzy lokalnymi ich elementami (obiektami).

Działanie klasycznych algorytmów identyfikacji obiektów, służących wskazywaniu podobieństw pomiędzy obrazami rejestrowanymi w bieżących pomiarach i referencyjnymi (tzw. wzorcami), bazuje w głównej mierze na wykorzystaniu metod korelacyjnych. Algorytmy te, mimo że efektywnie implementowane są w rozwiązaniach typowych problemów technicznych, w przypadku zagadnień odnoszących się do nawigacji topograficznej cechują się niewystarczającą skutecznością. Związane jest to m.in. z ograniczeniami i uwarunkowaniami występującymi w torze pomiarowym, warunkami środowiskowymi oraz z cechami charakterystycznymi rozpoznawanych obiektów terenowych, które w sposób silnie negatywny wpływają na uzyskiwane wyniki korelacji. Dyskwalifikuje to możliwość bezpośredniego ich wykorzystania w zadaniach kojarzenia referencyjnych map terenu z pozyskiwaną informacją obrazową.

Szczególnie istotne utrudnienie stanowi fakt, że elementy sensoryczne układów nawigacyjnych instalowanych na UAV/CM rejestrują dane obrazowe w różnych warunkach środowiskowych [10]. Niejednokrotnie też dane referencyjne o wysokiej wartości informacyjnej na skutek różnego rodzaju uwarunkowań stanowią wzorzec mało przydatny lub wręcz prowadzący do błędnych wyników. Dzieje się tak np. w sytuacji, w której rozpoznanie jest prowadzone w odmiennych warunkach pogodowych niż te, w których odbywa się misja UAV/CM. Dopasowywanie obrazów staje się wówczas zagadnieniem złożonym. Równie ważne okazują się uwarunkowania związane z parametrami rejestracji obrazu, m.in. zmienny kąt obserwacji, brak zachowania skali lub wykorzystanie różnego typu sensorów.

Metody związane z dopasowywaniem obrazów zaczęto intensywnie rozwijać wraz z upowszechnieniem obrazu cyfrowego w technice. Początkowo wykorzystywano klasyczne metody korelacyjne i fourierowskie. Metody te jednak nie pozwalały na skuteczne dopasowywanie wielomodalne, wieloperspektywiczne obrazów uzyskiwanych w różnym czasie. Taksonomie klasycznych metod wykorzystywanych w procesie dopasowywania obrazów przedstawiono na początku lat 90. ubiegłego stulecia [11]. Zdefiniowano również przestrzeń cech obrazu rozpatrywaną jako źródło informacji koniecznej do wzajemnego dopasowania obrazów, a jako największe utrudnienie procesu dopasowania wskazano lokalne wariacje obrazu. W XXI wieku postępował dalszy rozwój metod opartych o cechy charakterystyczne obrazu [12]. Na przestrzeni ostatnich kilkunastu lat opracowano nowe, efektywne algorytmy przetwarzania i dopasowywania obrazów cyfrowych, wykorzystujące metody statystyczne polegające na dopasowywaniu cech lokalnych (lokalnych elementów) na obrazach [11-14], których klasyfikację przedstawia Rys. 4.1.1. Metody te stały się alternatywą dla klasycznych metod korelacyjnych i fourierowskich. Należy podkreślić, że

większość metod dopasowywania obrazów opartych o cechy lokalne zawiera trzy, następujące po sobie, zasadnicze etapy: detekcję cech lokalnych (elementów obrazu), dopasowanie cech, estymację modelu wzajemnej transformacji. Autorzy tych metod wskazują na ich większą odporność, w stosunku do ww. ich klasycznych odpowiedników, na zniekształcenia perspektywiczne, rotację, translację, skalowanie czy zmiany oświetlenia.



Rys. 4.1.1 Klasyfikacja wybranych metod dopasowywania obrazów

Cechą wspólną wszystkich przedstawionych metod jest wykorzystanie tzw. „przestrzeni skali” [15], pozwalającej na decymację danych obrazowych i rozpatrywanie podobieństw pomiędzy obrazami o różnych skalach. Znaczący krok w rozwoju metod dopasowywania obrazów opartych o cechy lokalne stanowiło opracowanie algorytmu *Scale-Invariant Feature Transform* (SIFT) [16]. W tym przypadku cechy charakterystyczne stanowią lokalne elementy obrazu, a ich położenie nie ulega zmianie podczas skalowania obrazu. Wskazanie takich cech jest dokonywane poprzez wyznaczenie lokalnych ekstremów $\mathbf{D}(\hat{x})$ różnicy pomiędzy wynikami splotu obrazu $\mathbf{\Omega}(x, y)$ z funkcjami gaussowskimi $\mathbf{G}(x, y, \sigma)$ o różnym parametrze skali σ :

$$\mathbf{D}(\hat{x}) = \mathbf{D} + \frac{1}{2} \frac{\partial \mathbf{D}^T}{\partial x} \hat{x} \quad (1)$$

gdzie:

$$\begin{aligned} \mathbf{D} = \mathbf{D}(x, y, \sigma) &= \left(\mathbf{G}_{\sigma_1}(x, y) - \mathbf{G}_{\sigma_2}(x, y) \right) * \mathbf{\Omega}(x, y) = \\ &= \frac{1}{\sqrt{2\pi}} \left(\frac{1}{\sigma_1} e^{-\frac{x^2 y^2}{2\sigma_1^2}} - \frac{1}{\sigma_2} e^{-\frac{x^2 y^2}{2\sigma_2^2}} \right) * \mathbf{\Omega}(x, y) \end{aligned} \quad (2)$$

Bardziej efektywną numerycznie wersję algorytmu SIFT o nazwie *Speeded-Up Robust Features* (SURF) przedstawiono w [17]. Obie metody wykorzystują podstawowe etapy przetwarzania opisane w [12]. Dodatkowo w celu zapewnienia skuteczności wykrywania cech

na obrazach o różnej rozdzielczości wprowadzono w nich przestrzeń skali, składającą się z oktafów reprezentujących serie odpowiedzi filtra splotowego o zmiennym rozmiarze.

W dużym uproszczeniu wykrycie punktu charakterystycznego polega na wykorzystaniu wyznacznika macierzy Hessego, $\det(\mathbf{H})$. W przypadku SURF wykorzystuje się także aproksymowane filtrami kwadratowymi pochodne drugiego rzędu funkcji Gaussa G oraz tzw. „obraz całkowity” opisany w [18]. Macierz Hessego w tych metodach przyjmuje postać:

$$\mathbf{H} = \begin{bmatrix} \mathbf{L}_{xx}(x, y, \sigma) & \mathbf{L}_{xy}(x, y, \sigma) \\ \mathbf{L}_{xy}(x, y, \sigma) & \mathbf{L}_{yy}(x, y, \sigma) \end{bmatrix} \quad (3)$$

, gdzie:

$$\begin{aligned} \mathbf{L}_{xx}(x, y, \sigma) &= \frac{\partial^2}{\partial x^2} \mathbf{G}(x, y, \sigma) * \mathbf{\Omega}(x, y) \cong \mathbf{B}_{xx} * \mathbf{\Omega}(x, y). \\ \mathbf{L}_{xy}(x, y, \sigma) &= \frac{\partial^2}{\partial x \partial y} \mathbf{G}(x, y, \sigma) * \mathbf{\Omega}(x, y) \cong \mathbf{B}_{xy} * \mathbf{\Omega}(x, y). \\ \mathbf{L}_{yy}(x, y, \sigma) &= \frac{\partial^2}{\partial y^2} \mathbf{G}(x, y, \sigma) * \mathbf{\Omega}(x, y) \cong \mathbf{B}_{yy} * \mathbf{\Omega}(x, y). \end{aligned} \quad (4)$$

Wyznacznik macierzy Hessego po aproksymacji z wykorzystaniem filtrów kwadratowych oraz normy Forbeniusa wynosi:

$$\det(\mathbf{H}) \cong \mathbf{B}_{xx}\mathbf{B}_{yy} - (0.9\mathbf{B}_{xy})^2 \quad (5)$$

Po wykryciu lokalnych ekstremów $\det(\mathbf{H})$ podobnie jak dla $\mathbf{D}(\hat{x})$ określone jest położenie punktów charakterystycznych, reprezentujących cechy lokalne, nazywane dla metod SIFT i SURF plamo-podobnymi (ang. blob-like). W tym kroku w metodzie SIFT odrzucane są także cechy, których kontrast jest niższy niż zakładany próg t poprzez porównanie $|\mathbf{D}(\hat{x})| < t$, a także punkty leżące na odizolowanych krawędziach. Dokonywane jest to na podstawie porównania wartości ilorazu śladu macierzy Hessego $\mathbf{H}$, oraz jej wyznacznika z współczynnikiem krzywizny r :

$$\frac{Tr(\mathbf{H})^2}{Det(\mathbf{H})} < \frac{(r+1)^2}{r} \quad (6)$$

W 2011 roku zaproponowano alternatywną dla SIFT i SURF metodę *Oriented FAST and Rotated BRIEF* (ORB) [19]. Metoda oparta została o zmodyfikowany detektor *Features from Accelerated Segment Test* (FAST) [20,21], umożliwiający wykrywanie narożników i krawędzi, oraz zmodyfikowany deskryptor *Binary Robust Independent Elementary Features* (BRIEF) [22]. Podejście to zakłada zmianę skali obrazu na bazie rozmywania coraz większym filtrem gaussowskim. Pomimo redukcji szumu i zwiększania jednolitości obszarów interpretowanych przez człowieka jako unikalne (np. tafla jeziora, ściana budynku, sylwetka pojazdu itp.) powoduje ono jednak rozmycie ich krawędzi. Prowadzi to często do braku możliwości

wskazania granic pomiędzy obszarami i określenia punktów charakterystycznych w ich okolicy.

Rozwiązanie tego problemu zaproponowano w metodzie KAZE (z japońskiego „wiatr”) [23]. W odróżnieniu od metod SIFT i SURF, w których do uogólniania obrazu wykorzystywana jest funkcja gaussowska, powodująca izotropową dyfuzję luminancji, w metodzie KAZE uogólnianie oparto o nieliniową dyfuzję w kolejnych oktawach skali [24]. Anizotropowe rozmywanie obrazu w tej metodzie uzależnione jest od lokalnego rozkładu luminancji. Równanie opisujące nieliniową dyfuzję można przedstawić w postaci:

$$\frac{\partial \Omega}{\partial t} = \text{div}(c(x, y, t) \cdot \nabla) \quad (7)$$

Na dostosowanie intensywności rozmywania pozwala wprowadzona funkcja przewodnictwa c , która zwykle odniesiona jest do czasu. Jednak wykorzystując podejście zaproponowane w [15] parametr t odnosimy do skali [24]. W kolejnych pracach rozwijających zastosowanie nieliniowej dyfuzji w kontekście filtracji obrazu proponowano różne postaci funkcji przewodnictwa c [24-26]. Jedną z funkcji użytych do nieliniowej dyfuzji może być funkcja:

$$c = \exp\left(-\frac{|\nabla L_\sigma|^2}{k^2}\right) \quad (8)$$

gdzie: ∇L_σ jest gradientem rozmytego funkcją Gaussa obrazu oryginalnego w skali σ , natomiast k jest współczynnikiem kontrastu.

Funkcja ta umożliwia rozmywanie obrazu z zachowaniem krawędzi struktur. Daje to możliwość wykrywania większej ilości cech charakterystycznych w różnych skalach obrazu. Jednak wiąże się to z wykorzystaniem gradientu, co w przypadku występowania na obrazie intensywnych zakłóceń, np. w postaci cienia może powodować niekorzystny (ze względu na późniejsze wykrywanie cech charakterystycznych) rozkład dyfuzji na obrazie.

Istotnym etapem rozpatrywanych metod jest opis punktu charakterystycznego wektorem zawierającym informacje o otoczeniu tego punktu. W metodzie SIFT wykorzystywany jest gradient luminancji. W metodzie SURF odpowiedź obrazu na zorientowane poziomo i pionowo falki Harra. Wokół punktu charakterystycznego w obszarze o określonym promieniu uzależnionym od skali σ utworzona jest pewna liczba komórek, w których wyznaczane są dominujące wartości gradientu lub odpowiedzi na falki Harra, które są podstawą obliczenia tzw. metryki cechy, a następnie wyznaczana jest dominująca orientacja. Dla metody SIFT do opisu cechy obliczane są:

$$m(x, y) = \sqrt{(\mathbf{L}(x+1, y) - \mathbf{L}(x-1, y))^2 + (\mathbf{L}(x, y+1) - \mathbf{L}(x, y-1))^2} \quad (9)$$

$$\theta(x, y) = \tan^{-1} \left(\frac{L(x, y+1) - L(x, y-1)}{L(x+1, y) - L(x-1, y)} \right)$$

gdzie: $m(x, y)$ jest wielkością gradientu, $\theta(x, y)$ jest orientacją, L jest omawianym powyżej rozmytym obrazem oryginalnym.

Na tej podstawie w metodzie SIFT tworzony jest histogram gradientu, który sumuje wyznaczone wartości w czterech komórkach. W metodzie SURF w analogicznych komórkach sumowane są odpowiedzi na falki Harra rozłożone wzdłuż promieni otoczenia punktu z odstępem $\frac{\pi}{3}$. W każdym podregionie SURF wyznaczany jest wektor:

$$v = \left(\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y| \right) \quad (10)$$

gdzie: d_x jest odpowiedzią otoczenia punktu charakterystycznego na falkę Harra zorientowaną poziomo, natomiast d_y jest odpowiedzią na falkę Harra zorientowaną pionowo.

W metodzie KAZE postępowanie jest analogiczne jak dla metody SURF z tą różnicą, że wykorzystywane są pochodne pierwszego rzędu z funkcji obrazu. Operacja opisu punktu wykonywana jest dla wszystkich poziomów w przyjętej przestrzeni skali, tworząc w ten sposób piramidę wektorów przypisanych do kolejnych poziomów zawierających coraz bardziej uogólnioną postać obrazu.

Odminnym podejściem do wykrywania i opisu cech lokalnych charakteryzuje się metoda *Maximally Stable Extremal Regions* (MSER) wprowadzona w [27]. W metodzie tej jako cechy charakterystyczne obrazu wybierane są regiony (kształty), określane jako „maksymalnie stabilne”. Obraz w tej metodzie traktowany jest jako funkcja Ω , która przekształca:

$$\Omega: \mathcal{D} \subset \mathbb{Z}^2 \rightarrow S \quad (11)$$

gdzie: $\mathcal{D}$ dziedziną Ω , a S jej zbiorem wartości, zazwyczaj $S = \{0, 1, \dots, 255\}$.

Na obrazie wyznaczyć można regiony (obszary, kształty) o określonym (średnim) poziomie luminancji. Jako region Q rozumiany jest podzbiór pikseli obrazu, który jest ciągłym podzbiorem $\mathcal{D}$, takim, że $\forall p, q \in Q \exists$ sekwencje $p, a_1, a_2, \dots, a_n, q$ oraz $pAa_1, a_1Aa_2, \dots, a_nAq$. Gdzie $A \subset \mathcal{D} \times \mathcal{D}$ stanowi relację sąsiedztwa i zapis pAa_1 oznacza sąsiedztwo między pikselami p i a_1 . Natomiast region ekstremalny to region $Q \subset \mathcal{D}$, taki, że $\forall p \in Q, q \in \partial Q: \Omega(p) > \Omega(q)$ (region maksymalnej intensywności) lub $\Omega(p) < \Omega(q)$ (region minimalnej intensywności). Poszukiwany region ekstremalny, o maksymalnej stabilności (MSER) to region $R = Q_{i^*}$, który dla sekwencji $Q_1, \dots, Q_{i-1}, Q_i$ regionów ekstremalnych, zagnieżdżonych tj. $Q_i \subset Q_{i+1}$ i dla $q(i) = |Q_{i+\Delta} \setminus Q_{i-\Delta}| / |Q_i|$ ma lokalne minimum w i^* . Przy czym $\Delta \in S$ jest parametrem metody MSER i stanowi próg luminancji. Procedura wyznaczania regionów MSER powtarzana jest w całej zakładanej przestrzeni skali σ .

W etapie opisu cech dla każdego regionu wyznaczany jest wektor wykorzystujący momenty obrazowe. Na podstawie momentów $m_{00}, m_{01}, \dots, m_{20}$, wyznaczany jest środek ciężkości

każdego regionu MSER oraz elipsa aproksymująca dany region, według procedury opisanej w [28]. Równanie elipsy przedstawia się jako:

$$\frac{(x - x_g + \theta(y - y_g))^2}{a_1(1 + \theta^2)} + \frac{(y - y_g - \theta(x - x_g))^2}{a_2(1 + \theta^2)} - 1 = 0 \quad (12)$$

Orientacja θ i rozmiar elipsy określony za pomocą jej osi a_1 i a_2 pozwalają na opisanie własności regionu branego do porównania w etapie dopasowania. Moment, m , rzędu $(p+q)$ regionu MSER służący do wyznaczenia środka ciężkości regionu $C = \Omega(x_g, y_g)$ można przedstawić jako:

$$m_{pq} = \sum_{\{x,y\} \in R} x^p y^q \quad (13)$$

Wykorzystanie momentów i środka ciężkości jest również własnością metody ORB, która wykorzystuje uczenie maszynowe do detekcji narożników. Po ich detekcji dla każdego narożnika wyznaczany jest środek ciężkości narożnika C , na bazie momentów obrazowych, według zależności:

$$C = \left(\frac{m_{10}}{m_{00}}, \frac{m_{01}}{m_{00}} \right) \quad (14)$$

gdzie:

$$m_{pq} = \sum x^p y^q \Omega(x, y) \quad (15)$$

Na podstawie położenia narożnika i jego środka ciężkości określa się orientację cechy opisanej zależnością:

$$\theta(x, y) = \text{atan2}(m_{01}, m_{10}) \quad (16)$$

W etapie opisu cech wykorzystuje się wyznaczoną orientację do uzupełnienia binarnego deskryptora BRIEF [22] o warunek sprawdzenia przynależności punktu $L(x, y)$ do macierzy $\mathbf{W}_\theta$. Operacja ta bazuje na prostym porównaniu luminancji pikseli wokół cechy:

$$\tau(L; x, y) := \begin{cases} 1 & : L(x, y) < L(x_1, y_1) \\ 0 & : L(x, y) \geq L(x_1, y_1) \end{cases} \quad (17)$$

Macierz $\mathbf{W}_\theta$ jest wynikiem mnożenia oryginalnej macierzy $\mathbf{W}$ zawierającej lokalizacje punktów poddawanych testom oraz macierzy rotacji utworzonej na podstawie wyznaczonych kątów $\theta(x, y)$. Wówczas wektor ORB opisujący cechę charakterystyczną przyjmuje postać:

$$v_n(L, \theta) := \sum_{1 \leq i \leq n} 2^{i-1} \tau(L; x_i, y_i) | (x_i, y_i) \in \mathbf{W}_\theta \quad (18)$$

Elementem wspólnym dla opisywanych metod jest etap porównania określonych cech charakterystycznych wykrytych na obrazie referencyjnym i rejestrowanym. Ma on fundamentalne znaczenie w zagadnieniach dowiązania terenowego, ponieważ lokalizacja dopasowanych do siebie cech stanowi źródło wyznaczenia macierzy transformacji wzajemnej pomiędzy obrazami. W porównaniu tym brane są pod uwagę wektory opisujące cechy w danej metodzie, np. metryka cechy oraz jej orientacja.

Wyznaczenie podobieństwa pomiędzy wektorami opisu cech $\mathbf{v}_a$ i $\mathbf{v}_b$, wykorzystuje różne miary. Do najpowszechniej stosowanych miar zalicza się dystanse:

$$d_1(f_a, f_b) = \sum |\mathbf{v}_a - \mathbf{v}_b| \text{ oraz } d_2(\mathbf{v}_a, \mathbf{v}_b) = \sum (\mathbf{v}_a - \mathbf{v}_b)^2 \quad (19)$$

Trzecią często wykorzystywaną normą dla wektorów binarnych jest dystans Hamminga określony jako:

$$d_3(\mathbf{v}_a, \mathbf{v}_b) = \sum \text{XOR}(\mathbf{v}_a, \mathbf{v}_b) \quad (20)$$

Innym jeszcze podejściem służącym do dopasowania dwóch cech jest algorytm najbliższego sąsiada oparty o stosunek dystansów d_1 i d_2 . Należy jednak pamiętać, że wynik dopasowania dla opisanych dystansów może być różny, stąd istotne znaczenie etapu wykrywania i opisu cech.

Ostatnim etapem występującym we wszystkich omawianych metodach jest statystyczna weryfikacja zbioru dopasowanych cech lokalnych. Zdarza się, że w wyniku wstępnego porównania wektorów opisujących cechy wskazywane są błędne dopasowania, wynikające z uwarunkowań akwizycji opisanych powyżej. Dlatego też po etapie przetwarzania wstępnego stosuje się dodatkowe kryteria pozwalające na odróżnienie dopasowań poprawnych od błędnych, np. w oparciu o metodę *Random Sample Consensus* (RANSAC) [29]. Metoda ta pozwala na estymowanie modelu matematycznego opisującego lokalizację cech lokalnych na obrazie przy założeniu, że większość dopasowanych ze sobą punktów wpisuje się w ten model (z pewnym zakładanym maksymalnym błędem). Wówczas te punkty, które nie wpisują się w estymowany model, są odrzucane w etapie wyznaczania macierzy transformacji pomiędzy obrazami.

Algorytm ten jest powszechnie stosowany do estymacji parametrów modeli matematycznych na podstawie zbioru danych, w którym występują próbki nie wpisujące się w rozpatrywany model z zakładanym błędem maksymalnym (*ang. outliers*). RANSAC bazuje na określonym apriori modelu, który nie jest zmieniany podczas działania algorytmu. Wyznaczane są jedynie parametry modelu, które minimalizują błąd jego dopasowania w określonym zbiorze danych. Zakładany w algorytmie rozkład błędu ma charakter

gaussowski. Początkowo losowo dobierany jest minimalny zbiór danych na podstawie, którego możliwe jest wyznaczenie parametrów modelu metodą najmniejszych kwadratów. W kolejnym kroku sprawdzany jest błąd dopasowania wyznaczonego wstępnie modelu dla całego zbioru danych. Rozpatrywany zbiór danych zawiera N elementów i jest określony jako $D = \{d_1, \dots, d_N\}$. W algorytmie w każdej iteracji na podstawie danych ze zbioru D estymowany jest wektor parametrów $\kappa(\{d_1, \dots, d_h\})$, którego liczba elementów h jest większa lub równa minimalnej ilości elementów niezbędnych do wyznaczenia wszystkich parametrów modelu $\mathcal{M}$.

Przestrzeń modelu wyznaczanego w algorytmie może być w sposób uogólniony przedstawiona jako:

$$\mathcal{M}(\theta) \stackrel{\text{def}}{=} \{d \in \mathbb{R}^d : f_{\mathcal{M}}(d, \kappa) = 0\} \quad (21)$$

, gdzie κ jest wektorem parametrów opisujących model $\mathcal{M}$, natomiast $f_{\mathcal{M}}$ jest funkcją błędu dopasowania modelu.

Funkcja $f_{\mathcal{M}}$ w pierwszym kroku algorytmu przyjmuje wartość 0, co oznacza bezbłędne dopasowanie modelu dla przyjętego zbioru danych.

W każdej iteracji określany jest błąd dopasowania d do przestrzeni modelu $\mathcal{M}(\kappa)$ poprzez:

$$\epsilon_{\mathcal{M}}(d, \theta) \stackrel{\text{def}}{=} \min_{d' \in \mathcal{M}(\theta)} \text{dist}(d, d') \quad (22)$$

Funkcja $\text{dist}(\cdot, \cdot)$ określona jest wybraną normą, a w oryginale stanowi normę euklidesową.

Na podstawie błędu dopasowania określany jest zbiór $S(\theta)$ spełniający warunek dopasowania z błędem mniejszym od zakładanego progu δ .

$$S(\theta) \stackrel{\text{def}}{=} \{d \in D : \epsilon_{\mathcal{M}}(d, \theta) \leq \delta\} \quad (23)$$

Podsumowanie podrozdziału:

Algorytmy wykorzystujące cechy lokalne są obecnie podstawą analizy obrazowej w układach nawigacji wizyjnej. Proces dopasowywania cech lokalnych stosowany jest jako podstawa do wyznaczenia relacji pomiędzy płaszczyzną obrazową i obserwowanym terenem. Pomimo wielu zalet algorytmy te narażone są na ograniczenie ich skuteczności. Ograniczenie to objawiać się może poprzez niedostateczną dla zadania nawigacji precyzję dopasowania obrazów, brak możliwości dopasowania lub dopasowania niepoprawne. Czynniki ograniczającymi skuteczność są m.in. zmiana kontrastu wynikająca z obserwacji w różnych warunkach nasłonecznienia, rozmycie obrazu wynikające z ruchu głowicy samonaprowadzania w czasie nawigacji, zmiany w topologii obiektów w terenie będące następstwem wzajemnego ruchu tych obiektów. Ze względu na statystyczne ujęcie metod dopasowania cech i wyznaczania ogólnego modelu relacji pomiędzy całymi obrazami szczególnie istotne jest zrozumienie wpływu zakłóceń o różnej dystrybucji na obrazie na otrzymywane wyniki dopasowania. W pracy w szczególności skupiono się na dwóch rodzajach zakłóceń. Pierwszy to zakłócenia pasywne w postaci przemieszczających się jednostajnie wzdłuż obrazu grup

pikseli. Drugi to zniekształcenia obrazu w postaci artefaktów (innych niż ww. grup pikseli) będących następstwem filtracji Wienera. Rozpatrywane uwarunkowania stanowią odniesienie do postawionych w pracy problemów badawczych.

4.2. NAWIGACJA WIZUALNA I BEZWŁADNOŚCIOWA

W analizowanej literaturze nawigacja realizowana jest w lokalnym układzie współrzędnych z wykorzystaniem danych wizyjnych i bezwładnościowych. Najczęściej spotykanym narzędziem służącym do fuzji danych wizyjnych i bezwładnościowych są estymatory w postaci filtrów Kalmana [41, 41] oraz estymatory tworzone w oparciu o teorię grafów [41, 43]. W związku z pomiarem wielkości mierzonych w różnych układach współrzędnych powiązanych nieliniowymi zależnościami zachodzi w ww. narzędziach konieczność linearyzacji modeli oraz wyliczania jacobianów przetwarzanych zmiennych stanu i pomiarów. Operacje te są wymagające obliczeniowo dla systemów przetwarzania przeznaczonych do implementacji w urządzeniach mobilnych, gdzie oczekiwane jest również działanie z zachowaniem maksymalnego przybliżenia do czasu rzeczywistego.

Dodatkowym problemem dla systemów wyposażonych w pojedynczą kamerę jest brak możliwości określania głębi obrazu na pojedynczym obrazie. W przypadku wielu ujęć statycznego obiektu, którego elementy mają niezmiennie położenie tworzące bryłę sztywną z jednoznacznym dowiązaniem do inercjalnego układu globalnego, możliwe jest wyznaczenie głębi z dokładnością wynikającą z parametrów obrazu oraz systemu obserwacji. Parametry te omówiono w dalszej części rozdziału. Wyznaczanie głębi obrazu możliwe jest także w przypadku obserwacji, z wielu ujęć, nieznanego obiektu statycznego z wykorzystaniem systemu obserwacji o znanych parametrach i przy jednoczesnej znajomości położenia systemu obserwacji w globalnym układzie inercjalnym dla każdego z ujęć.

Niestety zachowanie powyższych warunków w sytuacji nawigacji platformy wyposażonej w rozważany system wizyjny w nieznanym terenie nie jest możliwe. Stąd większość rozwiązań sprowadza się do wsparcia systemu wizyjnego innymi systemami pomiarowymi. Oprócz systemów nawigacji wizualno-bezwładnościowej, określanej w literaturze anglojęzycznej często skrótem VINS (*ang. Visual-Inertial System*) występują także bardziej zaawansowane rozwiązania SLAM (*ang. Simultaneous localization and mapping*) wykorzystujące najczęściej lidary [45,46] lub radary z syntetyczną aperturą [47,48]. W ostatnim czasie rozwija się także odrębna dziedzina algorytmów wizyjnego śledzenia i lokalizacji - vSLAM (*ang. Visual simultaneous localization and mapping*). Przegląd wybranych rozwiązań z tej dziedziny opisuje praca [49]. Algorytmy te w swoich założeniach odnoszą się do statycznego obiektu obserwacji. Są to najczęściej rozwiązania przeznaczone do określania położenia i orientacji w zamkniętych pomieszczeniach. Ze względu na brak informacji o głębi obserwowanej sceny ze źródeł innych niż sama kamera, rozwiązania w tej grupie algorytmów są często mniej precyzyjne od algorytmów SLAM opartej o większą liczbę sensorów. Częstym rozwiązaniem konstrukcyjnym umożliwiającym precyzyjne określanie

głębi obrazu na podstawie tylko danych wizyjnych jest stosowanie układu podwójnego kamer. Dzięki znajomości translacji i rotacji pomiędzy układami kamer, przy założeniu, że układy te tworzą bryłę sztywną możliwe jest nie tylko określanie głębi obrazu, ale także zwiększenie odporności systemu na potencjalne błędy związane z ruchem obiektów w terenie. Układ podwójny musi jednak pracować synchronicznie. Dodatkowo wpływ na precyzję i skuteczność w przeciwdziałaniu zakłóceń ma odległość między kamerami. Im większa jest ta odległość, nazywana bazą dla układu stereowizyjnego, tym precyzyjniej można określać głębię. Takie wymaganie limituje zastosowanie układu stereowizyjnego na niewielkich platformach latających, gdzie przestrzeń jest ograniczona.

Wyznaczanie położenia i orientacji przestrzennej związane jest z określaniem, na każdej ramce obrazu z kamery, zbioru cech charakterystycznych $\{k_1, k_2, \dots, k_N\}$, z dowiązanymi do nich wektorami opisowymi $\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_N\}$, gdzie $\mathbf{d}_i \in \mathbb{R}^j$, $j \in \mathbb{N}$, natomiast $k_i = (u, v)$ są punktami na obrazie określonymi z niepewnością $\mathbf{R}_i$.

$$k_i = \bar{k}_i + \delta k_i, \quad \delta k_i \sim N(0, \mathbf{R}_i) \quad (24)$$

Cechy charakterystyczne obrazu rozpatrywane są lokalnie, a ich detekcja, opis wektorem parametrów oraz dopasowanie realizowane jest z wykorzystaniem metod opisanych w rozdziale 4.1. Do śledzenia ruchu cech na kolejnych obrazach stanowiących ujęcia-rzuty obrazowanego terenu wykorzystywany jest najczęściej algorytm Kandle-Lucas-Tomasi określany skrótem KLT, który pierwszy raz opisano w [50]. Algorytm ten zakłada estymację ruchu poszczególnych cech na obrazie przy założeniu niezmienności intensywności ich barwy na każdym kolejnym obrazie w oparciu o dane z obrazu analizowanego wcześniej. Realizowane jest to w procesie minimalizacji zależności:

$$\min_{\kappa} \|(I_1 \circ W)(u) - I_2\|^2 \quad (25)$$

, gdzie $W(u, \kappa)$ oznacza transformację obrazu I_1 do I_2 . Parametr κ obejmuje przesunięcie i rotację cech.

Znając parametry modelu opisującego transformację obrazu w kamerze oraz jej położenie i orientację w układzie związanym z terenem możliwe jest przypisanie punktom obrazu (a tym samym cechom) współrzędnych w trójwymiarowych $\mathbf{p}_i = [x, y, z]^T$, kartezjańskich układach odniesienia związanych z terenem. Opis układów terenowych i relacje pomiędzy nimi dostępne są w dalszej części pracy.

Na podstawie zbioru dopasowanych punktów według kryterium podobieństwa opisujących je wektorów opisowych (deskryptorów) wyznaczone są parametry transformacji pomiędzy obrazami oraz nowe położenie kamery.

Wyznaczanie transformacji realizowane jest w procesie stochastycznym, w którym występuje niezerowe prawdopodobieństwo błędnego dopasowania każdych dwóch cech, jeżeli

ich lokalizacja uległa zmianie. Dlatego w algorytmach nawigacji wizualnej stosuje się dodatkowy estymator transformacji wzajemnej pomiędzy obrazami - metodę RANSAC [29], opisaną wcześniej w pracy. Model transformacji pomiędzy płaszczyznami można przedstawić w postaci macierzy o trzech wierszach i kolumnach. W zależności od przyjętej hipotezy transformacji model estymowany będzie macierzą o różnej liczbie stopni swobody. Dla operacji skalowania, przesunięcia dwuwymiarowego i obrotu macierz transformacji nosi nazwę macierzy podobieństwa. Macierz o 6 stopniach swobody nosi nazwę macierzy afinicznej, natomiast macierz o 8 stopniach swobody nazywana jest macierzą projekcji dwuwymiarowej lub macierzą perspektywiczną.

Relacje pomiędzy płaszczyznami w uogólnieniu nazywane są homografią, która w pracy będzie odniesiona do transformacji perspektywicznej.

W przypadku założenia modelu trójwymiarowego estymuje się macierz istotną¹ lub macierz fundamentalną². Oba pojęcia nawiązują do oryginalnych nazw anglojęzycznych. Macierz istotna definiowana jest jako:

$$\mathbf{E} = [\mathbf{t}]_{\times} \mathbf{R} \quad (26)$$

, gdzie $\mathbf{R}$ jest macierzą rotacji, a $[\mathbf{t}]_{\times}$ jest macierzą skośnie symetryczną określającą translację w postaci:

$$[\mathbf{t}]_{\times} = \begin{bmatrix} 0 & -t_z & t_y \\ t_z & 0 & -t_x \\ -t_y & t_x & 0 \end{bmatrix} \quad (27)$$

Macierz skośnie symetryczna wiąże iloczyn wektorowy z dwóch wektorów z iloczynem skalarnym macierzy i wektora. Do wyznaczania macierzy istotnej konieczne jest posługiwanie się współrzędnymi znormalizowanymi. Współrzędne znormalizowane punktu z przestrzeni kartezjańskiej $\mathbf{P}(x, y, z)^T$ są opisane jako:

$$\mathbf{P}_{norm} = \begin{bmatrix} \frac{x}{z} \\ \frac{y}{z} \\ 1 \end{bmatrix} \quad (28)$$

Macierz fundamentalna jest rozszerzeniem pojęcia macierzy istotnej. Różnica pomiędzy nimi polega na konieczności dysponowania modelem kamery do wyznaczania macierzy

¹ macierz istotna – tłumaczenie terminu angielskiego terminu oryginalnego (ang. essential matrix)

² macierz fundametalna – tłumaczenie terminu angielskiego terminu oryginalnego (ang. fundamental matrix)

istotnej. Macierz fundamentalna wymaga jednak większej ilości powiązanych punktów do jej wyznaczenia.

Systemy nawigacji bezwładnościowej, zwane również systemami nawigacji inercyjnej (*ang. Inertial Navigation System - INS*), są szeroko rozpowszechnione w zastosowaniach nawigacji lądowej, morskiej, systemach raketowych i lotniczych. Pomiary parametrów bezwładnościowych tj. przyspieszeń liniowych z akcelerometrów i prędkości kątowych z żyroskopów pozwalają INS oszacować pozycję, prędkość i orientację platformy, na której układ jest zamontowywany. Przy czym zakłada się, że czujnik tworzy bryłę sztywną z platformą. Mankamentem pracy układów INS są błędy pomiarowe kumulujące się do estymatorów stanu ww. parametrów nawigacyjnych. Stąd dokładność nawigacyjna tych systemów zmniejsza się z upływem czasu. Aby złagodzić wynikający z całkowania błąd średniego i szumu własnego dryf oszacowań stanu, proponuje się różne podejścia do kompensacji niepożądanych błędów, stosując filtrowanie w dziedzinie częstotliwości [51], fuzję informacji ze źródeł zewnętrznych[52] lub redundantne wykorzystanie wielu takich samych czujników bezwładnościowych[53-54]

Obecnie w układach nawigacji bezwładnościowej coraz powszechniej stosowane są układy mikroelektromechaniczne MEMS (*ang. Microelectromechanical Systems*), których precyzja zwiększa się stopniowo wraz z rozwojem techniki w ostatnich latach. Szybkie rozpowszechnienie czujników tego typu w wielu dziedzinach związane jest z ich niewielkimi rozmiarami, niskim kosztem i zużyciem energii w stosunku do innych rozwiązań technologicznych realizujących tożsame zadania.

Błąd pomiarowy układów inercyjnych (*ang. Inertial Mesurement Unit - IMU*) narasta w czasie wykładniczo. Jednym z parametrów charakteryzujących dokładność pomiaru tych urządzeń jest wartość błędu losowego procesu (*ang. Random walk*), który wyrażany jest w jednostkach $[\alpha/\sqrt{s}]$, gdzie α wyraża wielkość mierzoną przez urządzenie. Dla żyroskopu będzie to $\alpha = \frac{^\circ}{s}$, natomiast dla akcelerometru $\alpha = \frac{m}{s^2}$. Błąd ten można powiązać z odchyleniem standardowym pomiaru zależnością:

$$\sigma = RW\sqrt{t} \quad (29)$$

Innym parametrem wiążącym dokładność pomiaru zależnym od częstotliwości próbkowania jest pasmowa gęstość szumowa ND $[\alpha/\sqrt{Hz}]$ pozwalająca na wyznaczenie odchylenia standardowego według zależności:

$$\sigma = ND\sqrt{f_p} \quad (30)$$

Oba wyżej wymienione parametry wyrażają kwadratową zależność z odchyleniem standardowym pomiaru. W nawigacji obiektów szybkich na duże odległości parametry te mają

istotny wpływ na dokładność procesu ze względu na wymóg wykonywania długotrwałego pomiaru z dużą częstotliwością.

Ze względu na powiększającą wariancję błędu czujników bezwładnościowych w czasie konieczne jest uwzględnienie tego zjawiska w modelu opisującym estymowany stan platformy nawigacyjnej. W dostępnej literaturze w układach wizualno-bezwładnościowych stosuje się modele oparte o estymatory. W pracy jako referencyjny przyjęto model przedstawiony w [42], który również odwołuje się do prac [43] i [55].

W pracach tych wykorzystuje się algebrę Liego, opisaną szerzej m in. w pracy [58], gdzie kwadratowe, odwracalne macierze tworzą grupy $\mathbf{G} \in \mathbb{R}^{N \times N}$. Przykładem grupy wykorzystywanej ww. pracach jest $\mathfrak{so}(3)$ algebry Liego, która odpowiada grupie euklidesowej rotacji składającej się z macierzy ortogonalnych $SO(3)$. Zależność między przestrzeniami zwana jest mapą i polega na rzutowaniu nieliniowych zależności występujących w grupach Liego do liniowych zależności w stycznych przestrzeniach euklidesowych. Grupy z przestrzeni Liego przenoszone są do przestrzeni euklidesowej $\mathbb{R}^q$ z wykorzystaniem zależności mapy logarytmicznej $\log: \mathbf{G} \rightarrow \mathbb{R}^q$. Natomiast grupy euklidesowe przenoszone do przestrzeni Liego wykorzystują mapę wykładniczą $\exp: \mathbb{R}^q \rightarrow \mathbf{G}$. Przykładowo grupa $\xi \in \mathbb{R}^q$ mapowana będzie do przestrzeni Liego jako:

$$\exp(\xi) = \exp_m(\xi^\wedge) \quad (31)$$

gdzie $\exp_m$ jest funkcją $\exp$ stosowaną dla macierzy, a $\xi^\wedge$ oznacza przekształcenie wektora do macierzy skośnie-symetrycznej w postaci:

$$\xi^\wedge = \begin{bmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \end{bmatrix}^\wedge = \begin{bmatrix} 0 & -\xi_3 & \xi_2 \\ \xi_3 & 0 & -\xi_1 \\ -\xi_3 & \xi_1 & 0 \end{bmatrix} \quad (32)$$

Mapowanie odwrotne przyjmie natomiast postać:

$$\log(\exp(\xi)) = \xi \quad (33)$$

Istotne jest to, że wspomniane mapy mogą być wykorzystywane do przeniesienia zależności nieliniowych do zależności liniowych i odwrotnie z zachowaniem odpowiedniej dokładności tylko w określonym (niewielkim) otoczeniu punktu styczności przestrzeni.

W omawianych pracach wykorzystujących algebrę Liego w opisie modelu dane wejściowe stanowią wielkości pozyskiwane z układu czujników bezwładnościowych INS (*ang. Inertial System*), który rejestruje prędkości kątowe $\omega = [\omega_x, \omega_y, \omega_z]^T \in \mathbb{R}^3$ oraz przyspieszenia liniowe

$a = [a_x, a_y, a_z]^T \in \mathbb{R}^3$. Nawigowana platforma porusza się względem inercjalnego układu związanego z Ziemią.

We wspomnianych powyżej pracach mapowana jest macierz stanu $\mathbf{x}$ estymatora w następujący sposób:

$$\mathbf{x}_n = \exp(\xi) \bar{\mathbf{x}}_n, \quad \xi \sim \mathcal{N}(0, \mathbf{P}_n) \quad (34)$$

, gdzie $\mathbf{x}_n$ jest stanem układu w chwili n , $\bar{\mathbf{x}}_n$ określa średni estymowany stan w chwili n , $\mathbf{P}_n$ jest macierzą kowariancji, ξ jest niepewnością stanu.

Stan układu nawigacji estymowany jest z wykorzystaniem parametrów $(\mathbf{x}, \mathbf{b})$, gdzie $\mathbf{x}$ jest macierzą zawierającą rotację układu $\mathbf{R} \in SO(3)$, prędkość platformy $\mathbf{v} \in \mathbb{R}^3$, położenie platformy $\mathbf{x} \in \mathbb{R}^3$ oraz położenie obserwowanych punktów terenowych $\mathbf{p}_1, \dots, \mathbf{p}_m \in \mathbb{R}^3$. Natomiast $\mathbf{b}$ jest błędem wnoszonym przez żyroskop oraz akcelerometr. Macierz ta o wymiarach $(3 + m + 2) \times (3 + m + 2)$ przyjmuje postać:

$$\mathbf{x} = \begin{bmatrix} \mathbf{R} & \mathbf{v} & \mathbf{x} & \mathbf{p}_1, \dots, \mathbf{p}_m \\ \mathbf{0}_{(m+2) \times 3} & & & \mathbf{I}_{(m+2) \times (m+2)} \end{bmatrix} \quad (35)$$

Macierz błędu $\mathbf{b}$ ma postać:

$$\mathbf{b} = [\mathbf{b}_\omega^T \mathbf{b}_a^T] \quad (36)$$

Dynamika układu platformy modelowana jest w następujący sposób:

$$\text{stan układu platformy} = \begin{cases} \dot{\mathbf{R}} = \mathbf{R}(\boldsymbol{\omega} - \mathbf{b}_\omega + \mathbf{n}_\omega)_\times \\ \dot{\mathbf{v}} = \mathbf{R}(\mathbf{a} - \mathbf{b}_a + \mathbf{n}_a) - \mathbf{g} \\ \dot{\mathbf{x}} = \mathbf{v} \end{cases} \quad (37)$$

, gdzie zapis $(\cdot)_\times$ odnosi się do macierzy skośnie-symetrycznej.

Błędy układu pomiarowego aktualizowane są w następujący sposób:

$$\dot{\mathbf{b}} = \begin{cases} \dot{\mathbf{b}}_\omega = \mathbf{n}_{b_\omega} \\ \dot{\mathbf{b}}_a = \mathbf{n}_{b_a} \end{cases} \quad (38)$$

W pracach rozpatruje się gaussowskie rozkłady błędu przetwarzanych zmiennych:

$$\mathbf{n} = [\mathbf{n}_\omega^T \mathbf{n}_a^T \mathbf{n}_{b_\omega}^T \mathbf{n}_{b_a}^T]^T \sim \mathcal{N}(\mathbf{0}, \mathbf{Q}) \quad (39)$$

Istotne jest, że w algorytmach opisywanych w literaturze, np. [42],[56] zakłada się statykę obiektów terenowych, co implikuje w stanie układu następującą zależność:

$$\text{stan obiektów terenowych} = \{\dot{\mathbf{p}}_i = 0, \quad i = 1, \dots, m; \quad (40)$$

Wyzerowanie $\dot{\mathbf{p}}_i$ pozwala na wyznaczenie zależności pomiędzy punktami terenowymi ulokowanymi dowolnie w przestrzeni trójwymiarowej i ich rzutami na płaszczyznę obrazu pod warunkiem dysponowania dwoma ujęciami tych samych punktów. Macierz istotną przytoczoną w zależności (26) wyznaczył w swojej pracy Longuet-Higgins [57]. W omawianej transformacji wykorzystuje się macierz, do której wyznaczenia niezbędne jest rozwiązanie układu równań opisujących wzajemne położenie na dwóch obrazach minimum ośmiu punktów.

W odniesieniu do relacji w rozpatrywanym układzie nawigacji zależność na transformację pomiędzy współrzędnymi znormalizowanymi na płaszczyźnie obrazu, a punktami terenowymi przedstawia zależność:

$$\lambda \begin{bmatrix} x_u^i \\ y_v^i \\ 1 \end{bmatrix} = \Pi [\mathbf{R}_k^T (\mathbf{R}^T (\mathbf{p}_i - \mathbf{x}) - \mathbf{x}_k)] \quad (41)$$


W równaniu tym λ jest parametrem skalującym, Π jest macierzą wewnętrzną kamery (jej opis dostępny jest w dalszej części pracy), $\mathbf{R}_k, \mathbf{x}_k$ reprezentują rotację i translację z układu platformy do układu kamery, natomiast $\mathbf{R}$ jest rotacją z terenowego układu referencyjnego dla procesu nawigacji.

W związku z podejmowaniem zagadnienia nawigacji konieczne jest odniesienie uzyskanego stanu w układzie lokalnym do układu związanego z Ziemią. Dlatego zdecydowano się na prezentację zależności umożliwiających takie transformacje.

Zagadnienie nawigacji platformy latającej związane jest z określaniem jej współrzędnych w różnych układach odniesienia. Obecnie powszechnie wykorzystywane są metody precyzyjnej nawigacji w oparciu o systemy satelitarne. Przykładami takich systemów są: amerykański GPS (ang. *Global Positioning System*), europejski GALILEO oraz rosyjski GLONASS. W układzie GPS położenie satelit transmitowane jest w komunikatach nawigacyjnych w odniesieniu do układu ECEF (ang. *Earth-centered, Earth-fixed*) opisanego modelem elipsoidy standardu geodezyjnego WGS 84 (ang. *World Geodetic System 84*). Układ ECEF jest związany z Ziemią według następujących zależności:

- środek układu znajduje się w środku grawitacyjnym Ziemi,
- oś pionowa układu pokrywa się z osią polarną ziemi i jest skierowana na północ,
- oś OX przecina południk zerowy, a oś OY dopełnia układ prawoskrętny,
- układ rotuje zgodnie z kierunkiem i prędkością obrotu Ziemi względem osi Z,


- układ ECEF ze względu na obrót wokół wspólnej osi pokrywa się cyklicznie z inercyjnym układem ziemskim ECI (ang. *Earth-Centered Inertial*), co przedstawiono na Rys. 4.2.1.



Rys. 4.2.1 Relacja pomiędzy układami ECI oraz ECEF

Położenie referencyjne punktu równonocy wiosennej dla systemu GPS określono 1 stycznia 2000 roku o godzinie 12.00 czasu standardowego UTC (ang. *Coordinated Universal Time*). Przypisanie konkretnej daty do wzorca punktu równonocy było konieczne ze względu na nieznaczne, ale ciągle przemieszczanie się płaszczyzny równikowej (rozpiętej na osiach X i Y układów ECI oraz ECEF) względem sfery niebieskiej, której przyczynami są m.in: nierównomierny rozkład masy Ziemi oraz oddziaływania grawitacyjne Słońca i Księżycy.

Dane nawigacyjne, którymi posługują się użytkownicy systemów nawigacji satelitarnej zazwyczaj nie stanowią współrzędnych kartezjańskich, a współrzędne geodezyjne odniesione do modelu elipsoidy ziemskiej WGS84. Relację pomiędzy układami przedstawia Rys. 4.2.2. Na rysunku zilustrowano także lokalny układ kartezjański NED styczny do elipsoidy standardu WGS84.



Rys. 4.2.2 Relacja układów WGS84, ECEF i NED

Punkt w układzie geodezyjnym WGS84 określamy jako:

$$P_{WGS} = \begin{pmatrix} \lambda \\ \varphi \\ h \end{pmatrix} \quad (42)$$

Długość geodezyjna λ , szerokość geodezyjna φ oraz wysokość elipsoidalna h w układzie WGS84 w odniesieniu do kartezjańskiego układu ECEF wyznaczane są z zależności (43)-(45):

$$\lambda = \text{atan} \frac{y_E}{x_E}, \quad (43)$$

$$\varphi = \text{atan} \left(\frac{z_E + \frac{e^2 a^2 \sin^3 \zeta}{b}}{\xi - e^2 a e^2 \cos^3 \zeta} \right), \quad (44)$$

$$h = \frac{\xi}{\cos \varphi} - r_T \quad (45)$$

, gdzie a , b , e są stałymi o wartościach:

$$\begin{aligned} a &= 6378137 \text{ m}, \\ b &= 6356752.314245 \text{ m}, \\ e^2 &= 6.69437999014 \times 10^{-3}, \end{aligned} \quad (46)$$

, natomiast parametry ξ , ζ , r_T wyznacza się z zależności:

$$\xi = \sqrt{x^2 + y^2}, \quad (47)$$

$$\zeta = \operatorname{atan}\left(\frac{az}{\xi}\right), \quad (48)$$

$$r_T = \frac{a}{\sqrt{1 - e^2 \sin^2 \varphi}}. \quad (49)$$

W pracy wykorzystano również prostokątne, prawoskrętne układy związane z obiektem nosiciela – platformę latającą przenoszącą układ pomiarowy, układ topograficzny, związany z płaszczyzną styczną do elipsoidy WGS84 oraz układ kartezjański związany z płaszczyzną obrazową kamery cyfrowej.

Lokalny, nieinercjalny układ topograficzny NED (*ang. north-east-down*) to ortogonalny, prawoskrętny układ współrzędnych kartezjańskich, który jest powszechnie używany w lotnictwie. Osie ON i OE rozpięte są na płaszczyźnie stycznej do elipsoidy opisanej w standardzie WGS84. Początek tego układu w pracy określono jako punkt na powierzchni elipsoidy poniżej środka ciężkości platformy latającej przenoszącej układ nawigacji określany wzdłuż normalnej do ww. płaszczyzny stycznej. Oś ON układu skierowana jest na północ, oś OE na wschód, a oś D w dół, pod powierzchnię Ziemi wzdłuż ww. normalnej.

Punkt w układzie NED określamy jako:


$$P_{NED} = \begin{pmatrix} x \\ y \\ z \end{pmatrix} \quad (50)$$

Znając położenie punktu referencyjnego $(\lambda_0, \varphi_0, h_0)^T$ w układzie WGS84 możliwe jest wyznaczenie transformacji pomiędzy układem NED i WGS84 dla dowolnego punktu poprzez zależności:

$$\begin{aligned} \Delta\lambda &= \frac{y}{(r_T + h_0) \cos \varphi_0} \\ \Delta\varphi &= \frac{x}{r_M + h_0}, \text{ gdzie} \\ r_M &= r_T \frac{1 - e^2}{1 - e^2 \sin^2 \varphi_0}, \quad \Delta\varphi = \varphi - \varphi_0, \quad \Delta\lambda = \lambda - \lambda_0 \end{aligned} \quad (51)$$

Zarówno r_M , jak i r_T w powyższych równaniach wyliczane są w odniesieniu do współrzędnej φ_0 .

W pracy rozpatrywany jest również lokalny układ kamery otworkowej (*ang. piano*), który przedstawiono na Rys. 4.2.3.



Rys. 4.2.3 Model kamery otworkowej

Obraz kamery według tego modelu uzyskuje się przez rzutowanie punktów z trójwspółrzednego, kartezjańskiego układu związanego z obserwowanym terenem, w pracy rozumianym jako układ NED, na płaszczyznę obrazu przy użyciu transformacji perspektywicznej.

Układ współrzędnych kamery (X_k, Y_k, Z_k) ma początek w ognisku, a jego oś Z_k pokrywa się z jej osią optyczną urządzenia. Układ współrzędnych obrazowych umieszczony jest przed ogniskiem kamery w odległości f . Położenie punktu $m(u, v)$ zlokalizowanego na płaszczyźnie obrazowej można opisać za pomocą znormalizowanych współrzędnych układu kamery według zależności:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} f_x x' + c_x \\ f_y y' + c_y \end{bmatrix}, \text{ gdzie } \begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \frac{X_k}{Z_k} \\ \frac{Y_k}{Z_k} \end{bmatrix} \Leftrightarrow Z_k \neq 0,$$

gdzie

f_x – ogniskowa kamery w osi OX,


f_y – ogniskowa kamery w osi OY,

c_x – współrzędne początku układu obrazowego w osi OU,

c_y – współrzędne początku układu obrazowego w osi OV.

Współrzędne obrazowe punktu w modelu kamery otworkowej są współrzędnymi znormalizowanymi względem współrzędnej Z_k , której wartość musi być różna od zera.

W pracy zakłada się, że układ podstawowy nie jest identyczny z układem kamery z powodu ruchu kamery wraz platformą latającą, co przedstawia Rys. 4.2.4 Na rysunku ten sam układ optyczny umieszczony jest w różnej orientacji i położeniu względem terenu.



Rys. 4.2.4 Rotacja i translacja platformy latającej w trakcie procesu nawigacji

Dla takiej sytuacji przed przystąpieniem do rzutowania punktu na płaszczyznę obrazu, należy dokonać transformacji związanej z rotacją i przesunięciem współrzędnych punktu z układu podstawowego do układu kamery według zależności (53).

$$\begin{bmatrix} X_k \\ Y_k \\ Z_k \end{bmatrix} = \mathbf{R} \begin{bmatrix} X_w \\ Y_w \\ Z_w \end{bmatrix} + \mathbf{t}, \quad (53)$$

gdzie:

$\mathbf{R}$ jest macierzą rotacji,

$\mathbf{t}$ jest wektorem translacji (przesunięcia).

Model przedstawiony na Rys. 4.2.4 pozwalający na przekształcenie punktu z przestrzeni dwuwymiarowej na punkt w układzie trójwymiarowym można uogólnić wprowadzając pewne modyfikacje. Punkt opisany wektorem $\mathbf{m}[u, v]^T$ rozszerza się do postaci $\tilde{\mathbf{m}}[u, v, I]^T$, podobnie punkt w układzie podstawowym opisany wektorem $\mathbf{M}[X_w, Y_w, Z_w]^T$ rozszerza się do postaci $\tilde{\mathbf{M}}[X_w, Y_w, Z_w, I]^T$. Wówczas dla idealnej kamery tzn. takiej, która nie wprowadza zniekształceń obrazowych relacja pomiędzy ww. punktami może być przedstawiona jako:

$$s\tilde{\mathbf{m}} = \mathbf{A}[\mathbf{R}|\mathbf{t}] \tilde{\mathbf{M}}, \quad \text{gdzie } \mathbf{A} = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}, \quad (54)$$

Natomiast s jest parametrem skali. Zapis $[\mathbf{R}|\mathbf{t}]$ oznacza połączoną macierz zewnętrzną kamery w postaci:

$$[\mathbf{R}|\mathbf{t}] = \begin{bmatrix} r_{11} & r_{12} & r_{13} & t_x \\ r_{21} & r_{22} & r_{23} & t_y \\ r_{31} & r_{32} & r_{33} & t_z \end{bmatrix}, \quad (55)$$

Macierz $\mathbf{A}$ często nazywana jest w literaturze macierzą wewnętrzną kamery.

Niestety, dostępne na rynku kamery odbiegają od idealnego modelu przedstawionego powyżej i wprowadzają do procesu transformacji różne zniekształcenia. W procesie nawigacji z wykorzystaniem źródeł wizyjnych istotne jest uzyskanie maksymalnie precyzyjnych transformacji pomiędzy omawianymi układami. Implikuje to konieczność przeprowadzania kalibracji wykorzystywanej w pracy kamery. Kalibracja pozwala na wyznaczenie dodatkowych parametrów opisujących relacje wprowadzanych zniekształceń z przedstawioną transformacją. Po ich wyznaczeniu możliwa jest korekta transformacji pozwalająca na uzyskanie wymaganej precyzji. W przypadku parametrów wewnętrznych kamery wyznacza się ogniskową obiektywu, zniekształcenia radialne, styczne i przyzmatyczne związane z układem optycznym, a także rzeczywiste współrzędne środka obrazu kamery, które nie muszą leżeć w geometrycznym środku matrycy przetwornika ze względu na niedokładność optyczną obiektywu określoną np. przez skrzywienie osi optycznej obiektywu.

Dla kamer wprowadzających zniekształcenia przedstawiony powyżej model idealnej kamery otworkowej modyfikuje zależność na współrzędne płaszczyzny obrazowej do postaci:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} f_x x'' + \gamma + c_x \\ f_y y'' + c_y \end{bmatrix}, \quad (56)$$

gdzie:

$$\begin{bmatrix} x'' \\ y'' \end{bmatrix} = \begin{bmatrix} x' \frac{1+k_1 r^2+k_2 r^4+k_3 r^6}{1+k_4 r^2+k_5 r^4+k_6 r^6} + p_1 x' y' + p_2 (r^2 + 2x'^2) + \rho_1 r^2 + \rho_2 r^4 \\ y' \frac{1+k_1 r^2+k_2 r^4+k_3 r^6}{1+k_4 r^2+k_5 r^4+k_6 r^6} + p_1 (r^2 + 2y'^2) + 2p_2 x' y' + \rho_3 r^2 + \rho_4 r^4 \end{bmatrix}, \quad (57)$$

$$r^2 = x'^2 + y'^2,$$

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \begin{bmatrix} \frac{X_k}{Z_k} \\ \frac{Y_k}{Z_k} \end{bmatrix} \Leftrightarrow Z_k \neq 0,$$

$k_1, \dots, k_6$ są parametrami zniekształcenia radialnego,

p_1, p_2 są parametrami zniekształcenia stycznego,

$\rho_1, \dots, \rho_4$ są parametrami zniekształcenia przyzmatycznego,

γ jest współczynnikiem przekoszenia.

Współcześnie wiele metod kalibracji rozwiązuje problem kalibracji w dwóch etapach. Procedurę taką pierwszy raz zaproponowano w [59], a obecnie bardzo często wykorzystywana jest także metoda [60]. W pierwszym etapie tych metod za pomocą zależności liniowych znajduje się przybliżone rozwiązanie, które stanowi warunek początkowy dla metod nieliniowej optymalizacji stosowanych w drugim etapie. Podział zagadnienia na dwa etapy pozwala na zwiększenie dokładności w porównaniu do metod klasycznych uwzględniających zniekształcenia.

Proces kalibracji wymaga znajomości współrzędnych serii punktów w przestrzeni z ich jednoznacznym dopasowaniem do punktów na płaszczyźnie obrazu.

W pracy wykorzystano metodę kalibracji przedstawioną w [60], zakładającą, że pojedyncza kamera obserwuje nieruchomą płaszczyznę ze znanym (w ujęciu kształtów i odległości wzajemnych), optycznym wzorcem strukturalnym, który nie ulega zmianom w czasie obserwacji. Obserwacja obejmuje, co najmniej dwa różne kątowe ujęcia wzorca.

W pracy tej zakłada się, że płaszczyzna w układzie terenowym posiada zerową wartość współrzędnej Z_w . Na podstawie macierzy A z równania (58) określa się następującą postać macierzy B :

$$\mathbf{B} = \mathbf{A}^{-T} \mathbf{A}^{-1} \equiv \begin{bmatrix} B_{11} & B_{12} & B_{13} \\ B_{21} & B_{22} & B_{23} \\ B_{31} & B_{32} & B_{33} \end{bmatrix} =$$

$$= \begin{bmatrix} \frac{1}{f_x^2} & -\frac{\gamma}{f_x^2 f_y} & \frac{c_y \gamma - c_x f_y}{f_x^2 f_y} \\ -\frac{\gamma}{f_x^2 f_y} & -\frac{\gamma^2}{f_x^2 f_y^2} + \frac{1}{f_y^2} & -\frac{\gamma(c_y \gamma - c_x f_y)}{f_x^2 f_y^2} - \frac{c_y}{f_y^2} \\ \frac{c_y \gamma - c_x f_y}{f_x^2 f_y} & -\frac{\gamma(c_y \gamma - c_x f_y)}{f_x^2 f_y^2} - \frac{c_y}{f_y^2} & \frac{(c_y \gamma - c_x f_y)^2}{f_x^2 f_y^2} + \frac{c_y^2}{f_y^2} + 1 \end{bmatrix} \quad (58)$$

$$\mathbf{b} = [B_{11}, B_{21}, B_{22}, B_{13}, B_{23}, B_{33}]^T \quad (59)$$

$$s\tilde{\mathbf{m}} = \mathbf{H} \tilde{\mathbf{M}}, \quad (60)$$

, gdzie:

$$\mathbf{H} = \mathbf{A}[\mathbf{r}_1 \ \mathbf{r}_2 \ \mathbf{t}], \quad (61)$$

$$\mathbf{H} = \mathbf{h}_i = [h_{i1}, h_{i2}, h_{i3}]^T, \quad (62)$$

$$\mathbf{h}_i^T \mathbf{B} \mathbf{h}_j = \mathbf{v}_{ij}^T \mathbf{b}, \quad (63)$$

$$\mathbf{v}_{ij} = [h_{i1}h_{j1}, h_{i1}h_{j2} + h_{i2}h_{j1}, h_{i2}h_{j2}, h_{i3}h_{j1} + h_{i1}h_{j3}, h_{i3}h_{j2} + h_{i2}h_{j3}, h_{i3}h_{j3}]^T, \quad (64)$$

$$\begin{bmatrix} \mathbf{v}_{12}^T \\ (\mathbf{v}_{11} - \mathbf{v}_{22})^T \end{bmatrix} \mathbf{b} = 0. \quad (65)$$

Wektor $\mathbf{b}$ wyznaczamy rozwiązując powyższe równania dla n ujęć uzyskując macierz $\mathbf{V}$ o wymiarach $2n \times 6$. Gdy $n \geq 3$ możliwe jest uzyskanie rozwiązania jednoznacznie określonego. Następnie wyznaczane są parametry macierzy wewnętrznej kamery A . Wiedząc, że:

$$\mathbf{B} = s\mathbf{A}^{-T} \mathbf{A} \quad (66)$$

wyznacza się kolejno:

$$c_y = \frac{B_{11}B_{13} - B_{11}B_{23}}{B_{11}B_{22} - B_{12}^2},$$

$$s = B_{33} - \frac{[B_{13}^2 + c_y(B_{12}B_{13} - B_{11}B_{23})]}{B_{11}}, \quad (67)$$

$$\begin{aligned}
f_x &= \sqrt{\frac{s}{B_{11}}}, \\
f_y &= \sqrt{\frac{sB_{11}}{B_{11}B_{22}-B_{12}^2}}, \\
\gamma &= -\frac{B_{12}f_x^2f_y}{s}, \\
c_x &= \frac{\gamma c_y}{\alpha} - \frac{B_{13}\alpha^2}{s}
\end{aligned}$$

Następnym krokiem jest wyznaczenie parametrów zniekształceń wprowadzanych przez kamerę:

$$\begin{bmatrix} u \\ v \end{bmatrix} = \begin{bmatrix} f_x x'' + \gamma + c_x \\ f_y y'' + c_y \end{bmatrix}, \quad (68)$$

$$\begin{bmatrix} x'' \\ y'' \\ 1 \end{bmatrix} = \begin{bmatrix} r_{11} & r_{12} & t_x \\ r_{21} & r_{22} & t_y \\ r_{31} & r_{32} & t_z \end{bmatrix} \begin{bmatrix} x_i \\ y_i \\ 1 \end{bmatrix} \quad (69)$$

Po wyznaczeniu parametrów macierzy A , estymuje parametry zewnętrzne kamery tj. macierz R oraz wektor t z uwzględnieniem zależności (57) dla dwóch pierwszych współczynników zniekształceń radialnego i stycznego oraz z pominięciem współczynników zniekształcenia pryzmatycznego. Metoda estymacji zakłada, że mając n ujęć, z których każde zawiera m punktów o znanym położeniu minimalizuje się następujący funkcjonal:

$$\sum_{i=1}^n \sum_{j=1}^m \| \mathbf{m}_{ij} - \hat{\mathbf{m}}(\mathbf{A}, \mathbf{R}_i, \mathbf{t}_i \mathbf{M}_j) \|^2 \quad (70)$$

Powyższy problem jest zagadnieniem minimalizacji nieliniowej i może być rozwiązany metodą Levenberg-a-Marquardt-a, gdzie wartości do inicjalizacji mogą być uzyskane z zależności:

$$\begin{aligned}
\mathbf{R} &= [\mathbf{r}_1, \mathbf{r}_2, \mathbf{r}_3], \\
\mathbf{r}_1 &= s\mathbf{A}^{-1}\mathbf{h}_1, \quad \mathbf{r}_2 = s\mathbf{A}^{-1}\mathbf{h}_2, \quad \mathbf{r}_1 = \mathbf{r}_1 \times \mathbf{r}_2, \quad \mathbf{t} = s\mathbf{A}^{-1}\mathbf{h}_3
\end{aligned}$$

Podsumowanie podrozdziału:

Przedstawione w rozdziale modele nawigacji wizualno-bezwładnościowej pozwalają na sformułowanie własnych modeli, a także modyfikacje istniejących rozwiązań, które pozwolą na osiągnięcie wyznaczonych w pracy celów.

Istotnym spostrzeżeniem wynikającym z analizy literatury jest przyjmowanie w części prezentowanych modeli założenia o statycznym układzie obserwowanych obiektów terenowych. Takie założenie może powodować ograniczenie skuteczności tych algorytmów dla układów z jedną kamerą pracujących w trakcie nawigacji platform latających.

Zaprezentowane w rozdziale układy odniesienia oraz transformacje pozwalają na sformułowanie modelu zależności pomiędzy wielkościami mierzonymi tj. obrazem z kamery

danymi z układu bezwładnościowego oraz wysokościomierza, a także przeniesienie tych zależności do układu inercyjnego związanego z Ziemią, co jest zasadniczym celem układu nawigacyjnego. Model procesu kalibracji umożliwia znaczącą poprawę dokładności odwzorowania rzeczywistych obiektów w przestrzeni trójwymiarowej na ich rzuty na płaszczyznę obrazu. Dzięki parametrom zawartym w macierzy wewnętrznej kamery możliwe są korekty zniekształceń, które mają negatywny wpływ na możliwość wyliczania homografii pomiędzy obrazami, a w skrajnym przypadku mogą nawet prowadzić do braku możliwości jej wyznaczenia. Taka sytuacja może mieć miejsce przy zastosowaniu modelu dopasowania statystycznego obrazów według algorytmu RANSAC, którego próg ma niską wartość w stosunku do wprowadzanych zniekształceń. Odwzorowania płaszczyzna-płaszczyzna są istotne w algorytmach wykrywania i śledzenia cech na obrazach, do których zalicza się algorytm KLT [50], który wykorzystano w badaniach przedstawionych w niniejszej pracy.

Dzięki zastosowaniu macierzy wewnętrznej kamery możliwe jest także wyznaczenie macierzy istotnej³, która jest podstawą odwzorowania pomiędzy przestrzenią trójwymiarową i płaszczyzną. Odwzorowanie punktów w przestrzeni trójwymiarowej wymaga znajomości położenia 8 tożsamyh punktów obserwowanych na dwóch obrazach. Tożsamość punktów rozumiana jest jako rzuty tych samych statycznych punktów z przestrzeni trójwymiarowej na dwie różne płaszczyzny obrazowe.

Parametry zewnętrzne kamery wiążą położenie i orientację kamery z trójwymiarowym układem podstawowym.

4.3. UWARUNKOWANIA ROZMYCIA OBRAZÓW TERENU


Tematyka rozmycia obrazów jest szeroko rozpatrywana w literaturze, a zjawisko rozmycia obrazów związane z ruchem kamery jest opisane. Niemniej jednak usuwanie lub ograniczanie tego niekorzystnego zjawiska w układzie nawigacyjnym nie jest zagadnieniem trywialnym. Zwłaszcza w kontekście ruchu układu obserwacji z prędkościami powyżej 200 m/s, przy jednoczesnym wymaganiu przetwarzania w czasie możliwie zbliżonym do rzeczywistego.

W przeanalizowanych pracach większość stosowanych metod usuwania rozmycia wykorzystuje algorytm Richardson–Lucy [61],[62], który iteracyjnie przeprowadza proces dekonwolucji obrazu przy zakładanych parametrach filtru. Drugą często stosowaną metodą jest filtracja Wienera [63] operująca najczęściej w dziedzinie widmowej. Filtr Wienera to stacjonarny, liniowy filtr optymalny (minimalizujący błąd średniokwadratowy – MSE) stosowany do niwelowania zakłóceń w postaci rozmycia przy występowaniu addytywnego szumu białego.

Efektywne wykorzystanie ww. narzędzi wiąże się ze znajomością modelu rozmycia. Jeżeli model ten jest obciążony błędem usuwanie efektu rozmycia nie jest optymalne przy kryterium najmniejszej różnicy pomiędzy obrazem zarejestrowanym bez uwarunkowań powodujących rozmycie i obrazem będącym efektem filtracji usuwającej rozmycie. Skutkiem błędnie

³ macierz istotna – tłumaczenie terminu angielskiego terminu oryginalnego (ang. essential matrix)

przyjętych parametrów dla filtra Wienera jest powstanie tzw. efektu dzwonienia (*ang. ringing effect*) opisanego w pracy [64], który na obrazie powoduje przestrzennie powtarzalne artefakty w postaci jasnych i ciemnych plam wokół krawędzi elementów obrazu. Związane jest to z efektem Gibbsa. Przyczyna powstania ww. efektu jest następstwem przetwarzania sygnału bazującego na iloczynie jego widma oraz widma prostokątnego filtra dolnoprzepustowego. Ideę tego przetwarzania przedstawia Rys. 4.3.1. Na rysunku przedstawiono sygnał prostokątny, który może reprezentować niedopasowanie modelu sygnału do rzeczywistego sygnału rozmycia. Na skutek transformacji Fouriera sygnał ten przyjmuje postać $\frac{\sin x}{x}$, która po scałkowaniu, będącego konsekwencją iloczynu widm powoduje powstanie sygnału oscylacyjnego asymptotycznie tłumionego.



Rys. 4.3.1 Sygnał prostokątny i jego transformata Fouriera oraz całka z transformaty

W przeanalizowanej literaturze autorzy wykorzystują m.in. metody optymalizacyjne iteracyjnie poszukujące najlepszego efektu usunięcia rozmycia dla różnych postaci stosowanego filtra. Takie podejście zaprezentowano w pracy [65].

Metody korekcji obrazów związane z usuwaniem zjawiska rozmycia stosowane są m.in. w medycynie przy korekcji zdjęć rentgenowskich, co przedstawiono w pracy [66] oraz w astronomii, czego efekty prezentuje praca [67].

Przekształcenia w układzie optycznym można ogólnie opisać symbolicznie za pomocą operatora ℓ , który wskazuje, w jaki sposób układ dokonuje przekształcenia sygnału wejściowego w sygnał wyjściowy. W omawianym przypadku wejście i wyjście stanowią płaszczyzny Π i Λ na których określono funkcje f oraz g .

Funkcja g opisująca wyjście układu jest związana z funkcją wejściową f zależnością

$$g(x_2, y_2) = \ell \{ f(x_1, y_1) \}, \quad (71)$$

przy czym zakłada się, że badany układ spełnia zasadę superpozycji, co determinuje liniowość operatora ℓ . Jeżeli (na podstawie własności filtracji funkcji delta Diraca) funkcja f przedstawiona zostanie w postaci całki, to sygnał g określać będzie wyrażenie

$$g(x_2, y_2) = \ell \left\{ \iint f(x, y) \delta(x_1 - x, y_1 - y) dx dy \right\} \quad (72)$$

$$g(x_2, y_2) = \iint f(x_1, y_1) \ell\{\delta(x_1 - x, y_1 - y)\} dx dy \quad (73)$$

Wielkość

$$\ell\{\delta(x_1 - x, y_1 - y)\} \quad (74)$$

opisuje obraz punktowego przedmiotu otrzymywany w płaszczyźnie obrazowej (wyjściowej) Λ analizowanego układu. Oznaczając

$$h(x_2, y_2; x, y) = \ell\{\delta(x_1 - x, y_1 - y)\} \quad (75)$$

zależność (73) można wyrazić w postaci

$$g(x_2, y_2) = \iint f(x_1, y_1) h(x_2, y_2; x, y) dx dy. \quad (76)$$

Funkcja h określana jest mianem odpowiedzi impulsowej układu, która w literaturze anglojęzycznej w odniesieniu do obrazu oznaczana jest jako PSF (*ang. Point Spread Function*). Dla przypadku optycznego PSF jest odpowiedzią, przy wymuszeniu punktowym. Charakteryzuje ona w sposób kompletny transformacyjne własności układu liniowego i jest wystarczająca do opisu jego działania jako przetwornika sygnałów.

Przyjmując założenie upraszczające, że odpowiedź impulsowa rozpatrywanego układu optycznego zależy wyłącznie od przesunięcia, tj. różnicy współrzędnych $x_2 - x$ i $y_2 - y$:

$$h(x_2, y_2; x, y) = h(x_2 - x, y_2 - y) \quad (77)$$

i uwzględniając zamianę zmiennych zgodnie z przyjętym oznaczeniem współrzędnych dla płaszczyzny wejściowej Π :

$$x \rightarrow x_1 \quad \wedge \quad y \rightarrow y_1 \quad (78)$$

otrzymuje się ostatecznie

$$g(x_2, y_2) = \iint f(x_1, y_1) h(x_2 - x_1, y_2 - y_1) dx dy, \quad (79)$$

co można uogólnić do zależności

$$g(x, y) = f(x, y) * h(x, y)$$

, gdzie symbol $*$ oznacza operację splotu sygnałów.

W przypadku rozmycia liniowego obrazu Π dla ruchu prostoliniowego, w którym przemieszczenie układu akwizycji będzie oddziaływało na L kolejnych elementów Π , w zadanym kierunku określonym przez kąt θ przy założeniu, możliwe jest opisanie funkcji odpowiedzi impulsowej układu jako zależności:

$$h(x, y) = \begin{cases} \frac{1}{L}, & \text{gd}y \sqrt{x^2 + y^2} \leq \frac{L}{2} \wedge \frac{x}{y} = -\tan \theta, \\ 0, & \text{w pozostałych przypadkach} \end{cases} \quad (80)$$

Przy czym w praktycznych zastosowaniach dla obrazów cyfrowych o skończonej rozdzielczości modyfikuje się do postaci:

$$h(x, y) \rightarrow h(i, j), \quad i, j \in \mathbb{N}$$

$$h(i, j) = \max \left(1 - \min \left(\frac{|ai + bj + c|}{\sqrt{a^2 + b^2}} \right) \right) \quad (81)$$

Możliwe jest także wyznaczenie przybliżonej funkcji PSF na podstawie obrazów g_1, g_2 , uzyskiwanych z różnym czasem ekspozycji kamery oraz w warunkach występowania szumu własnego układu, co przedstawiono w [68] i opisano równaniami:

$$\alpha g_1(x, y) = f(x, y) + n_1$$

$$g_2(x, y) = h(x, y) * f(x, y) + n_2, \quad (82)$$

gdzie n_1 i n_2 są szumami własnymi kamery przy dwóch różnych czasach ekspozycji, natomiast α jest współczynnikiem określającym różnicę pomiędzy obrazami g_1 i g_2 . Zależność (82) można przekształcić również do postaci:

$$g_2(x, y) = \alpha h(x, y) * f(x, y) + n(x, y), \text{ gdzie} \quad (83)$$

$$n(x, y) = n_2(x, y) - h(x, y) * n_1(x, y),$$

Zakładając gaussowski charakter szumu kamery dla obu rozpatrywanych przypadków oraz przyjmując założenie, że wariancja szumu $\sigma_2^2 \ll \sigma_1^2$ można z przybliżeniem określić funkcję $h(x, y)$. Dokonywane jest to na podstawie odwrotnej transformacji Fouriera funkcji $H(\omega)$ uzyskanej na bazie filtra Wiener-a, która jest określona jako:

$$H(\omega) = \frac{\alpha G_1(\omega) G_2(\omega)}{\alpha^2 |G_1(\omega)|^2 + \sigma_1^2} \quad (84)$$

Duże litery w zależności (84) oznaczają transformaty Fouriera funkcji h, g_1 i g_2 . Współczynnik α dobiera się iteracyjnie poprzez minimalizację zależności:

$$\alpha = \frac{\sum_{(x,y) \in \Omega} g_2(x, y) [g_1 * h(x, y)] n(x, y)}{\sum_{(x,y) \in \Omega} [g_1 * h(x, y)]^2}, \quad \Omega \subset \mathbb{R}^2 \quad (85)$$

Wartość początkowa procesu minimalizacji wykorzystuje różnice średnich wartości na obrazach g_1 i g_2 :

$$\alpha_0 = \frac{\sum_{(x,y) \in \Omega} g_2(x, y)}{\sum_{(x,y) \in \Omega} g_1(x, y)}. \quad (86)$$

Po zastosowaniu takiej funkcji obraz wyjściowy Λ , będzie zawierał rozmyte piksele w kierunku θ . Ostateczny efekt rozmycia będzie zależny od osiągniętej przez platformę prędkości, która będzie wpływała na drogę s przebytą przez platformę w trakcie akwizycji. Drogę przebytą przez ciało poruszające się z prędkością $V(t)$ od chwili początku akwizycji t_0 do jej zakończenia w chwili t_1 określa się zależnością:

$$s(t) = \int_{t_0}^{t_1} V(t) dt \quad (87)$$

Przy założeniu, że platforma porusza się prostoliniowo w jednym kierunku droga będzie tożsama z przebytą odległością $d(t)$ w terenie. Aby wyznaczyć liczbę pikseli poddanych rozmyciu konieczne jest odniesienie przebytej odległości na liczbę pikseli L odpowiadającą tej odległości w obrazowanym terenie

$$d \rightarrow L \quad (88)$$

$$d = VT_e, \quad (89)$$

gdzie T_e jest czasem ekspozycji matrycy kamery układu nawigacji.


Określając odwzorowanie przestrzenne piksela (przyporządkowanie odległości w terenie do pojedynczego piksela), jako p_d możliwe jest wyznaczenie wartości L – liczby pikseli ulegających rozmyciu w trakcie akwizycji w ruchu, które wyniesie:

$$L = \frac{d}{p_d} \quad (90)$$

5. ZAŁOŻENIA FUNKCJONOWANIA GŁOWICY SAMONAPROWADZANIA PLATFORMY LATAJĄCEJ


Układ samonaprowadzania platformy latającej funkcjonuje w oparciu o dane nawigacyjne i parametry, które stanowią wejścia dla modelu naprowadzania. W pracy nie rozpatruje się aspektów sterowania platformą w procesie naprowadzania. Dane nawigacyjne pozyskiwane są z systemu pomiarowego, który obejmuje układy czujników, a także z cyfrowej bazy danych referencyjnych. Procesorowe układy przetwarzania realizują algorytmy wyznaczania położenia i orientacji platformy w układzie współrzędnych związanym z Ziemią.

Schemat blokowy rozpatrywanego w pracy systemu nawigacji wchodzącej w skład układu samonaprowadzania przedstawiono na Rys. 5.1.



Rys. 5.1 Schemat blokowy systemu nawigacji rozpatrywanego w pracy


Koncepcja funkcjonowania układu – etap realizacji misji. Platforma bezzałogowa wyposażona jest w sensoryczny układ wizualno-bezwładnościowy oraz wysokościomierz laserowy. Rozpoczyna swój lot z punktu startu do pierwszego punktu nawigacyjnego, wykorzystując do nawigacji dane pozyskiwane z bloku nawigacji inercyjnej. Ze względu na narastającą wraz z upływem czasu rozbieżność pomiędzy rzeczywistością a wskazywaną przez blok nawigacji inercyjnej (IMU) pozycję obiektu przyjęto, że lot w oparciu o wskazania IMU będzie korygowany przez algorytm wizyjny w określonych punktach nawigacyjnych. Funkcjonowanie platformy latającej wyposażonej w układ nawigacji na pierwszym etapie lotu przedstawiono na Rys. 5.2.



Rys. 5.2 Funkcjonowanie platformy latającej wyposażonej w układ nawigacji na pierwszym etapie lotu

Zakłada się, że po przebyciu pewnej odległości, dla której wariancje błędów położenia, kierunku oraz prędkości przekroczą zakładane progi, udział błędów nawigacyjnych


w informacji użytecznej będzie znaczący. Dlatego zakłada się wprowadzanie platformy z układem nawigacyjnym w obszar korekcji stanowiący otoczenie obranego na etapie planowania misji punktu nawigacyjnego A (Rys. 5.3).



Rys. 5.3 Funkcjonowanie platformy latającej wyposażonej w układ nawigacji – orientowanie topograficzne w oparciu o cyfrowe wzorce otoczenia punktu nawigacyjnego A

W trakcie przebywania nad obszarem korekcji platforma dokonuje ciągłej analizy podobieństwa cech obrazowych wzorca przechowywanego w pamięci urządzenia oraz obrazów pozyskiwanych w czasie rzeczywistym, podczas lotu. Po poprawnym wykryciu i dopasowaniu wymaganej liczby cech obrazowych układ platformy wyznacza transformację do nowego układu współrzędnych związanych z wzorcem, a następnie transformuje położenie układu kamery i platformy ponownie do topograficznego układu globalnego. Dzięki opisaniu wzorca współrzędnymi geograficznymi możliwe jest precyzyjne uaktualnienie położenia platformy w przestrzeni i wypracowanie sygnałów korekt do układu nawigacyjnego. W modelu estymatora stanu układu nawigacyjnego macierze kowariancji sprowadzane są do wartości początkowych. Dzięki temu możliwa jest eliminacja skumulowanych błędów wskazań z układu bezwładnościowego.

Od chwili uaktualnienia pozycji układ nawigacyjny rozpoczyna swoją pracę od początku, co zapewnia możliwość nawigowania na kolejny punkt nawigacyjny B. Po wprowadzeniu platformy w obszar korekcji B powtarzane są procedury opisane wyżej dla punktu A, itd., aż do wyczerpania listy punktów nawigacyjnych (Rys. 5.4).



Rys. 5.4 . Funkcjonowanie platformy latającej wyposażonej w układ nawigacji – orientowanie topograficzne w oparciu o cyfrowe wzorce otoczenia punktu nawigacyjnego B

Koncepcja funkcjonowania układu nawigacji – etap planowania misji. Na etapie planowania misji operator oprogramowania, korzystając z dedykowanej aplikacji ustala trasę lotu platformy latającej i definiuje punkty nawigacyjne. Do każdego punktu nawigacyjnego przypisywany jest obraz referencyjny. Każdy z tych obrazów opisywany jest zbiorem parametrów w postaci współrzędnych geograficznych i azymutu pozwalający na jednoznaczne powiązanie pikseli mapy z rzeczywistymi wielkościami metrycznymi obrazowanego terenu.

Umożliwienie realizacji zadań w etapie planowania misji wymagało opracowania dedykowanego oprogramowania przeznaczonego do wyznaczania tras, punktów nawigacyjnych wraz z cyfrowymi opisami terenu ich otoczenia oraz generowania plików misji w dedykowanym formacie. Autor pracy był współautorem oprogramowania w zakresie planowania tras, przetwarzania obrazów cyfrowych i generacji danych referencyjnych.

Zakłada się uproszczony model dynamiki platformy latającej, który opisuje ruch punktu z masą w przestrzeni trójwymiarowej wektorem:

$$\mathbf{T} \in \mathbb{R}^{1 \times 7} : \mathbf{T} = [x_T \ y_T \ z_T \ \theta_T \ \gamma_T \ \phi_T \ V_T] \quad (91)$$

, gdzie $x_T \ y_T \ z_T$ są współrzędnymi położenia platformy latającej (m), $\theta_T \ \gamma_T \ \phi_T$ są kątami odchylenia, pochylenia i przechylenia platformy (rad), a V_T jest modulem prędkości platformy (m/s). Zmiany przyspieszeń platformy aproksymowane są według zależności:

$$\dot{a}_L = \frac{1}{\tau_T} (u_L - a_L) \quad \dot{a}_\theta = \frac{1}{\tau_T} (u_\theta - a_\theta) \quad \dot{a}_\gamma = \frac{1}{\tau_T} (u_\gamma - a_\gamma) \quad (92)$$

, gdzie u_L, u_θ, u_γ są zadawanymi przyspieszeniami – kolejno wzdłużnym oraz kątowymi w płaszczyznach odchylenia i pochylenia (m/s^2), natomiast a_L, a_θ, a_γ są odpowiadającymi przyspieszeniami osiąganymi przez platformę w rozpatrywanej chwili. Manewrowość platformy podlega ograniczeniom w formie:

$$|u_L| \leq \bar{u}_L \quad |u_\theta| \leq \bar{u}_\theta \quad |u_\gamma| \leq \bar{u}_\gamma \quad (93)$$

Zmiany prędkości oraz kątów odchylenia i pochylenia opisane są zależnościami:

$$\dot{V}_T = a_L \quad \dot{\theta}_T = \frac{a_\theta}{V_T} \quad \dot{\gamma}_T = \frac{a_\gamma}{V_T} \quad (94)$$


Natomiast kąt przechylenia platformy aproksymowany jest jako:

$$\phi_T = \arctan\left(\frac{V_T}{g} \dot{\gamma}_T\right) = \arctan\left(\frac{a_\gamma}{g}\right) \quad (95)$$

, gdzie g jest przyspieszeniem grawitacyjnym (m/s^2). Następujące równania kinematyczne opisują ruch środka masy platformy latającej:


$$\dot{x}_T = V_T \cos \theta_T \sin \gamma_T \quad \dot{y}_T = V_T \sin \theta_T \quad \dot{z}_T = V_T \cos \theta_T \cos \gamma_T \quad (96)$$

W badaniach przedstawionych w punkcie 6 pracy proces przetwarzania danych i sygnałów oparty jest o algorytm KAZE w odniesieniu do obrazów w algorytmie korekcyjnym. Algorytm wizualno-bezwładnościowy pracuje w oparciu o model przedstawiony w pracy [42]. Schemat funkcjonowania układu nawigacji rozpatrywanego w niniejszej pracy przedstawia Rys. 5.5.



Rys. 5.5 Schemat funkcjonowania układu nawigacji wizualno-bezwładnościowej oraz korekcyjnej

Algorytm wizyjny KAZE stosowany w pracy bazuje na kilku etapach, które można przedstawić w postaci algorytmu. Schemat funkcjonowania algorytmu wizyjnego KAZE przedstawiono na Rys. 5.6.



Rys. 5.6 Schemat funkcjonowania algorytmu wizyjnego KAZE

6. REALIZACJA BADAŃ

W pierwszym etapie badań dokonano kalibracji kamery. W procesie wykorzystano metodę przedstawioną w [60], zakładającą, że pojedyncza kamera obserwuje nieruchomą płaszczyznę z wzorcem strukturalnym niezmiennym w czasie obserwacji. Obserwacja obejmuje, co najmniej dwa różne kątowe ujęcia wzorca w postaci czarno-białej szachownicy z bokiem pojedynczego pola o długości równej 25 mm. Model wyznaczania parametrów macierzy wewnętrznej kamery opisują równania (52-70) przedstawione w niniejszej pracy.

Na podstawie ww. metody kalibracji wyznaczono parametry kamery przedstawione w Tabeli 6.1.

.

.

Tabela 6.1 Parametry macierzy wewnętrznej kamery w procesie kalibracji


Wyznaczony parametr	Wartość
Zniekształcenia radialne	$k_1 = -0.1047 \pm 0.0027$
	$k_2 = -0.1845 \pm 0.0322$
Zniekształcenia styczne	$p_1 = -0.0009 \pm 0.0002$
	$p_2 = 0.0009 \pm 0.0002$
Współczynnik przekoszenia	$\gamma = 0.1196 \pm 0.0661$
Współrzędne początku układu obrazowego	$c_x = 486.5438 \pm 0.9520$
	$c_y = 307.1183 \pm 0.8248$
Ogniskowe kamery	$f_x = 1056.9043 \pm 1.8189$
	$f_y = 1054.6497 \pm 1.8497$

W związku ze zmianą orientacji kamery w czasie lotu platformy obraz terenu uzyskiwany w systemie nawigacji ulega transformacjom perspektywicznym.

Transformacje te powodują nieliniową zmianę relacji pomiędzy elementami terenu i rzutem tych elementów na płaszczyznę obrazu. Z tego powodu częstym zabiegiem stosowanym w systemach nawigacji wizualnej jest stabilizacja kamery w położeniu zapewniającym prostopadłość osi optycznej kamery względem obrazowanego terenu. Rozwiązanie takie zwiększa znacząco masę układu oraz koszty, zwłaszcza jeżeli wymagana jest szybka i precyzyjna odpowiedź układu stabilizacji. Zaletą takiego układu jest jednak minimalizacja wpływu rozmycia obrazu wynikającego z obrotów platformy.

Dysponując w systemie czujnikiem bezwładnościowym możliwa jest wirtualna stabilizacja zniekształcenia perspektywicznego, której czas realizacji nie jest obciążony inercją związaną z układem elektro-mechanicznym. Stąd realizacja stabilizacji wirtualnej może być znacząco krótsza od tego samego procesu realizowanego metodą sprzętową. Potencjalne błędy związane z interpolacją nowego układu pikseli na bazie obrazu przed stabilizacją wirtualną w odniesieniu do innych czynników determinujących precyzję całości opisywanego w pracy systemu nawigacji nie są znaczące. Przy czym rozpatrywane w pracy zmiany kątów obserwacji terenu nie przekraczają zakresu $\pm \pi/6$ dla osi pochylenia i odchylenia oraz 2π dla osi odchylenia. Uzyskane błędy reprojekcji obrazu uzyskane w trakcie badań i kalibracji kamery potwierdzają wyżej postawione stwierdzenie. Badania polegały na obserwacji nieruchomej płaszczyzny ze znanym wzorcem - zbiorem elementów o znanych wymiarach za pomocą kamery, której rotacja

i translacja ulegała zmianie w kolejnych ujęciach. Wartości kątów pochylenia, przechylenia i odchylenia, a także wartości translacji w globalnym układzie kartezjańskim przedstawiono w Tabeli 6.2 Średnie wartości błędu reprojektacji uzyskane na bazie różnicy położenia ww. elementów płaszczyzny kalibracyjnej oraz ich projekcji uzyskanej na bazie wyznaczonego modelu kamery i obrazu płaszczyzny w kolejnych ujęciach przedstawia Rys. 6.1 Rys. 6.1 Średni błąd reprojektacji uzyskany w procesie kalibracji dla 18 ujęć wzorca. Model wykorzystuje homografię perspektywiczną opisaną w rozdziale 4.1.



Rys. 6.1 Średni błąd reprojektacji uzyskany w procesie kalibracji dla 18 ujęć wzorca

Tabela 6.2 Tabela wartości kątowych oraz położenia kamery w układzie globalnym

Nr próby	ϕ_T (°)	γ_T (°)	θ_T (°)	x (mm)	y (mm)	z (mm)
1	-8,96	-3,24	-89,82	84,09	166,39	809,56
2	1,13	8,04	-86,75	-59,13	93,08	751,09
3	-0,51	0,99	-87,10	-100,76	127,80	700,02
4	-7,35	-1,91	-95,22	-9,05	131,68	786,97
5	-2,32	11,36	-90,33	57,11	76,14	768,21
6	0,80	11,41	-94,90	22,69	147,48	774,94
7	-4,86	7,03	-91,73	108,55	103,23	772,63
8	-3,25	10,54	-90,62	93,53	99,25	770,92
9	-2,32	18,41	-94,56	149,68	68,53	773,62
10	-5,05	12,86	-95,98	128,88	149,87	828,65
11	-8,12	10,53	-97,30	117,39	171,80	826,07

12	8,55	19,29	84,12	183,67	12,51	742,37
13	-25,76	12,93	-92,98	100,25	183,48	721,84
14	-24,01	8,64	-93,71	53,00	192,80	727,37


6.1. BADANIE WPLYWU WYSOKOŚCI OBIEKTÓW TERENOWYCH NA DOKŁADNOŚĆ OKREŚLANIA POŁOŻENIA DLA PŁASKIEGO MODELU TERENU

Zasadniczym celem prowadzonego badania jest określenie wpływu zakłóceń pasywnych w postaci elementów przestrzennych na dokładność określania ich położenia w algorytmie opartym o cechy lokalne i homografię. Elementy przestrzenne o różnej wysokości i położeniu umieszczone są na tle płaskiego terenu (modelu terenu w postaci płaszczyzny). Badanie przeprowadzono w środowisku rzeczywistym oraz symulacyjnym porównując uzyskane wyniki. Z tego względu dodatkowym celem badania jest weryfikacja zasadności stosowania modelu kamery otworkowej do opisu użytego w badaniach urządzenia rzeczywistego oraz poprawności przyjętych w środowisku symulacyjnym założeń.

W badaniu przetwarzano obrazy o rozdzielczości wynoszącej 600x960 pikseli. Wzorcem obrazu w środowisku symulacyjnym jest podstawa prostopadłościanu pokryta strukturami Voronoi [69]. Prostopadłościan, imituje obiekt pokrycia terenowego na tle płaskiego terenu. Struktury Voronoi rozmieszczone są równomiernie na bokach i podstawach prostopadłościanu. Struktury te generowane są losowo, przy uwzględnieniu następujących parametrów w tworzonej populacji struktur:

- powierzchnia struktur jest opisana rozkładem normalnym w przedziale $<0;3000>$ (pix^2),
- badany obraz jest monochromatyczny o normalnym rozkładzie luminancji pomiędzy strukturami,
- struktury posiadają krawędzie składające się z odcinków,
- w trakcie symulowanego zwiększania wysokości prostopadłościanu badanego struktury na prostopadłościanie referencyjnym i badanym są tożsame i nie ulegają zmianie dla danej próby.

Struktury Voronoi stanowią źródło cech obrazowych, które są dopasowywane do tożsamych cech na drugim prostopadłościanie, który jest przesuniętą kopią prostopadłościanu wzorca. Przykładowy obraz poddany testom przedstawia Rys. 6.1.1.



Rys. 6.1.1 Obraz przykładowej lokalizacji prostopadłościanów na płaszczyźnie w prowadzonym badaniu symulacyjnym

Algorytm dopasowania zakłada wykorzystanie metody RANSAC mającej na celu wyznaczenie homograficznej relacji pomiędzy płaszczyznami. Przyjęto następujące parametry metody RANSAC:


- próg dopasowania (po transformacji) = 2.5 (pix),
- poziom ufności 0.99 (-),
- minimalna liczba wykrytych i dopasowanych punktów = 4 (-),
- maksymalna liczba iteracji = 1000 (-).

Symulacja przebiegała w następujący sposób:


- prostopadłościany umieszczano na ustalonej odległości od osi optycznej wynoszącej dla kolejnych prób: 90, 220, 390, 530 pikseli, co odpowiadało odległościom 9, 30, 50, 70 (m) w środowisku rzeczywistym,
- w kolejnych krokach symulacji zwiększano wysokości prostopadłościanu w zakresie $\langle 0; 26 \rangle$ (m),
- kamera rejestruje obrazy dla każdego kroku symulacji,
- po każdej zmianie wysokości prostopadłościanu następuje etap wykrywania i dopasowywania cech obrazowych na górnej podstawie prostopadłościanu do cech na prostopadłościanie z ułożonym środkiem swojej podstawy w punkcie (0,0) układu kartezjańskiego,
- wyznaczana jest transformacja pomiędzy obrazami,
- po zakończeniu próby następuje zmiana położenia prostopadłościanu.

W trakcie symulacji weryfikowano poprawność dopasowania odpowiadających sobie elementów obrazu. Wynik prowadzonego badania symulacyjnego przedstawia Rys. 6.1.2. Zawarte na rysunku charakterystyki opisują zniekształcenie pomiaru przesunięcia obiektu na płaszczyźnie obrazowej kamery w funkcji wysokości tego obiektu. Wykresy reprezentują zbiór funkcji przenoszenia kamery dla obiektów o różnej wysokości oraz o różnej odległości od osi optycznej kamery. W każdym przypadku, dla kamery, która nie zniekształcałaby perspektywy funkcje te miałyby wartość stałą dla dowolnego przesunięcia. Wyznaczona charakterystyka kamery obrazuje wzrost zniekształcenia pomiaru odległości pomiędzy tymi samymi obiektami obserwowanymi na dwóch ujęciach kamery wraz z ze zwiększaniem ich wysokości. Wzrost odległości tych obiektów od osi optycznej powoduje przyrost tego zniekształcenia.

Na Rys. 6.1.3 przedstawiono charakterystykę znormalizowanego współczynnika zniekształcenia pomiaru przemieszczenia obiektów dla różnej ich wysokości. Normalizacja wykonana jest względem odległości początkowej dla danej próby. Wynik normalizacji pokazuje, że możliwe jest uogólnienie modelem nieliniowym wpływu wysokości na dokładność pomiaru przemieszczenia obiektów przy założeniu modelu terenu w postaci płaszczyzny. Wykres na Rys. 6.1.3 należy także interpretować w kontekście prędkości obserwowanych cech na płaszczyźnie obrazowej w trakcie ruchu kamery nad terenem. Jeżeli cechy te odpowiadają obiektom o różnej wysokości to nawet w przypadku statyki tych obiektów cechy będą miały różną prędkość przemieszczania się po obrazie rejestrowanym przez kamerę. Obiekty wyższe będą miały większą prędkość niż obiekty niższe.



Rys. 6.1.2 Charakterystyki zniekształcenia pomiaru przemieszczenia w funkcji wysokości obserwowanego obiektu dla modelu transformacji perspektywicznej




Rys. 6.1.3 Charakterystyka znormalizowanego współczynnika zniekształcenia pomiaru przemieszczenia dla różnej wysokości obiektów terenowych

Charakterystykę przedstawioną na Rys. 6.1.3 uzyskano w wyniku aproksymacji metodą najmniejszych kwadratów znormalizowanych punktów uzyskanych wcześniej w badaniu. Do aproksymacji użyto wielomianu drugiego stopnia. Otrzymano następującą postać funkcji:

$$f(x) \cong 0,001x^2 + 0,015x + 1. \quad (97)$$

W kolejnym etapie przeprowadzone badanie symulacyjne powtórzono w warunkach rzeczywistych z wykorzystaniem układu wizyjnego umieszczonego na platformie latającej. Wykorzystana kamera odpowiadała modelowi w środowisku symulacyjnym, a jej parametry w postaci macierzy wewnętrznej były znane. W badaniach wybrano obiekty terenowe o znanej wysokości. Na Rys. 6.1.4 przedstawiono wynik badania w postaci nałożonych na siebie dwóch kolejnych ujęć z kamery platformy latającej dopasowanych do siebie z wykorzystaniem cech lokalnych odpowiadających terenowi wokół obiektu. W ten sposób możliwe jest pokazanie zjawiska przebadanego symulacyjnie w odniesieniu do rzeczywistych obiektów i kamery. Na rysunku widać, że odległość pomiędzy cechami opowiadającymi podstawie obiektu jest inna niż odległość pomiędzy cechami odpowiadającymi górnej części obiektu. Obiekt o wysokości względnej wynoszącej 10,5 m w rzeczywistości ustawiony był pionowo w terenie płaskim. Wysokość kamery nie ulegała zmianie, oś optyczna była skierowana wzdłuż wektora przyspieszenia ziemskiego.



Rys. 6.1.4 Zestawienie kolejnych ramek z kamery układu wizyjnego z zaznaczonym pomiarem odległości pomiędzy odpowiadającymi sobie elementami obrazu

Błąd względny pomiaru odległości pomiędzy odpowiadającymi sobie punktami terenowymi podstawy i części górnej obiektu terenowego wyniósł:

$$\frac{30,65 - 26,53}{26,53} \cong 0,16 \quad (98)$$

Wartość wyrażenia (98) odniesiona do charakterystyki przedstawionej na Rys. 6.1.3 jest równoważna do współczynnika przemieszczenia znormalizowanego o wartości 1,16. Potwierdza to zgodność badań symulacyjnych i rzeczywistych w zakresie wyznaczania wpływu wysokości obiektów terenowych na dokładność pomiaru odległości pomiędzy obiektami uzyskiwanego na podstawie danych obrazowych z wykorzystaniem transformacji homograficznej.

Podsumowanie podrozdziału:

Wyznaczenie charakterystyki przedstawionej na Rys. 6.1.3 pozwala na opracowanie metody filtracji cech odpowiadających obiektom o wysokości przekraczającej zakładany próg. Dzięki temu możliwe jest zwiększenie dokładności określania położenia platformy latającej przy wykorzystaniu modelu transformacji homograficznej. Realizacja tego stwierdzenia jest możliwa przy następujących założeniach:


- obraz przedstawia płaszczyznę równoległą do stycznej do elipsoidy WGS84 obserwowaną z określonej wysokości nad terenem,
- odległość ww. płaszczyzn jest równa wysokości terenowej,
- sumaryczna powierzchnia obiektów terenowych o niezerowej wysokości nie jest większa od powierzchni terenu o zerowej wysokości,
- w płaskim terenie występuje dostateczna ilość (min. 4) cech pozwalających na wyznaczenie transformacji,
- obraz podlega korekcie zniekształceń z wykorzystaniem macierzy wewnętrznej kamery,
- znana jest wysokość umiejscowienia kamery nad terenem.

Proponowany filtr ma za zadanie odrzucenie obiektów, których prędkość przemieszczania się na kolejnych obrazach jest większa od prędkości wynikającej z ruchu platformy lecącej nad terenem powiększonej o określony próg. Wyznaczona funkcja (97) aproksymująca ww. charakterystykę pozwala na prowadzenie warunkowej analizy przestrzennej cech na obrazach.

6.2. BADANIE ODPORNOŚCI METOD NAWIGACJI WIZUALNO-BEZWŁADNOŚCIOWYCH NA ZAKŁÓCENIA PASYWNE


W pracy [42] przedstawiono charakterystyki błędu średniokwadratowego określania położenia przez platformę latającą wyposażoną w układ wizualno-bezwładnościowy. W pracy tej wykorzystano zarejestrowane dane pomiarowe w trakcie lotu niezależnego od układu nawigacji. Następnie metodami przetwarzania poza układem platformy w oparciu o grupę filtrów Kalmana estymowano stan parametrów nawigacyjnych w odniesieniu do zarejestrowanego przelotu. Zarejestrowane dane pomiarowe obejmowały dane referencyjne określające rzeczywiste parametry lotu platformy, a także parametry uzyskane w wyniku kalibracji czujników. Wykorzystany zbiór danych został opublikowany przez [70] i jest dostępny publicznie [71].

Fragment wyników uzyskanych przez autorów pracy [42] przedstawiono na Rys. 6.2.1. Rysunek ten prezentuje przyrost błędów określania położenia dla grupy algorytmów Kalmana tj. R-UKF-LG, I-UKF-LG, SE(3)-UKF, UKF oraz IEKF. Algorytmy szerzej opisane są w oryginalnej pracy. Przedstawiony rysunek stanowi referencję do badania odporności ww. algorytmów na zakłócenia w postaci ruchomych obiektów nakładanych na obraz oryginalny. Obiekty te mają postać grup pikseli w układzie krzyżowym i poruszają się po płaszczyźnie obrazowej ze stałą prędkością, przemieszczając się w lewo o 5 pikseli na każdym ujęciu. Zaproponowane zakłócenia pasywne odzwierciedlają zachowanie rzeczywistych obiektów poruszających się w przestrzeni pomiędzy kamerą a stałymi elementami terenu.




Rys. 6.2.1 Fragment charakterystyki błędu średniokwadratowego określania położenia przedstawionej w pracy [42]

W trakcie przeprowadzonego badania dowiedziano się do założeń przyjętych przez autora pracy [42]. Zakłada się zerową wartość błędu określania położenia na początku badania oraz przypisanie znanej początkowej lokalizacji rzeczywistej do współrzędnych obrazowych dla trzydziestu cech charakterystycznych algorytmu śledzącego. Obraz obarczony ww. zakłóceniami przedstawia Rys. 6.2.2. Na rysunku tym widać zarówno zakłócenia, oznaczone na czarno, jak i śledzone w danym momencie elementy obrazu, których lokalizacja prezentowana jest kolorem zielonym.




Rys. 6.2.2 Ujęcie obrazu z zaznaczonymi na zielono śledzonymi elementami obrazu oraz zakłóceniami w kolorze czarnym.

Na skutek zakłócenia błąd średniokwadratowy wszystkich rozpatrywanych algorytmów uległ zwiększeniu, co przedstawiono na Rys. 6.2.3. Przyrost błędu jest nierównomierny i różny dla rozpatrywanych algorytmów. Charakter przyrostu wynika z różnic w strukturze algorytmów oraz z konieczności aktualizacji zbioru 30 śledzonych cech na każdym ujęciu z kamery w trakcie jej ruchu.



Rys. 6.2.3 Charakterystyka błędu średniokwadratowego określanego położenia po zastosowaniu zakłóceń

Dlatego na Rys. 6.2.4 przedstawiono procentowy przyrost błędów odniesiony do danych oryginalnych. Dodatkowo w Tabeli 6.2. zaprezentowano wartości średnie ww. błędów.



Rys. 6.2.4 Procentowy przyrost błędu średniokwadratowego określanego położenia po zastosowaniu zakłóceń

Tabela 6.2. Wartość średnia charakterystyk przedstawionych na Rys. 6.2.4

Rodzaj algorytmu	R-UKF-LG	L-UKF-LG	SE(3)-UKF	UKF	IEKF
Wartość średnia (%)	4,47	4,40	3,16	3,66	4,52

Przedstawione wyniki potwierdzają podatność analizowanych algorytmów na zakłócenia pasywne w postaci ruchomych obiektów na obrazach. Ruch tych obiektów jest niezależny od obserwatora. Badanie symulowane oddaje charakter możliwych do wystąpienia w rzeczywistości zjawisk. Zakłóceniami pasywnymi tego typu są m.in. poruszające się samochody, zwierzęta, ludzie. W takich sytuacjach układy nawigacji wizualno-bezwładnościowej będą charakteryzowały się ograniczoną dokładnością określania położenia obserwatora, a tym samym także nawigacji. Dlatego w pracy podjęto próbę zaproponowania algorytmu zmniejszenia wpływu tego rodzaju zakłóceń przy założeniu dysponowania wysokościomierzem laserowym.

Urządzenie to w odróżnieniu do lidarów czy radarów z syntetyczną aperturą nie generuje skupionej grupy punktów odpowiadających detekcjom przeszkód, a pojedynczymi pomiarami, które nie pozwalają na uzyskanie dostatecznej precyzji odwzorowania całości obserwowanego terenu. Pomimo tego taki szczątkowy pomiar umożliwia pozyskanie informacji o wysokości lotu nad średnim poziomem terenu. Będzie to możliwe dla terenów o niewielkim zróżnicowaniu wysokości, gdzie występują pojedyncze elementy pokrycia terenowego wyraźnie dominujące nad terenem. Dodatkowo zakłada się, że wysokościomierz wraz z platformą nosiciela tworzy bryłę sztywną, wysokościomierz zlokalizowany jest w początku układu współrzędnych platformy. Orientacja wysokościomierza jest zgodna z orientacją platformy i kamery. Osie optyczne kamery i wysokościomierza są równoległe.

Uwzględniając powyższe założenia pomiar odległości wysokościomierzem zamontowanym na platformie można opisać modelem określania współrzędnych, który bazuje na modelach stosowanych w zagadnieniach radiolokacyjnych. Proponuje się autorski model rozszerzonego filtra Kalmana, w którym dodatkowo zaimplementowano dystans Mahalanobisa do odrzucania pomiarów odstających. Zastosowanie tego filtra podyktowane jest nieliniowymi zależnościami pomiędzy pomiarem z wysokościomierza, a kartezjańskim układem odniesienia, w którym dostępne są estymowane dane nawigacyjne.

Mierzona odległość do terenu r może być opisana w relacji do układu kartezjańskiego jako:

$$r = \sqrt{x^2 + y^2 + z^2} \quad (99)$$

Kąty pochylenia i przechylenia mierzone przez układ bezwładnościowy w tym modelu to:

$$\gamma_T = \tan^{-1} \frac{y}{x} \quad (100)$$

$$\phi_T = \tan^{-1} \frac{z}{\sqrt{x^2 + y^2}} \quad (101)$$

Zależności pomiędzy współrzędnymi kartezjańskimi i sferycznymi określone są jako:

$$x = r \cos \gamma_T \cos \phi_T \quad (102)$$

$$y = r \sin \gamma_T \cos \phi_T \quad (103)$$

$$z = r \sin \phi_T \quad (104)$$

Wektor stanu dynamiki obserwowanych punktów określono następująco:

$$\mathbf{x}_n = [x \ \dot{x} \ \ddot{x} \ y \ \dot{y} \ \ddot{y} \ z \ \dot{z} \ \ddot{z}]^T. \quad (105)$$

Ekstrapolacja wektora następuje poprzez:

$$\hat{\mathbf{x}}_{n+1,n} = \mathbf{F} \hat{\mathbf{x}}_n \quad (106)$$

W zapisie macierzowym z uwzględnieniem modelu dynamiki opartego o stałe przyspieszenie równanie to ma postać:

$$\begin{bmatrix} \hat{x}_{n+1,n} \\ \hat{\dot{x}}_{n+1,n} \\ \hat{\ddot{x}}_{n+1,n} \\ \hat{y}_{n+1,n} \\ \hat{\dot{y}}_{n+1,n} \\ \hat{\ddot{y}}_{n+1,n} \\ \hat{z}_{n+1,n} \\ \hat{\dot{z}}_{n+1,n} \\ \hat{\ddot{z}}_{n+1,n} \end{bmatrix} = \begin{bmatrix} 1 & \Delta t & 0.5\Delta t^2 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & 0.5\Delta t^2 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & \Delta t & 0.5\Delta t^2 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_{n,n} \\ \dot{x}_{n,n} \\ \ddot{x}_{n,n} \\ y_{n,n} \\ \dot{y}_{n,n} \\ \ddot{y}_{n,n} \\ z_{n,n} \\ \dot{z}_{n,n} \\ \ddot{z}_{n,n} \end{bmatrix} \quad (107)$$

Z powodu nieliniowej relacji pomiędzy pomiarem a wektorem stanu, wektor pomiaru dla rozszerzonego filtra Kalmana wyraża się za pomocą funkcji obserwacji $\mathbf{z} = \mathbf{h}(\hat{\mathbf{x}})$. Jakobian tej funkcji ma postać:

$$\frac{\partial \mathbf{h}(\hat{\mathbf{x}})}{\partial \mathbf{x}} = \begin{bmatrix} \frac{\partial h_1}{\partial x_1} & \cdots & \frac{\partial h_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_m}{\partial x_1} & \cdots & \frac{\partial h_m}{\partial x_n} \end{bmatrix} =$$

$$= \begin{bmatrix} \frac{\partial (\sqrt{x^2 + y^2 + z^2})}{\partial x} & 0 & 0 & \frac{\partial (\sqrt{x^2 + y^2 + z^2})}{\partial y} & 0 & 0 & \frac{\partial (\sqrt{x^2 + y^2 + z^2})}{\partial z} & 0 & 0 \\ \frac{\partial (\tan^{-1} \frac{y}{x})}{\partial x} & 0 & 0 & \frac{\partial (\tan^{-1} \frac{y}{x})}{\partial y} & 0 & 0 & \frac{\partial (\tan^{-1} \frac{y}{x})}{\partial z} & 0 & 0 \\ \frac{\partial (\tan^{-1} \frac{z}{\sqrt{x^2 + y^2}})}{\partial x} & 0 & 0 & \frac{\partial (\tan^{-1} \frac{z}{\sqrt{x^2 + y^2}})}{\partial y} & 0 & 0 & \frac{\partial (\tan^{-1} \frac{z}{\sqrt{x^2 + y^2}})}{\partial z} & 0 & 0 \end{bmatrix} \quad (108)$$

$$= \begin{bmatrix} \frac{x}{\sqrt{x^2 + y^2 + z^2}} & 0 & 0 & \frac{y}{\sqrt{x^2 + y^2 + z^2}} & 0 & 0 & \frac{z}{\sqrt{x^2 + y^2 + z^2}} & 0 & 0 \\ -\frac{y}{x^2 + y^2} & 0 & 0 & \frac{x}{x^2 + y^2} & 0 & 0 & 0 & 0 & 0 \\ -\frac{zx}{(x^2 + y^2 + z^2)\sqrt{x^2 + y^2}} & 0 & 0 & -\frac{zy}{(x^2 + y^2 + z^2)\sqrt{x^2 + y^2}} & 0 & 0 & \frac{\sqrt{x^2 + y^2}}{x^2 + y^2 + z^2} & 0 & 0 \end{bmatrix}$$

Dla modelu ekstrapolacji stanu układu zakłada się stałe przyspieszenie obiektu obserwacji pomiędzy kolejnymi uaktualnieniami w algorytmie Kalmana. Macierz kowariancji szumu procesu odnosi się również do wariancji położenia i prędkości, które są funkcjami wariancji przyspieszenia. Wariancja prędkości może być wyrażona jako:

$$V(\dot{x}) = \Delta t^2 \sigma_a^2 \quad (109)$$

Wariancja prędkości może być wyrażona w funkcji wariancji przyspieszenia jako:

$$V(x) = \frac{\Delta t^4}{4} \sigma_a^2 \quad (110)$$

Macierz kowariancji **Q** jest wówczas określona jako:

$$\mathbf{Q} = \begin{bmatrix} \frac{\Delta t^4}{4} & \frac{\Delta t^3}{2} & \frac{\Delta t^2}{2} & 0 & 0 & 0 & 0 & 0 & 0 \\ \frac{\Delta t^3}{2} & \Delta t^2 & \Delta t & 0 & 0 & 0 & 0 & 0 & 0 \\ \frac{\Delta t^2}{2} & \Delta t & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{\Delta t^4}{4} & \frac{\Delta t^3}{2} & \frac{\Delta t^2}{2} & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{\Delta t^3}{2} & \Delta t^2 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 0 & \frac{\Delta t^2}{2} & \Delta t & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & \frac{\Delta t^4}{4} & \frac{\Delta t^3}{2} & \frac{\Delta t^2}{2} \\ 0 & 0 & 0 & 0 & 0 & 0 & \frac{\Delta t^3}{2} & \Delta t^2 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 0 & \frac{\Delta t^2}{2} & \Delta t & 1 \end{bmatrix} \sigma_a^2 \quad (111)$$

Macierz kowariancji **P** jest określona jako:

$$\mathbf{P} = \begin{bmatrix} p_x & p_{x\dot{x}} & p_{x\ddot{x}} & 0 & 0 & 0 & 0 & 0 & 0 \\ p_{x\dot{x}} & p_{\dot{x}} & p_{\ddot{x}} & 0 & 0 & 0 & 0 & 0 & 0 \\ p_{x\ddot{x}} & p_{\ddot{x}} & p_{\ddot{x}} & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & p_y & p_{y\dot{y}} & p_{y\ddot{y}} & 0 & 0 & 0 \\ 0 & 0 & 0 & p_{y\dot{y}} & p_{\dot{y}} & p_{\ddot{y}} & 0 & 0 & 0 \\ 0 & 0 & 0 & p_{y\ddot{y}} & p_{\ddot{y}} & p_{\ddot{y}} & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & p_z & p_{z\dot{z}} & p_{z\ddot{z}} \\ 0 & 0 & 0 & 0 & 0 & 0 & p_{z\dot{z}} & p_{\dot{z}} & p_{\ddot{z}} \\ 0 & 0 & 0 & 0 & 0 & 0 & p_{z\ddot{z}} & p_{\ddot{z}} & p_{\ddot{z}} \end{bmatrix} \quad (112)$$

Zakłada się następującą, początkową postać macierzy $\mathbf{P}$:

$$\mathbf{P}_{0,0} = \mathbf{10} \mathbf{I}_{9 \times 9} \quad (113)$$

Równanie ekstrapolacji macierzy kowariancji $\mathbf{P}$ ma postać:

$$\mathbf{P}_{n+1,n} = \mathbf{F} \mathbf{P}_{n,n} \mathbf{F}^T + \mathbf{Q} \quad (114)$$

Macierz niepewności pomiarów określa się następująco:

$$\mathbf{R}_n = \begin{bmatrix} \sigma_r^2 & 0 & 0 \\ 0 & \sigma_{\gamma_T}^2 & 0 \\ 0 & 0 & \sigma_{\phi_T}^2 \end{bmatrix} \quad (115)$$

Niepewność pomiaru odległości wysokościomierza wykorzystanego w pracy opisuje $\sigma_r = 0.3$ (m). Niepewności kątowe są zmienne w czasie i opisywane są poprzez funkcje wyznaczone w pracy [42]. Początkowe wartości wynikają z danych katalogowych wykorzystywanego układu giroskopu, w pracy przyjęto: $\sigma_{\gamma_T}^2 = \sigma_{\phi_T}^2 = 200(1.6968e - 4)^2$.

Wzmocnienie filtra, aktualizacja stanu i kowariancji wyznaczane są z zależności:

$$\mathbf{K}_n = \mathbf{P}_{n,n-1} \frac{\partial \mathbf{h}^T}{\partial \mathbf{x}} \left(\frac{\partial \mathbf{h}}{\partial \mathbf{x}} \mathbf{P}_{n,n-1} \frac{\partial \mathbf{h}^T}{\partial \mathbf{x}} + \mathbf{R}_n \right)^{-1} \quad (116)$$

$$\hat{\mathbf{x}}_{n,n} = \hat{\mathbf{x}}_{n,n-1} + \mathbf{K}_n (\mathbf{z}_n - \mathbf{h}(\hat{\mathbf{x}}_{n,n-1})) \quad (117)$$

$$\mathbf{P}_{n,n} = \left(\mathbf{I} - \mathbf{K}_n \frac{\partial \mathbf{h}}{\partial \mathbf{x}} \right) \mathbf{P}_{n,n-1} \left(\mathbf{I} - \mathbf{K}_n \frac{\partial \mathbf{h}}{\partial \mathbf{x}} \right)^T + \mathbf{K}_n \mathbf{R}_n \mathbf{K}_n^T \quad (118)$$

Ze względu na możliwość pomiaru odległości do obiektów stanowiących pokrycie terenowe, których wysokość znacząco odbiega od średniej wysokości terenu zdecydowano się na zastosowanie mechanizmu odrzucania takich cech. Obiektami rozpatrywanymi jako zakłócenia pasywnymi, które należy odfiltrować będą np. budynki, drzewa, wiadukty.

Odrzucanie pomiarów odbiegających od modelu terenu płaskiego realizowane jest z wykorzystaniem dystansu Mahalanobis-a, który ma postać:

$$d_M = \sqrt{(\mathbf{h}(\hat{\mathbf{x}}_{n,n-1}) - \mathbf{z}_n)^T \mathbf{P}_{n,n-1}^{-1} (\mathbf{h}(\hat{\mathbf{x}}_{n,n-1}) - \mathbf{z}_n)} \quad (119)$$

Wyjściem prezentowanego filtra będzie zbiór współrzędnych kartezjańskich punktów pomiarowych terenu obserwowanych w układzie wysokościomierza, który w pracy jest rozpatrywany jako tożsamy z układem IMU oraz całej platformy. Przeniesienie wyników pomiarów do układu związanego z terenem w układzie NED wymaga transformacji, która została opisana w rozdziale 4.2. W związku z ruchem platformy punkty zostaną rozciągnięte wzdłuż rzutu trajektorii platformy na płaszczyznę NED.

W kolejnym kroku na podstawie zbioru punktów wyznaczana jest lokalna płaszczyzna będąca modelem terenu bez elementów pokrycia.

Model ten wraz z płaszczyzną uzyskaną jako model terenu przy wykorzystaniu algorytmu wizyjnego stanowi podstawę algorytmu wyznaczenia nowej uśrednionej płaszczyzny, której punkty będą posiadały minimalną sumaryczną odległość od obu płaszczyzn.

Wyjście filtra Kalmana dla wysokościomierza połączono z pomiarem uzyskanym z układu wizualno-bezwładnościowego z wykorzystaniem estymatora MLE. Znając wartości pomiarów wysokości z układu bezwładnościowego z_{IMU} oraz wysokościomierza z_{DAL} , a także ich niepewności pomiarowe, przy założeniu gaussowskiego rozkładu błędów, tj. $p(z_{IMU}|z) \sim \mathcal{N}(z, \sigma_{IMU}^2)$, $p(z_{DAL}|z) \sim \mathcal{N}(z, \sigma_{DAL}^2)$ możliwe jest uzyskanie wartości estymowanej wysokości z zależności:

$$\hat{z}_{MLE} = \frac{\sigma_{IMU}^{-2} z_{IMU} + \sigma_{DAL}^{-2} z_{DAL}}{\sigma_{IMU}^{-2} + \sigma_{DAL}^{-2}} \quad (120)$$

Zakłada się, że pomiar z_{DAL} uzyskiwany jest wielokrotnie w czasie pomiędzy rejestracją dwóch kolejnych ujęć z kamery, które podlegają dopasowaniu. W modelu pomiaru wysokości z wykorzystaniem wysokościomierza zastosowano mechanizm odrzucania pomiarów odległości do obiektów punktowych, których wysokość odbiega od estymaty uwzględniającej historię pomiarów, stąd w przypadku pomiaru odległości od płaskiego obiektu terenowego o wymiarach zbliżonych do połowy obszaru terenowego będącego obiektem projekcji do kadru kamery, np. dużej hali magazynowej, wartość średnia oszacowania wysokości przyjmuje wartość zbliżoną do wysokości terenowej tego obiektu. Spowoduje to w konsekwencji rozbieżność pomiędzy pomiarami wysokości w układach bezwładnościowym oraz wysokościomierza. W tym przypadku łączenie danych nie będzie wykonywane, a przetwarzana będzie tylko wartość estymaty wysokości z algorytmu wysokościomierza. W ten sposób obiekt o dużej płaskiej powierzchni zostanie uwzględniony jako odniesienie w układzie przetwarzania obrazu. Wyznaczona głębina obrazu po rzutowaniu kadru na płaszczyznę wirtualną równoległą do obserwowanego terenu pozwoli na filtrację wykrywanych

cech o parametrach kinematycznych odbiegających od modelu stosowanego w układzie wizyjnym.

Pomiary współrzędnych x_{DAL} i y_{DAL} po analogicznym uzupełnieniu współrzędnymi z układu bezwładnościowego pozwalają na wyznaczenie na podstawie wielu pomiarów płaszczyzny terenowej $\mathcal{M}$ metodą najmniejszych kwadratów. W przypadku współliniowości punktów zakłada się, że wszystkie punkty płaszczyzny mają średnią wartość współrzędnej z , a wysokość terenowa stanowi wektor normalny płaszczyzny.

Dysponując pomiarem punktów $\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)} \in \mathbb{R}^3$ tworzymy następujący układ równań liniowych:

$$\begin{cases} v_1 x^{(1)} + v_2 y^{(1)} + v_3 z^{(N)} + v_4 = 0 \\ \vdots \\ v_1 x^{(N)} + v_2 y^{(N)} + v_3 z^{(N)} + v_4 = 0 \end{cases} \quad (121)$$

Układ ten w zapisie macierzowym ma postać:

$$\begin{bmatrix} (\mathbf{x}^{(1)})^T & 1 \\ \vdots & \vdots \\ (\mathbf{x}^{(N)})^T & 1 \end{bmatrix} \mathbf{v} = \mathbf{A} \mathbf{v} = 0 \quad (122)$$

Aby opisać płaszczyznę z wykorzystaniem punktów, które nie są współpłaszczyznowe konieczna jest aproksymacja. W tym celu minimalizuje się zbiór parametrów wektora $\mathbf{v}^*$:

$$\mathbf{v}^* = \operatorname{argmin}_{\mathbf{v} \in \mathbb{R}^4, \|\mathbf{v}\|=1} \|\mathbf{A} \mathbf{v}\|^2 \quad (123)$$

Płaszczyznę definiuje się jako:

$$\mathcal{M}(\mathbf{v}) \stackrel{\text{def}}{=} \{\mathbf{x} \in \mathbb{R}^3 : [\mathbf{x}^T \ 1] \mathbf{v} = 0\}$$

Błąd aproksymacji określa się jako odległość punktu $\mathbf{x}$ należącego do rozpatrywanego zbioru od płaszczyzny $\mathcal{M}(\mathbf{v})$. Wartość błędu dla każdego rozpatrywanego punktu wyznacza się metodą Lagrange'a na podstawie zależności:

$$e = \operatorname{argmin}_{\mathbf{x}' \in \mathcal{M}(\mathbf{v})} \|\mathbf{x} - \mathbf{x}'\|^2. \quad (124)$$

W postaci macierzowej kwadrat błędu określa się z zależności:

$$e(\mathbf{x}, \mathcal{M}(\mathbf{v}))^2 = \frac{([\mathbf{x}^T \ 1] \mathbf{v})^2}{\|\mathbf{v}_{1:3}\|^2} \quad (125)$$

Jeżeli wszystkie rozpatrywane punkty mają zostać dopasowane do płaszczyzny to parametry wektora $\mathbf{v}$ można wyznaczyć z wykorzystaniem metody dekompozycji macierzy na składowe główne określanej skrótem SVD (ang. *singular value decomposition*).

Po wyznaczeniu opisywanej płaszczyzny możliwe jest na etapie śledzenia cech rzutowanie obrazu kamery na powierzchnię wirtualnej płaszczyzny obserwacji, która jest równoległa do

wyznaczonej płaszczyzny i posiada arbitralnie ustaloną wysokość w układzie globalnym. Dzięki temu, nawet jeżeli płaszczyzna może tylko w ograniczonym zakresie przybliżać powierzchnię Ziemi to dzięki wyznaczonej charakterystyce zniekształcania opisanej zależnością (97) możliwe jest ustalenie progu odrzucania cech, które na wyznaczonej wirtualnej płaszczyźnie poruszają się szybciej, niż te których prędkość jest liniowo powiązana z rzutem prędkości platformy na płaszczyznę układu terenowego NED. Rzutowanie oparte może być o grupę rotacji $SO(3)$ i parametr skali uzyskany na podstawie wyznaczonej wysokości lotu.


Przedstawioną metodę zastosowano na danych pomiarowych rozpatrywanych w pracy [42] z poszerzeniem danych o zbiór losowych, symulowanych pomiarów do płaszczyzny podłogi pomieszczenia, których odchylenie standardowe ustalono na wartość 0.3 m. Wartość rzeczywista została wyznaczona na podstawie danych kalibracyjnych zawartych w zbiorze referencyjnym.

Na Rys. 6.2.5 przedstawiono wynik rzutowania obrazu z kamery na wyznaczoną płaszczyznę wirtualną, równoległą do podłogi pomieszczenia. Odległość wzajemna cech na obrazie uległa zmianie, jednak cechy przypisane elementom podłogi reprezentują relacje w wymiarach odpowiadające relacjom na rzeczywistej płaszczyźnie podłogi. Dzięki temu na etapie wykrywania i śledzenia cech możliwa jest filtracja środkowoprzepustowa, w której pasmo filtra wynika z parametrów ruchu platformy w osiach OX i OY układu inercjalnego.




Rys. 6.2.5 Efekt rzutowania obrazu kamery na płaszczyznę równoległą do podłogi pomieszczenia

Efekt filtracji cech widoczny jest na Rys. 6.2.6, gdzie na zielono oznaczono śledzone cechy. Na przedstawionym ujęciu wszystkie śledzone cechy znajdują się na podłodze pomieszczenia.



Rys. 6.2.6 Efekt filtracji wykrywanych i śledzonych cech obrazowych

Ideę autorskiego procesu filtracji wykrytych cech obrazowych w zakresie kwalifikowania ich do śledzenia przedstawia Rys. 6.2.7. Wartości przesunięć oraz kątów obliczonych po rzutowaniu wykrytych i dopasowanych cech z dwóch kolejnych ujęć kamery na ww. płaszczyznę przedstawia Tabela 6.2.1.



Rys. 6.2.7 Dopasowanie cech z dwóch kolejnych obrazów po ich rzutowaniu na płaszczyznę równoległą do połoogi pomieszczenia


Tabela 6.2.1 Tabela wartości przesunięć i kątów dla dopasowanych cech obrazowych po ich rzutowaniu na płaszczyznę równoległą do połogi pomieszczenia

Nr / opis	1	2	3	Punkty połączone żółtymi odcinkami
Przesunięcie (pix)	123	170	182	200±2
Orientacja (°)	3,8	7,1	21	19,5±0,2

Istotne na rzutowanym i dopasowywanym obrazie jest to, że odległości pomiędzy cechami zakłóceń (punkty połączone niebieskimi odcinkami) oraz ich orientacje różnią się od odległości i orientacji wyznaczonych dla puli cech dopasowanych, które są rozlokowane na płaszczyźnie podłogi (punkty połączone żółtymi odcinkami). Różnice te są znacząco większe od odchyłeń standardowych odległości i kątów orientacji wyznaczonych dla puli cech związanych z podłogą. Dzięki temu możliwe jest odrzucanie cech związanych z zakłóceniami pasywnymi. Na takiej samej zasadzie możliwe jest odrzucanie cech związanych z obiektami statycznymi nienależącymi do ww. płaszczyzny.

Wprowadzona modyfikacja odnosi się do etapu transformacji, opisanej równaniem (41), cech pomiędzy układami omówionymi w rozdziale 4.2 i uwzględnia znajomość parametru skalującego λ .

Po wprowadzeniu omówionej korekty zbadano ponownie dokładność wyznaczania położenia w rozpatrywanym algorytmie, a wyniki przedstawiono na Rys. 6.2.8. Na czterech z pięciu charakterystyk zmniejszono popełniany błąd średniokwadratowy. Charakterystyka przedstawiająca błędy algorytmu UKF posiada największą wariancję w badaniu, zarówno przed modyfikacją, jak i po niej, co jest potencjalną przyczyną braku pozytywnych rezultatów.



Rys. 6.2.8 Procentowy przyrost błędu średniokwadratowego określanego położenia po zastosowaniu filtracji

Tabela 6.2.2 Wartość średnia charakterystyk przedstawionych na Rys. 6.2.8

Rodzaj algorytmu	R-UKF-LG	L-UKF-LG	SE(3)-UKF	UKF	IEKF
Wartość średnia (%)	-4,24	-4,48	0,59	3,36	-4,26

Podsumowanie podrozdziału:

W przedstawionym badaniu wykazano podatność algorytmów nawigacji wizualno-bezwładnościowej na zakłócenia pasywne w postaci przemieszczających się po płaszczyźnie obrazu dodatkowych grup pikseli. W związku z wykazaną podatnością sformułowano zależności na rozszerzony filtr Kalmana, który umożliwia estymację współrzędnych kartezjańskich, które po fuzji z danymi bezwładnościowymi pozwalają opisać płaszczyznę terenu i wyznaczyć wirtualną płaszczyznę równoległą do płaszczyzny terenowej. Dzięki temu możliwa jest filtracja cech w odniesieniu do ich prędkości na nowej płaszczyźnie, co ogranicza wpływ wprowadzonych zakłóceń.

6.3. BADANIE WPLYWU RUCHU PLATFORMY LATAJĄCEJ ORAZ PARAMETRÓW FILTRACJI WIENERA NA DOKŁADNOŚĆ OKREŚLANIA POŁOŻENIA

Wysokość lotu rakiet manewrujących mieści się zazwyczaj w zakresie 50-150 m. Rozpatrując pracę wizyjnego układu nawigacyjnego platformy latającej w tym zakresie wysokości (przy niezmiennych w trakcie badań pozostałych parametrach akwizycji) należy stwierdzić, że powierzchnia podlegająca obrazowaniu ulega zmianie wraz z wysokością przelotu. Ze względu na dominujący ruch postępowy rakiet manewrujących, orientację kamery dobiera się w taki sposób, aby dłuższa krawędź rejestrowanego obrazu była równoległa do składowej wektora ww. ruchu postępowego. Wówczas długość tej krawędzi odpowiada rzutowi odległości terenowej możliwej do uchwycenia w kadrze kamery. Zmiany tej odległości w funkcji wysokości lotu prezentuje Rys. 6.3.1. Na rysunku przedstawiono obraz uzyskany w trakcie badań platformy z kamerą (realizowanych w prezentowanym fragmencie na wysokości 69 m) przeprowadzonych w dniu 29.10.2021 r., przy konfiguracji oryginalnej oraz w konfiguracji lotu na wysokościach 100 i 150 m.

Dla użytych w badaniu obrazów o rozdzielczości wynoszącej 960x600 pikseli oraz wysokości lotu równej 150 m pojedynczy piksel obrazu odpowiada odległości w terenie równej 0,1299197916666 m. Zakładając, że platforma latająca porusza się z prędkością rakiet manewrujących wynoszącą 200 m/s odległość przebyta w czasie akwizycji obrazu wyniesie:

$$d = 200T_e, \quad (126)$$

gdzie T_e jest czasem ekspozycji matrycy kamery.


W modelu rozmycia obrazu wykorzystanym w pracy założono, że cała matryca kamery układu akwizycji poddawana jest ekspozycji w tym samym czasie określonym jako T_e . Zgodność modelu z rzeczywistością w tym zakresie spełniona jest tylko dla kamer z migawką globalną. Taki rodzaj kamery wykorzystano w trakcie badań rzeczywistych. Wybrana kamera gwarantowała również programową kontrolę parametrów sprzętowych. Jednym z ustalanych parametrów jest czas otwarcia migawki określającego jak długo trwa ekspozycja matrycy. Pozostałe ustalone parametry to: brak automatycznej regulacji kontrastu, ustalona rozdzielczość obrazu wyjściowego, sprzętowo-programowe wyzwalanie akwizycji obrazu.

W trakcie badań rzeczywistych, ustalając czas ekspozycji matrycy, z jednej strony dążono do minimalizacji wspomnianego w rozdziale 4 efektu rozmycia obrazu, a z drugiej strony do zagwarantowania możliwie maksymalnej energii dostarczanej matrycy podczas akwizycji. Oba te wymagania są przeciwstawne. W pracy ustalono czas ekspozycji matrycy na wartość wynoszącą 1 ms.

Opisując odległości w terenie reprezentującą szerokość pojedynczego piksela obrazu kamery jako p_d możliwe jest wyznaczenie wartości L – liczby pikseli ulegających rozmyciu w trakcie akwizycji w ruchu. Dla założonego modelu ruchu platformy z prędkością 200 m/s na wysokości 50 m liczba pikseli ulegających rozmyciu w trakcie akwizycji wynosi:

$$L = \frac{d}{p_d} = \frac{\frac{200m}{s} \cdot 0,001s}{0,041m} \cong 5 \quad (127)$$

Wartość wyznaczonego rozmycia będzie większa w przypadku konieczności lotów na wysokościach poniżej 50 m, zmniejszających wartość p_d oraz w przypadku zwiększania czasu ekspozycji matrycy. Dłuższy czas ekspozycji wskazany jest dla warunków małego nasłonecznienia.



Rys. 6.3.1 Odległość obrazowana w kadrze kamery dla przelotu na różnej wysokości (od lewej kolejno 69 m, 100 m, 150 m)

Prędkość lotu w trakcie badań w dniach 18.06 i 29.10.2021 r. mieściła się w zakresie 5-20 m/s i nie była charakterystyczna dla rakiet manewrujących. Jednak poprzez zastosowanie technik symulacyjnych, podpartych fizyką zagadnienia, możliwe jest rozpatrywanie zrealizowanego zagadnienia badawczego w taki sposób, aby przedstawić działanie układu wizyjnego dla większych prędkości (w tym, np. dla 200 m/s) charakterystycznych dla rakiet manewrujących.

Ze względu na dużą prędkość rakiet manewrujących konieczna jest analiza zjawiska rozmycia liniowego (wynikającego z ruchu platformy i kamery w trakcie akwizycji) zachodzącego w układzie optycznym.


Istotnymi parametrami toru akwizycji przy rozpatrywaniu platformy latającej jako rakiety manewrującej (dla prędkości ~ 200 m/s) są:

- czas ekspozycji matrycy (ang. *exposure time*),
- rozdzielczość,
- rodzaj migawki.

Wybrana kamera Blackfly S USB3 oraz układ optyczny posiadają następujące parametry:


- czas ekspozycji matrycy ($19.0 \mu\text{s} \div 30.0 \text{ s}$),
- rozdzielczość 960x600 [pix],
- rodzaj migawki: globalna.

Na Rys. 6.3.2 przedstawiono wpływ wartości L na rozmycie wybranego obrazu zarejestrowanego w trakcie badań w dniu 29.10.2021 r. Kolejne zdjęcia przedstawiają obraz oryginalny (zarejestrowany w trakcie badań przy przelocie z małą prędkością) oraz obrazy rozmywane z coraz większą wartością parametru L (odpowiadającego coraz większej prędkości i/lub obniżaniu wysokości lotu).




Rys. 6.3.2 Wpływ parametru L zależnego od czasu akwizycji kamery oraz prędkości i wysokości przelotu na rozmycie obrazu

Wpływ rozmycia należy rozpatrywać w kontekście zmniejszenia liczby wykrywanych cech obrazowych, które stanowią podstawę wyznaczania transformacji pomiędzy obrazami oraz w kontekście zmian w strukturze, a zwłaszcza przemieszczania granic krawędzi cech obrazowych. Na Rys. 6.3.3 i Rys. 6.3.4 przedstawiono dopasowanie dwóch tych samych cech na obrazie zarejestrowanym w bezruchu, na obrazie rozmytym oraz na obrazie po zastosowaniu filtracji Wienera ukierunkowanej na usunięcie tego rozmycia. Na rysunkach połączono ze sobą dopasowane algorytmem KAZE cechy lokalne. Położenie cechy na obrazie odpowiadającej temu samemu obiektowi fizycznemu na obrazie rozmytym i po filtracji Wienera różni się. Wielkość różnicy wynosząca w przybliżeniu 1 piksel nie jest znacząca dla wielu algorytmów, jednak w przypadku algorytmu obrazowej korekcji parametrów nawigacji konieczne jest skupienie wysiłku na możliwie precyzyjnym wyznaczeniu położenia obiektów rzeczywistych, którym przypisane są cechy obrazowe.



Rys. 6.3.3 Wynik dopasowania obrazu rozmytego w wyniku ruchu kamery do obrazu uzyskanego z tej samej kamery w warunkach statycznych



Rys. 6.3.4 Wynik dopasowania obrazu po filtracji Wienera usuwającej rozmycie do obrazu uzyskanego z tej samej kamery w warunkach statycznych


Aspekt zmniejszania liczby cech obrazowych na skutek rozmycia zdecydowano się poruszyć w ramach badania opartego o metodę symulacyjną.

W pracy zdecydowano się na przebadanie wpływu intensywności rozmycia obrazu na liczbę wykrywanych cech obrazowych. Intensywność mierzona jest wartością L określającą liczbę rozmywanych pikseli obrazowych.

Badane obrazy przedstawiają płaszczyzny o równomiernym rozkładzie cech w postaci struktur Voronoï. Struktury te generowane są losowo przy uwzględnieniu następujących parametrów w tworzonej populacji struktur:


- powierzchnia struktur jest opisana rozkładem normalnym w przedziale $\langle 0; 3000 \rangle$ (pix^2),
- powierzchnia całego obrazu stanowi sumę powierzchni struktur,
- badany obraz jest monochromatyczny o normalnym rozkładzie luminancji wśród struktur,
- struktury posiadają krawędzie składające się z odcinków.

Przykładowy obraz poddany badaniom przedstawia Rys. 6.3.5. Badanie zakłada uzyskanie statystycznej próbki wyników ze stu iteracji procesu wykrywania cech dla dostępnego zbioru obrazów. Przetwarzane obrazy mają rozdzielczość wynoszącą 600x960 pikseli. Obraz wzorca poddawany jest rozmyciu, którego model opisano zależnościami (71-81) przedstawionymi w rozdziale 4.3. Rozmycie propaguje się wzdłuż dłuższej krawędzi obrazu. Badania prowadzono przy stałym stosunku sygnału do szumu wynoszącym 30dB.




Rys. 6.3.5 Przykładowy obraz z próbki badanej poddany badaniom symulacyjnym związanych z efektem rozmycia

Charakterystyki przedstawione na Rys. 6.3.6 oraz Rys. 6.3.7 reprezentują funkcje znormalizowanej liczby cech na obrazie dla różnych wartości parametru L . Rys. 6.3.6 przedstawia liczbę cech wykrywanych dla obrazu rozmytego, natomiast Rys. 6.3.7 odnosi się do tego samego obrazu po filtracji ukierunkowanej na usuwanie efektu rozmycia. Normalizacja została zrealizowana poprzez podzielenie wynikowej liczby cech z danej symulacji przez pierwotną liczbę cech wykrytych na obrazie przed rozmyciem.



Rys. 6.3.6 Przebieg znormalizowanej liczby wykrywanych cech obrazowych w funkcji wielkości rozmycia



Rys. 6.3.7 Przebieg znormalizowanej liczby wykrywanych cech obrazowych w funkcji rozmiaru PSF wykorzystanej do ponownego wyostwienia obrazu

Warte podkreślenia jest uzyskanie dużej skuteczności filtracji rozumianej jako uzyskanie liczby cech na wyjściu procesu ich wykrywania na przefiltrowanym obrazie na poziomie zbliżonym do wartości uzyskiwanej dla tego samego procesu dla obrazu przed rozmyciem. Drugi istotny czynnik badania to fakt nieliniowego zmniejszania się liczby cech na skutek rozmycia, który dla wartości $L=20$ wynosił 0.1 wartości początkowej. Taka wartość w przypadku warunków rzeczywistych przy niewielkiej ilości wykrywanych i przetwarzanych cech, które są specyficzne np. dla warunków niskiego nasłonecznienia, może prowadzić do braku możliwości wyznaczania transformacji między obrazami przy dodatkowo występującym rozmyciu na skutek ruchu.

Prowadzone badanie zakładało odzwierciedlenie rzeczywistej liczby rozmywanych pikseli w długości jądra PSF filtra Wienera przeznaczonego do usuwania efektu rozmycia. W takiej sytuacji ograniczony jest wpływ „efektu dzwonienia”, opisanego w [[64], na obraz. Wraz ze wzrostem różnicy pomiędzy parametrami filtra, a wartością rzeczywistą rozmycia efekt ten zwiększa swój wpływ na strukturę obrazu. Istotna jest tu zarówno różnica w długości stosowanego filtra, jak i w kierunku jego stosowania. Jeżeli parametry te różnią się od parametrów rozmycia, wówczas na całym obrazie utrwalane są artefakty, które stanowią nowe cechy obrazowe. Sytuacja taka, pomimo zwiększenia liczby cech jest jednak niekorzystna ze względu na ich charakter jako zakłóceń z nieznaną dystrybucją na obrazie. Nowe cechy przesłaniają także cechy oryginalne, co zmienia ich charakter opisany za pomocą przedstawionych w rozdziale 4.1. deskryptorów. Na bazie tych wektorów dokonywana jest weryfikacja podobieństwa, która w nowej sytuacji może okazać się błędna.

Dlatego istotne jest, aby poznać formalny i uogólniony związek pomiędzy jakością danych wejściowych do filtra, rozumianą jako jego podobieństwo do parametrów rzeczywistego rozmycia, a efektami działania algorytmu dopasowywania cech. W dostępnej literaturze nie znaleziono opisu tego zagadnienia, a ma ono istotny wpływ na poprawne działanie algorytmu wizyjnej nawigacji przy poruszaniu się z dużymi prędkościami na małych wysokościach.

W związku z powyższym w pracy opracowano autorski algorytm wyznaczania postaci jądra filtra Wienera w oparciu o estymowane w układzie bezwładnościowym parametry ruchu platformy latającej z kamerą. W związku z wariancją estymowanych parametrów ruchu platformy zachodzi konieczność uwzględniania w opracowywanym algorytmie błędów w przyjętych parametrach wyznaczanego filtra i zrozumienie ich wpływu na dokładność dopasowywania obrazów. Dopasowanie ma charakter statystyczny, więc wpływ artefaktów powstałych na skutek błędów w przyjmowanych parametrach filtrów może być znaczący. W Tabeli 6.3.1 Autorski algorytm określania wartości PSF i filtracji obrazów Tabela 6.3.1 przedstawiono opis autorskiego algorytmu określania wartości PSF dla filtra Wienera. Algorytm zakłada wyliczanie parametrów L i θ funkcji PSF z uwzględnieniem minimalizacji negatywnego wpływu wariancji danych wejściowych. Opracowany algorytm generuje funkcję PSF w postaci przedstawionej na Rys. 6.3.8, gdzie $L=16$, θ . Na rysunkach Rys. 6.3.9 i Rys.

6.3.10 przedstawiono warianty PSF dla stałej długości L filtra i zmiennego kąta θ . Oba parametry mogą być zmieniane w algorytmie.

Tabela 6.3.1 Autorski algorytm określania wartości PSF i filtracji obrazów

Określanie wartości PSF i filtracja rozmycia - rekonstrukcja obrazu $I(x, y)$	
1. Rozpatrywane są następujące dane wejściowe:	
• $\hat{L}$ - estymowana liczba pikseli podlegająca rozmyciu wyliczana na podstawie parametrów ruchu oraz układu akwizycji, • $\hat{\gamma}$ - kierunek rozmycia wyliczany na podstawie parametrów ruchu platformy	
Zakłada się, że estymowane zmienne $\hat{L}$ i $\hat{\gamma}$ przybliżają wartości rzeczywiste z niepewnościami określonymi rozkładami normalnymi z wariancjami odpowiednio σ_L^2 i σ_γ^2 , co można przedstawić zapisem:	
$\hat{L} = L + n_L \wedge n_L \sim \mathcal{N}(0, \sigma_L^2), \quad \hat{\gamma} = \gamma + n_\gamma \wedge n_\gamma \sim \mathcal{N}(0, \sigma_\gamma^2).$	
2. Na podstawie danych wejściowych oraz wyznaczonych charakterystyk błędu dopasowania $E(\Delta L, \Delta\theta)$ przy założeniu, że:	
$\Delta L \rightarrow x \in \mathbb{R}, \quad \Delta\theta \rightarrow y \in \mathbb{R}$	
realizowana jest optymalizacja paramteru $\hat{L}$, minimalizująca zależność:	
$x_{opt} = \arg \min_{x,y} \Gamma(x, y)$	
Wartość zoptymalizowanej długości filtra dla ΔL_{opt} , po ponownej zmianie dziedziny $x \rightarrow \Delta L$ wynisie:	
$L_{opt} = \hat{L} + \Delta L_{opt},$	
3. Na podstawie L_{opt} oraz $\hat{\gamma}$ wyznacza się postać filtra $PSF(x, y)$). Rozpatrywany jest następujący zbiór argumentów - współrzędnych pikseli filtra: $x, y \in \langle 0; L \rangle \wedge x, y \in \mathbb{N}$.	
Kroki algorytmu:	
• Wyznacz wartość kąta rozmycia $\beta = \frac{\pi}{2} - \hat{\gamma}$ ○ Jeżeli $\beta = \frac{\pi}{2} \Rightarrow \begin{cases} PSF(x, y) = 1 & \text{dla } x = 0, \\ PSF(x, y) = 0 & \text{dla } x \neq 0; \end{cases}$ Normalizuj $PSF(x, y) = \frac{PSF(x, y)}{\sum_{x=0, y=0}^{L-1} PSF(x, y, L)} \Rightarrow$ przejdź do punktu 4 algorytmu. ○ Jeżeli $\beta \neq \frac{\pi}{2} + 2k\pi$ wyznacz współczynnik kierunkowy prostej równaniu: $y_l = ax_l$:	
$a = \tan \beta$	
W zbiorze $x \in \langle 0; L \cos \beta \rangle, y \in \langle 0; L \sin \beta \rangle \wedge x, y \in \mathbb{N}$:	


- Wyznacz wartości odległości od ww. prostej: $d(x, y) = \frac{ax-y}{\sqrt{a^2+1}}$;
- określ wartość funkcji $PSF(x, y) = 1 - |d|$,
- $PSF(x, y) < 0 \Rightarrow PSF(x, y) = 0$
- normalizuj $PSF(x, y) = \frac{PSF(x, y)}{\sum_{x=0, y=0}^{L-1} PSF(x, y, L)}$

4. Dla określonego stosunku sygnału i szumu – K, na podstawie transformat Fouriera rozmytego obrazu $G(u, v)$ oraz filtra $PSF(u, v)$, wykonaj rekonstrukcję obrazu:


$$I(u, v) = \frac{PSF^*(u, v)}{|PSF(u, v)|^2 + K} G(u, v)$$

Wyjściem algorytmu jest odwrotna transformata Fouriera funkcji obrazu w dziedzinie częstości przestrzennych:


$$I(x, y) = \mathcal{F}^{-1}\{I(u, v)\} \Rightarrow \text{zakończ algorytm}$$



Rys. 6.3.8 Przyjęta postać PSF przeznaczona do usuwania zakłóceń w postaci rozmycia obrazu dla $L=16$ i $\theta=0$




Rys. 6.3.9 Funkcje PSF dla $L=20$ i $\theta \in \langle 10; 20 \rangle$



Rys. 6.3.10 Funkcje PSF dla $L=20$ i $\theta \in \langle 30; 90 \rangle$

Na Rys. 6.3.11 przedstawiono obraz rozmyty zarejestrowany w trakcie badań w terenie oraz efekt filtracji usuwającej rozmycie. Obraz rozmyty uzyskano w warunkach lotu platformy wraz z układem optycznym z regulowanym czasem ekspozycji matrycy. Na podstawie opracowanego algorytmu wyznaczono odpowiedź impulsową układu optycznego. Następnie przez filtrację Wienera w przestrzeni widmowej uzyskano obraz ostrzejszy, przez co umożliwia wykrycie na nim większej ilości cech charakterystycznych, wykorzystywanych w rozpatrywanych algorytmach obrazowych. Istotne w obrazie po filtracji jest występowanie niekorzystnego zjawiska powstawania charakterystycznych form obrazowych rozłożonych równomiernie wzdłuż osi ruchu platformy z kamerą. Odstęp pomiędzy artefaktami zależy od częstości przestrzennej zastosowanego filtra. Niestety powstałe artefakty mogą stanowić źródło dodatkowych cech charakterystycznych na obrazie i powodować zmniejszenie precyzji dopasowania obrazów stanowiących źródło danych nawigacyjnych dla platformy latającej.



Rys. 6.3.11 Obraz rozmyty (lewy) oraz poddany filtracji z wykorzystaniem odpowiedzi impulsowej – PSF (prawy) w filtrze Wienera

Filtr Wienera do badania został wybrany ze względu na swoją prostotę i możliwość zastosowania w układzie działającym w czasie rzeczywistym. Ma to jednak konsekwencje w postaci prawdopodobieństwa pogorszenia efektywności nawigacji platformy latającej na skutek wprowadzania błędnych dopasowań do statystycznej puli przetwarzanej przez algorytm RANSAC.

Ze względu na ww. czynniki powodowane występowaniem artefaktów na obrazach po filtracji w pracy zdecydowano się na przebadanie wpływu błędów estymat kąta odchylenia oraz prędkości na jakość dopasowania cech na obrazach. Badane obrazy przedstawiają płaszczyzny o równomiernym rozkładzie cech w postaci struktur Voronoi. Struktury te generowane są losowo przy uwzględnieniu następujących parametrów w tworzonej populacji struktur:

- powierzchnia struktur jest opisana rozkładem normalnym w przedziale $\langle 0; 3000 \rangle$ (pix^2),
- powierzchnia całego obrazu stanowi sumę powierzchni struktur,
- badany obraz jest monochromatyczny o normalnym rozkładzie luminancji pomiędzy strukturami,

- struktury posiadają krawędzie składające się z odcinków.

Algorytm dopasowania zakłada wykorzystanie metody RANSAC mającej na celu wyznaczenie homograficznej relacji pomiędzy płaszczyznami. Przyjęto następujące parametry metody RANSAC:


- próg dopasowania (po transformacji) = 2.5 (pix),
- poziom ufności 0.99 (-),
- minimalna liczba wykrytych i dopasowanych punktów = 4 (-),
- maksymalna liczba iteracji = 1000 (-).

Przetwarzane obrazy mają rozdzielczość wynoszącą 600x960 pikseli. Obraz wzorca poddawany jest rozmyciu wzdłuż jego dłuższej krawędzi według modelu opisanego zależnościami w rozdziale 4.3. Błąd dopasowania rozumiany jest jako odległość punktu obrazu wzorca do dopasowanego punktu na obrazie po filtracji z wykorzystaniem filtra Wienera z określonymi parametrami jądra. Odległość ta wyznaczana jest na podstawie translacji w osi x oraz y obrazu będącej częścią macierzy homografii. Badania prowadzono przy stałym stosunku sygnału do szumu wynoszącym 30dB. W pierwszym badaniu skupiono się na wpływie rozmycia na dokładność dopasowania cech na obrazach. Badanie przeprowadzono metodą Monte Carlo na bazie próbki 100 obrazów z losowo wygenerowanymi teksturami Voronoi. Do wyznaczenia rozkładu błędu dopasowania dla jednej wartości analizowanego parametru (w tym przypadku długości L filtra rozmywającego obraz) przeprowadzano 500 symulacji rozmycia. W każdej symulacji algorytm RANSAC rozpoczyna iteracyjną realizację wyznaczania modelu dopasowania przy losowo wybranej próbce początkowej. W ramach symulacji wymuszano dla każdego obrazu 5 różnych wartości początkowych algorytmu RANSAC. Wartości błędu dopasowania wyrażane są w pikselach. Błąd opisywany jest na wykresach także wyznaczonymi wielkościami średniej z zaznaczonym obszarem $\pm\sigma$ i mediany. Na podstawie rozkładów błędów dopasowania wyznaczanych dla określonej wartości badanego parametru prezentowane są także zależności określające tendencje w całym badanym zakresie wartości. Podobnie jak na ww. wykresach prezentowane są także średnia z zaznaczonym obszarem $\pm\sigma$ i mediana.


6.3.1. BADANIE WPLYWU ROZMYCIA NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW

Na pierwszym wykresie Rys. 6.3.1.1 przedstawiono rozkład błędu dopasowania obrazów dla rozmycia o długości $L=5$ pikseli. W celu umożliwienia porównania wartości błędu dopasowania dla kolejnych wartości parametru L zdecydowano się na prezentację wyników w zakresie umożliwiającym wyciąganie uogólnionych wniosków. Dlatego kolejne wykresy przedstawiają ten sam zakres na osiach odciętych. Przedstawiony na pierwszym wykresie Rys. 6.3.1.1 rozkład mieści się w zakresie poniżej 1 piksela, co utrudnia interpretację na tym pojedynczym ujęciu, ale rozkład ten jest istotny dla przedstawienia zależności pomiędzy kolejnymi wykresami błędu. Kolejne wykresy z Rys. 6.3.1.1, $L=10$, $L=15$

i Rys. 6.3.1.2 będą komentowane przy charakterystykach zbiorczych.




Rys. 6.3.1.1 Rozkład błędu dopasowania obrazów dla rozmycia o długości $L = 5, L = 10, L = 15$




Rys. 6.3.1.2 Rozkład błędu dopasowania obrazów dla rozmycia o długości $L=20$, $L=25$, $L=30$ pikseli

Zapisy $\mu(E_m)$, $med(E_m)$, $\sigma(E_m)$ stanowią skróconą wersję zapisów $(E_m(L))$, $med(E_m(L))$, $\sigma(E_m(L))$ i są stosowane dla zachowania przejrzystości. Funkcja $E_m(L)$ charakteryzuje błąd dopasowania dwóch obrazów. Pierwszy z nich jest obrazem referencyjnym, a drugi obrazem rozmytym filtrem o długości L . Długość filtra wyrażona jest w pikselach i wynika z zależności (90) omówionej w pracy.

Na Rys. 6.3.1.3 przedstawiono charakterystykę wartości średniej z oznaczonym przedziałem ufności oraz mediany błędu dopasowania obrazów dla zakresu $L \in \langle 5; 20 \rangle$ długości filtra PSF służącego rozmyciu obrazu pierwotnego. W pierwszym zakresie rozpatrywana funkcja ma charakter wykładniczy. Mediana i średnia są do siebie zbliżone. Na Rys. 6.3.1.4 przedstawiono cały badany zakres rozpatrywanej charakterystyki. Na rysunku tym w części wykresu widać kontynuację tendencji z rysunku Rys. 6.3.1.3 Jednak dla wartości rozmycia $L > 40$ błąd ustala się na wartości granicznej wynikającej z rozdzielczości badanych obrazów.



Rys. 6.3.1.3 Charakterystyka wartości średniej błędów z oznaczonym przedziałem ufności oraz mediany błędów dopasowania obrazów dla zakresu $L \in \langle 5; 20 \rangle$ długości filtra PSF służącego rozmyciu obrazu pierwotnego



Rys. 6.3.1.4 Charakterystyka wartości średniej z oznaczonym przedziałem ufności oraz mediany błędu dopasowania obrazów dla zakresu $L \in \langle 5;50 \rangle$ długości filtra PSF służącego rozmyciu obrazu pierwotnego

W Tabela 6.3.1.1 przedstawiono wartości dla mediany, średniej i odchylenia standardowego dla całego zakresu wartości badanych długości L .


Tabela 6.3.1.1 Tabela mediany błędu dopasowania obrazu po filtracji do obrazu rozmytego wzorca dla różnych wartości rozmycia określonych parametrem L

L	$med(E_m)$	$\mu(E_m)$	$\sigma(E_m)$
5	0,03	0,03	0,02
10	0,21	0,28	0,23
15	1,10	1,31	0,92
20	3,29	3,53	2,17
25	6,14	17,76	83,24
30	10,61	140,20	264,27
35	277,28	364,21	334,84
40	617,56	517,77	317,02
45	551,80	556,17	253,78
50	619,45	588,04	243,39


6.3.2. BADANIE WPLYWU BŁĘDU $\Delta\theta$ NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW

W kolejnym badaniu analizie poddano wpływ błędu $\Delta\theta$ na dokładność dopasowania obrazów. Pierwszy obraz stanowi wzorec z ww. strukturą Voronoi, drugi to obraz poddany rozmyciu i filtracji usuwającej ten efekt. Wielkość $\Delta\theta$ odnosi się do różnicy pomiędzy

rzeczywistym kierunkiem rozmycia θ a wartością przyjętą jako parametr funkcji PSF w filtrze Wienera przeznaczonym do usuwania efektu rozmycia z obrazów. Wartość błędu określana jest w stopniach. Na Rys. 6.3.2.1 i Rys. 6.3.2.2 przedstawiono rozkład błędu dopasowania obrazów w funkcji błędów $\Delta\theta=1, \Delta\theta=5, \Delta\theta=9, \Delta\theta=13, \Delta\theta=17$ i $\Delta\theta=19$ określania wartości kąta PSF.




Rys. 6.3.2.1 Rozkład błędu dopasowania obrazów dla błędów $\Delta\theta=1, \Delta\theta=5, \Delta\theta=9$ ($^\circ$) określania wartości kąta PSF



Rys. 6.3.2.2 Rozkład błędu dopasowania obrazów dla błędów $\Delta\theta = 13^\circ, \Delta\theta = 17^\circ, \Delta\theta = 19^\circ$ określania wartości kąta PSF


Rysunek Rys. 6.3.2.3 przedstawia charakterystykę błędu dopasowania dwóch obrazów przy różnej wartości błędu kierunku rozmycia $\Delta\theta$. Obraz ulegał rozmyciu filtrem o długości $L = 10$ (pix) dla kierunku $\theta = 0$ (°). Kolejne wartości przyrostów różniły się o 1 (°). Zapisy $\mu(E_m)$, $med(E_m)$, $\sigma(E_m)$ stanowią skróconą wersję zapisów $(E_m(\Delta\theta))$, $med(E_m(\Delta\theta))$, $\sigma(E_m(\Delta\theta))$ i są stosowane dla zachowania przejrzystości.




Rys. 6.3.2.3 Charakterystyka wartości średniej z oznaczonym przedziałem ufności oraz mediany błędu dopasowania obrazów rozmytego oraz po filtracji Wienera przy błędzie PSF z zakresu $\Delta\theta \in \langle 2; 20 \rangle$

Na Rys. 6.3.2.3 nie zaznaczono wartości średnich dla $\Delta\theta = 19^\circ$ i $\Delta\theta = 20^\circ$, które wynoszą odpowiednio 11,6 (pix) i 13 (pix). Odstającym przypadkiem pomiarowym jest wartość błędu dopasowania kierunku rozmycia $\Delta\theta = 16^\circ$. Przedstawia on pierwsze odstępstwo dla wartości średniej oraz odchylenia standardowego od zaobserwowanego dla wcześniejszych przypadków wykładniczego modelu charakterystyki błędów. Histogram błędu dopasowania, wartości średnią, medianę oraz odchylenie standardowe dla przypadku $\Delta\theta = 16^\circ$ przedstawiono na Rys. 6.3.2.4.

Przyczyną powstania skokowego przyrostu wartości średniej błędu jest znacząca liczba artefaktów, które zaczynają wykazywać duże podobieństwo do siebie. Artefakty te rozłożone są na brzegach obrazu, symetrycznie względem osi podłużnej i poprzecznej obrazu, a także skośnie, pod różnym kątem, na całym obrazie. Liczba podobnych do siebie artefaktów stanowi znaczącą populację wśród wszystkich wykrytych na obrazie cech, co skutkuje możliwością błędnego dopasowania całego obrazu. Obraz rozmyty o 10 pikseli, a następnie poddany filtracji z błędem estymacji kierunku rozmycia $\Delta\theta = 16^\circ$ przedstawia Rys. 6.3.2.5. Długość L zastosowanego filtra Wienera odpowiadała wartości pierwotnej użytej przy rozmyciu obrazu.



Rys. 6.3.2.4 Rozkład błędu dopasowania obrazów dla błędów $\Delta\theta = 16^\circ$ określania wartości kąta PSF



Rys. 6.3.2.5 Obraz po zastosowaniu filtra Wienera z błędem kierunku rozmycia $\Delta\theta = 16^\circ$.

Różnica pomiędzy medianą i średnią błędu rozpatrywanej zmiennej losowej wynika z niewielkiej liczby błędnych dopasowań, które jednak wnoszą duże wartości do próbki badanej. Dla kolejnych przyrostów błędu kierunku rozmycia, prawdopodobieństwo błędnych dopasowań wzrasta, co odzwierciedlają przedstawione na Rys. 6.3.2.3 charakterystyki dla wartości $\Delta\theta = 19^\circ$ i $\Delta\theta = 20^\circ$. Wartość średnia błędu dla przypadku $\Delta\theta = 18^\circ$ jest

odstępstwem od ogólnej tendencji. Charakterystyka mediany w tym przypadku, w odróżnieniu od średniej, zmienia się o niewielką wartość, a jej niewielkie fluktuacje w całym przebiegu pozwalają na zobrazowanie ogólnej tendencji zmian. W związku z powyższym zdecydowano się na aproksymację charakterystyki mediany funkcją wykładniczą drugiego rzędu.

Do wyznaczenia funkcji posłużono się metodą najmniejszych kwadratów. Uzyskano wynik w postaci:

$$E_m(\Delta\theta) = 0,0059(\Delta\theta)^2 - 0.0231(\Delta\theta)^2 + 0.0850 \quad (128)$$


Błąd średniokwadratowy aproksymacji wyniósł 0.057 (pix), co w stosunku do maksimum funkcji w przedziale wynoszącym 2,2 (pix) pozwala na stwierdzenie, że wielomian stopnia drugiego może aproksymować otrzymaną charakterystykę z dokładnością umożliwiającą jej wykorzystanie do dalszych analiz. Należy zauważyć jednak, że charakterystyka aproksymowanej funkcji posiada swoje minimum $\min(E_m(\Delta\theta)) = 0,0624$ dla $\Delta\theta = 1.9576$ i jest malejąca w przedziale $(0; 1,9576)$, co nie oddaje poprawnie charakteru przyrostu błędu dopasowania obrazów dla ww. przedziału. Stąd zdecydowano na nałożenie na aproksymację warunku monotoniczności dla całej rozpatrywanej dziedziny. Zmodyfikowany problem jest w postaci:

$$\min_x \frac{1}{2} \|Cx - d\|_2^2 \wedge \begin{cases} Ax \leq b \\ 0 \leq x \leq \infty \end{cases}$$

Wektor $\mathbf{b}$ jest wówczas wektorem zerowym. Po uwarunkowaniu metody otrzymano nową postać aproksymowanej funkcji:

$$E_m(\Delta\theta) = 0,0048(\Delta\theta)^2 + 0.0012 \quad (129)$$

Błąd średniokwadratowy funkcji w tej postaci ma wartość 0.068 (pix) i jest większy od wartości błędu dla pierwszej aproksymaty. Jednak różnica ta nie jest znacząca, ze względu na niepewność wyznaczonych dyskretnych wartości błędu dopasowania obrazów, które wynikają z zastosowania metody Monte Carlo. Nowa postać funkcji przyrasta w całym rozpatrywanym przedziale. Niezerowa wartość funkcji dla $\Delta\theta = 0$ może być pomijana w dalszych analizach. Aproksymowaną charakterystykę $E_m(\Delta\theta)$ przedstawia Rys. 6.3.2.6






Rys. 6.3.2.6 Aproxymowana charakterystyka błędu dopasowania w funkcji ($\Delta\theta$)



6.3.3. BADANIE WPŁYWU BŁĘDU ΔL NA DOKŁADNOŚĆ DOPASOWANIA OBRAZÓW

Badanie wpływu dodatniego przyrostu błędu ΔL na dokładność dopasowania dwóch obrazów. Pierwszy obraz stanowi wzorzec z ww. strukturą Voronoi. Drugi to obraz poddany rozmyciu i filtracji usuwającej ten efekt. Wielkość ΔL odnosi się do różnicy pomiędzy rzeczywistą wartością rozmycia L a wartością przyjętą jako parametr funkcji PSF w filtrze Wienera przeznaczonym do usuwania efektu rozmycia z obrazów. Wartość błędu określana jest w pikselach.

Na rysunkach Rys. 6.3.3.1 oraz Rys. 6.3.3.2 przedstawiono histogramy błędu dopasowania ww. obrazów dla kolejnych przyrostów ΔL . Obraz ulegał rozmyciu filtrem o długości $L = 10$.




Rys. 6.3.3.1 Rozkłady błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L=1$, $\Delta L=3$ i $\Delta L=5$ w zastosowanym filtrze




Rys. 6.3.3.2 Rozkłady błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L=7$ i $\Delta L=9$ w zastosowanym filtrze

Na rysunkach Rys. 6.3.3.3 oraz Rys. 6.3.3.4 oraz przedstawiono charakterystyki błędu dopasowania dla przyrostów ΔL z zakresu $\langle 1; 8 \rangle$ pikseli. Obraz ulegał rozmyciu filtrem o długości $L = 10$. Podobnie jak w przypadku przyrostów błędów kątowych, tak i w tym przypadku charakterystyka ma charakter wykładniczo narastający.




Rys. 6.3.3.3 Charakterystyka błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera w funkcji błędu $\Delta L \in \langle 1; 5 \rangle$






Rys. 6.3.3.4 Charakterystyka błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera w funkcji błędu $\Delta L \in \langle 1; 8 \rangle$

W kolejnym badaniu przeanalizowano wpływ dodatniego przyrostu błędu ΔL na dokładność dopasowania dwóch obrazów. Pierwszy obraz stanowi wzorec z ww. strukturą Voronoi. Drugi to obraz poddany rozmyciu i filtracji usuwającej ten efekt. Obraz ulegał

rozmyciu filtrem o długości $L = 20$. Wielkość ΔL odnosi się do różnicy pomiędzy rzeczywistym wartością rozmycia L a wartością przyjętą jako parametr funkcji PSF w filtrze Wienera przeznaczonym do usuwania efektu rozmycia z obrazów. Wartość błędu określana jest w pikselach. Na rysunkach Rys. 6.3.3.5 oraz Rys. 6.3.3.6 przedstawiono histogramy błędu dopasowania ww. obrazów dla kolejnych przyrostów ΔL w zakresie $\Delta L \in \{1; 14\}$.




Rys. 6.3.3.5 Rozkłady błędu dopasowania obrazu rozmytego o 20 pikseli ($L=20$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L=1$ i $\Delta L=3$ w zastosowanym filtrze




Rys. 6.3.3.6 Rozkłady błędu dopasowania obrazu rozmytego o 20 pikseli ($L=20$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L=1$ i $\Delta L=3$ w zastosowanym filtrze

Charakterystykę mediany przedstawioną na rysunku Rys. 6.3.3.7 można opisać wielomianem wykładniczym drugiego rzędu. Szerszy zakres charakterystyki przedstawia Rys. 6.3.3.9. Widać na nim, że powyżej wartości $\Delta L=8$ dla średniej i $\Delta L=8$ w odniesieniu do mediany błędu można wyróżnić skokowy przyrost, a potem ustalenie wartości na maksymalnym poziomie błędu.



Rys. 6.3.3.7 Charakterystyka błędu dopasowania obrazu rozmytego o 20 pikseli ($L=20$, $\theta=0$) do obrazu po filtracji Wienera w funkcji błędu $\Delta L \in \{1; 8\}$



Rys. 6.3.3.8 Charakterystyka błędu dopasowania obrazu rozmytego o 20 pikseli ($L=20$, $\theta=0$) do obrazu po filtracji Wienera w funkcji błędu $\Delta L \in \{1; 15\}$

Po przeanalizowaniu charakterystyk błędów dla zakresu $\Delta L \in \langle 0; 0.9L \rangle$ oraz dla różnej długości L filtrów stwierdza się, że charakterystyki te mogą być uogólnione. Funkcja określająca położenie punktu podziału charakterystyki błędu dopasowania obrazów z rozkładu wykładniczego na rozkład oscylacyjny z tłumieniem sprowadzającym charakterystykę do asymptoty określona jest zależnością:

$$\Delta L_{pg} = f_{pp}(\Delta\theta) + 0,1L + 7 \quad (130)$$

, gdzie $f_{pp}(\Delta\theta)$ jest funkcją liniową w postaci:

$$f_{pp}(\Delta\theta) = -0.3478 \Delta\theta \quad (131)$$

Wartości funkcji liniowych aproksymowano metodą najmniejszych kwadratów z wykorzystaniem danych symulacyjnych. Funkcja $f_{pp}(\Delta\theta)$ została ujęta w powyższych zależnościach ze względu na zaobserwowane relacje pomiędzy błędami $E_m(\Delta\theta)$ i $E_m(\Delta L)$.

Na rysunku Rys. 6.3.3.9 przedstawiono znormalizowane przebiegi funkcji znormalizowanego błędu dopasowania obrazów dla różnych wartości ΔL_{norm} . Wartości ΔL_{norm} powiązane są z ΔL poprzez zależność:

$$\Delta L_{norm} = \frac{\Delta L}{\Delta L_{pg}} \quad (132)$$


Natomiast $E_{norm}(\Delta L)$ związane jest z $E_m(\Delta L)$ liniową zależnością:

$$\Delta E_{norm}(\Delta L) = \frac{E_m(\Delta L)}{L} \quad (133)$$

Charakterystyka aproksymująca znormalizowane przebiegi funkcji może być opisana z wykorzystaniem zależności:

$$E_+^D(\Delta L_{norm}) = 0,2975(\Delta L_{norm})^2 \quad (134)$$

Funkcję wyznaczono metodą najmniejszych kwadratów i uzyskano uogólniony błąd aproksymacji w postaci błędu średniokwadratowego o wartości 0.0361 i odniesiony do znormalizowanej amplitudy. Błąd ten można przenieść liniowo na charakterystyki dla filtrów o różnej długości, np. dla filtra o długości 10 błąd wyniesie 1,08 piksela, dla filtra o długości $L=20$ błąd wyniesie 0,72 piksela, a dla filtra o długości $L=10$ wartość błędu wyniesie 0,36 piksela. Wyznaczone charakterystyki znormalizowane wraz funkcją aproksymującą przedstawia Rys. 6.3.3.9.



Rys. 6.3.3.9 Charakterystyka znormalizowanego błędu dopasowania obrazów dla dodatnich wartości błędu ΔL w część wykładniczej

Wykres funkcji błędu dopasowania dla zakresu powyżej wartości podziału można opisać zależnością:

$$E_+^G(\Delta L) = \left(1 - \frac{e^{-a_0(\Delta L)}}{a_2} \cos(a_1(\Delta L)) \right) a_3 \quad (135)$$


, gdzie ΔL oznacza dodatnie wartości błędu w przedziale $\Delta L > f_{pp}(\Delta\theta) + 0,1L + 7$.

Wartość współczynników $a_0, \dots, a_3$ funkcji przedstawia tabela 6.3.3

Tabela 6.3.3.1 Wartość współczynników funkcji $E(\Delta L_+^G)$

a_0	a_1	a_2	a_3
0,4788	0,8496	0,9813	367,8237

Wyznaczoną funkcję aproksymującą charakterystykę w przedziale wartości powyżej $f_{pp}(\Delta\theta) + 0,1L + 7$ przedstawiono na Rys. 6.3.3.10.



Rys. 6.3.3.10 Funkcja aproksymująca charakterystykę błędu dopasowania obrazów dla dodatnich przyrostów ΔL powyżej wyznaczonego punktu podziału

Do wyznaczenia współczynników $a_0, \dots, a_3$ wykorzystano metodę nieliniowej regresji Gaussa-Newtona. Zakładając, że $f(x) = E_+^G(\Delta L)$ dla $\Delta L \rightarrow x \in \mathbb{R}$ jakobian wykorzystany do wyznaczenia aproksymowanej funkcji ma postać:

$$J_f = \begin{bmatrix} \frac{\partial f_1}{\partial a_0} & \dots & \frac{\partial f_1}{\partial a_3} \\ \vdots & \ddots & \vdots \\ \frac{\partial f_n}{\partial a_0} & \dots & \frac{\partial f_n}{\partial a_3} \end{bmatrix} \quad (136)$$

$$\frac{\partial f_n}{\partial a_0} = \frac{x e^{-a_0 x}}{a_2} \cos(a_1 x) a_3$$

$$\frac{\partial f_n}{\partial a_1} = \frac{x e^{-a_0 x}}{a_2} \sin(a_1 x) a_3$$

$$\frac{\partial f_n}{\partial a_2} = \frac{e^{-a_0 x}}{a_2^2} \cos(a_1 x) a_3$$

$$\frac{\partial f_n}{\partial a_3} = 1 - \frac{e^{-a_0 x}}{a_2} \cos(a_1 x)$$

(137)

Metoda regresji Gaussa-Newtona wymaga inicjalizacji szukanych wartości współczynników $a_0, \dots, a_3$, określenia progu konwergencji oraz maksymalnej liczby iteracji. Przyjęto wartość 3500 jako maksymalną liczbę iteracji, a warunkiem konwergencji jest uzyskanie wartości błędu wszystkich współczynników na poziomie mniejszym niż 0,001.

W określeniu wartości współczynników wykorzystano fakt, że poszukiwana funkcja może opisywać stabilny, oscylacyjny układ inercyjny drugiego rzędu, gdzie argument x z równania (137) dalej reprezentowany jest czasem t :

$$x \mapsto t \in \mathbb{R} \quad (138)$$

Współczynnik tłumienia ζ oraz pulsacja ω_n w takim układzie mogą być powiązane ze współczynnikiem a_0 poprzez:

$$a_0 = \zeta \omega_n \quad (139)$$

Czas, dla którego funkcja przyjmuje swoje maksimum, przy założeniu, że chwila początkowa charakterystyki odpowiada ww. punktowi podziału charakterystyki błędu dopasowania na dwie części, może być wyrażony poprzez:

$$t_p = \frac{\pi}{\omega_d} \quad (140)$$

, gdzie

$$\omega_d = \omega_n \sqrt{1 - \zeta^2} = a_1, \quad (141)$$

Wartość współczynnika a_2 związana jest z tłumieniem członu poprzez:

$$a_2 = \sqrt{1 - \zeta^2}. \quad (142)$$

Natomiast a_3 jest współczynnikiem skalującym, którego wartość będzie zależna od wartości asymptoty funkcji $E_+^G(\Delta L)$. Wartość ta została ustalona na podstawie średniej z pomiarów dla filtrów o różnej ($L=10, L=20, L=30$) długości i badanego zakresu $\Delta L \in \langle 0.1L + 7; 0.9L \rangle$. Pomiaru te zawierają wartości skokowo różniące się od charakterystyki kwadratowej dla wartości ΔL poniżej punktu podziału. Wartości asymptot charakterystyk wykorzystanych do wyznaczenia postaci aproksymowanej znajdują się w przedziale $\langle 360; 500 \rangle$. Wartość ww. asymptoty prawdopodobnie powiązana jest z rozdzielczością badanego obrazu. Potwierdzenie tego stwierdzenia wymagałoby jednak ponowienia badań dla nowej próbki losowej obrazów o innej niż przejęta w pracy rozdzielczości. Wykres aproksymowanej funkcji błędu dopasowania dla dodatnich wartości błędu $\Delta L > \Delta L_{pg} = f_{pp}(\Delta\theta) + 0,1L + 7$. przedstawia Rys. 6.3.3.10. Na rysunku tym wartość 0 odpowiada wartości $f_{pp}(\Delta\theta) + 0,1L + 7$. Funkcja $f_{pp}(\Delta\theta)$ określa liniowe przesunięcie skokowego przyrostu błędu, prezentowanego Rys. 6.3.3.10 w funkcji błędu $\Delta\theta$. Wartości ΔL_{norm} wyrażone są w pikselach, a relacja pomiędzy ΔL i ΔL_{norm} Jest określona jako $\Delta L_{norm} = \Delta L - \Delta L_{pg}$. Błąd średniokwadratowy aproksymacji dla przedstawionego na Rys. 6.3.3.10 zbioru punktów wyniósł 37,39 (pix). Wartość ta jest znacząco większa niż w przypadku innych aproksymowanych w pracy funkcji. Jednak wariancja położenia tych punktów również jest największa. Wartość asymptoty jest kilkaset razy większa od wartości maksymalnej na końcu przedziału opisanego funkcją $E_+^D(\Delta L)$, a przyrost amplitudy jest gwałtowny i następuje w przedziale 2 pikseli. Ze względu na to, że w proponowanej wersji

filtra $\Delta L \in \mathbb{N}$ niemożliwe jest dokładniejsze odwzorowanie charakterystyki w tym przedziale. Stąd stwierdza się, że aproksymata ma wystarczającą dokładność, zwłaszcza, że największe wartości błędów charakteryzują punkty w przedziale wartości ± 100 (pix) od poziomu asymptoty. Punkty określające nachylenie charakterystyki są obarczone mniejszymi wartościami błędów. Opisywana funkcja dla zachowania ciągłości charakterystyki błędu dopasowania obrazów jest przesuwana i skalowana w osi rzędnych tak, aby pierwsza wartość części oscylacyjnej odpowiadała ostatniej wartości części wykładniczej, a wartość asymptoty nie ulegała zmianie. Dodatkowy wpływ na wartość funkcji ma również ewentualny błąd wynikający z niezerowej wartości $\Delta\theta$. Powyższe uwarunkowania opisuje się jako:


$$E_+^G(\Delta L_{pg}, \Delta\theta) = E_+^D(\Delta L_{pg}) + E_m(\Delta\theta) + \frac{E_{max} - E_m(\Delta\theta)}{E_{max}}, \quad (143)$$

gdzie $E_{max}=400$ jest uśrednioną wartością maksymalną błędu dla obrazów stałej rozdzielczości uzyskiwanych w badaniu.




Dla wartości $\Delta L > \Delta L_{pg}$ postać ogólną charakterystyki $E_+^G(\Delta L, \Delta\theta)$ można opisać jako:

$$E_+^D(\Delta L_{pg}) + E_m(\Delta\theta) + \frac{E_{max} - E_m(\Delta\theta)}{E_{max}} \left(1 - \frac{e^{-0,4788(\Delta L)}}{0,9813} \cos(0,8496(\Delta L)) \right) 367,8237 \quad (144)$$

Badanie wpływu ujemnego przyrostu błędu ΔL na dokładność dopasowania dwóch obrazów. Pierwszy obraz stanowi wzorec z ww. strukturą Voronoi. Drugi to obraz poddany rozmyciu i filtracji usuwającej ten efekt. Na rysunkach Rys. 6.3.3.11 oraz Rys. 6.3.3.12 przedstawiono histogramy błędu dopasowania ww. obrazów dla kolejnych przyrostów błędu w kierunku ujemnych wartości ΔL . Obraz ulegał rozmyciu filtrem o długości $L = 10$.




Rys. 6.3.3.11 Rozkłady błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L = -1$




Rys. 6.3.3.12 Rozkłady błędu dopasowania obrazu rozmytego o 10 pikseli ($L=10$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L = -3$, $\Delta L = -5$, $\Delta L = -7$

Na Rys. 6.3.3.13 przedstawiono charakterystykę błędu dopasowania dla ujemnego zakresu wartości $\Delta L \in \langle -1; -8 \rangle$. Na przedstawionym wykresie oś odciętych reprezentuje moduł z wartości błędu ΔL . Rozmycie wykonano filtrem o długości $L=10$. Charakterystyczne dla tego przebiegu jest tylko początkowe narastanie błędu, po którym następuje oscylacja wokół asymptoty.




Rys. 6.3.3.13 Charakterystyka błędu dopasowania dla ujemnych wartości $\Delta L \in \langle -1; -8 \rangle$ przy rozmyciu filtrem o długości $L=10$.




W kolejnym badaniu analizowano wpływ ujemnego przyrostu błędu ΔL na dokładność dopasowania dwóch obrazów. Pierwszy obraz stanowi wzorzec z ww. strukturą Voronoi. Drugi to obraz poddany rozmyciu i filtracji usuwającej ten efekt. Na Rys. 6.3.3.14 - Rys. 6.3.3.17 przedstawiono histogramy błędu dopasowania ww. obrazów dla kolejnych przyrostów błędu w kierunku ujemnych wartości ΔL . Obraz ulegał rozmyciu filtrem o długości $L = 30$.




Rys. 6.3.3.14 Rozkłady błędów dopasowania obrazu rozmytego o 30 pikseli ($L=30$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L = -1$



Rys. 6.3.3.15 Rozkłady błędu dopasowania obrazu rozmytego o 30 pikseli ($L=30$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L = -3$, $\Delta L = -6$, $\Delta L = -9$




Rys. 6.3.3.16 Rozkłady błędu dopasowania obrazu rozmytego o 30 pikseli ($L=30$, $\theta=0$) do obrazu po filtracji Wienera dla wartości błędu $\Delta L = -12$, $\Delta L = -15$, $\Delta L = -18$




Rys. 6.3.3.17 Rozkłady błędu dopasowania obrazu rozmytego o 30 pikseli ($L=30$, $\theta=0$) dla obrazu po filtracji Wienera dla wartości błędu $\Delta L = -20$

Na Rys. 6.3.3.18 oraz Rys. 6.3.3.19 przedstawiono charakterystykę błędu dopasowania dla ujemnego zakresu wartości $\Delta L \in \{-1; -20\}$. Na przedstawionym wykresie oś odciętych reprezentuje moduł wartości błędu ΔL . Rozmycie wykonano filtrem o długości $L=30$. Charakterystyczne dla tego przebiegu jest tylko początkowe narastanie błędu, po którym następuje oscylacja wokół asymptoty. Oscylacja dotyczy zarówno średniej, jak i mediany.




Rys. 6.3.3.18 Charakterystyka błędu dopasowania dla ujemnych wartości $\Delta L \in \{-1; -20\}$ przy rozmyciu filtrem o długości $L=30$.



Rys. 6.3.3.19 Charakterystyka mediany błęd dopasowania dla ujemnych wartości $\Delta L \in \{-1; -20\}$ przy rozmyciu filtrem o długości $L=30$

Na Rys. 6.3.3.20 przedstawiono zestawienie charakterystyk mediany błędów dopasowania dla filtrów o długościach L równych 10, 20 i 30 pikseli. Legenda rysunku odnosi się do tych długości poprzez indeks dolny. Oś odciętych wykresu na rysunku przedstawia moduł wartości ΔL . Dzięki temu na rysunku można zaobserwować dużą zgodność charakterystyk odnoszących się do przeciwnych sobie wartości ΔL . Znak błędu określony jest indeksem górnym charakterystyk w legendzie wykresu. Po analizie rysunku stwierdza się, że wszystkie charakterystyki w części bliskiej wartości 0 mogą zostać opisane uogólnionym wielomianem drugiego rzędu. Ze względu na to, że rozkłady charakterystyk opisanych przeciwnym znakiem są do siebie zbliżone zdecydowano się wykorzystać wyznaczony wielomian aproksymujący charakterystyki z dodatnim błędem ΔL również do opisu charakterystyk z błędem ujemnym. Ostatnim istotnym aspektem przedstawionym na Rys. 6.3.3.20 jest występowanie zmian monotoniczności charakterystyk odniesionych do ujemnych wartości ΔL . Zmiana charakteru przyrostowego na oscylacyjnie asymptotyczny widoczna jest dla charakterystyk $med(E_{10}^-)$, $med(E_{20}^-)$ oraz $med(E_{30}^-)$. Wartość błędu dla której następuje opisywana zmiana jest różna dla przedstawionych charakterystyk. Opis wykładniczy wielomianem drugiego rzędu tych charakterystyk ma więc zastosowanie do przedziału, dla którego moduł wartości błędu ΔL jest mniejszy od modułu wartości odpowiadającej zmianie monotoniczności. Zagadnienie lokalizacji punktu zmiany tendencji charakterystyki oraz jej opisu w części asymptotycznej podejmowane jest w dalszej części pracy.



Rys. 6.3.3.20 Zestawienie charakterystyk mediany błędów dopasowania dla filtrów o różnych długościach


W trakcie analizy danych z symulowanych pomiarów zauważono, że charakterystyka błędu dopasowania obrazów dla ujemnych ΔL wartości jest nieliniowa i można na niej rozróżnić dwa różne zakresy. Pierwszy zakres ma charakter wykładniczy, który można opisać wielomianem drugiego rzędu wyznaczonym dla charakterystyki dodatniego błędu parametru L filtra Wienera. Drugi zakres charakteryzuje się przebiegiem, który można opisać równaniem różniczkowym drugiego rzędu. W zakresie tym można również wyróżnić asymptotę. Wartość asymptoty w ujemnym zakresie ΔL zmienia się w odniesieniu do różnych wartości rozmycia L . Odróżnia to zakres ujemny od dodatniego, gdzie wyznaczono analogiczną funkcję przyrastającą do wartości błędów maksymalnych otrzymywanych w całym badaniu. W pierwszym etapie wyznaczono aproksymatywne wartości funkcji dla charakterystyk odniesionych do rozmycia o długościach 10, 15, 20, 25, 30, a na Rys. 6.3.3.21-Rys. 6.3.3.23 przedstawiono otrzymane wyniki dla obciążonych błędem filtrów o długościach 10, 20 i 30.

Zakłada się, że charakterystyka w drugim zakresie będzie aproksymowana zależnością tożsamą z (135). W pierwszej kolejności wyznaczono wielomiany aproksymujące funkcje oscylacyjnie tłumione niezależnie dla każdej długości filtra. Wyniki uzyskanych funkcji aproksymujących przedstawiają Rys. 6.3.3.21-Rys. 6.3.3.23. Natomiast wartości współczynników wielomianów zawarte są Tabela 6.3.3.2.


Tabela 6.3.3.2 Tabela współczynników funkcji oscylacyjnych filtrów dla ujemnego zakresu ΔL

L	a_0	a_1	a_2	a_3
10	0,76	0.94	1.604	0.18
15	0,28	0.92	1,13	0,85
20	0,25	0,72	1,74	3,81


25	0,59	1,21	1,48	5.66
30	0,16	0,89	1,79	8,44



Rys. 6.3.3.21 Funkcja aproksymująca E_m dla ujemnych wartości ΔL odniesionych do pierwotnego rozmycia o wartości 10



Rys. 6.3.3.22 Funkcja aproksymująca E_m dla ujemnych wartości ΔL odniesionych do pierwotnego rozmycia o wartości 20



Rys. 6.3.3.23 Funkcja aproksymująca E_m dla ujemnych wartości ΔL odniesionych do pierwotnego rozmycia o wartości 30

Na podstawie wartości maksimum charakterystyk błędów dopasowania obrazów przedstawionych na Rys. 6.3.3.21-Rys. 6.3.3.23 stwierdza się, że ich okres można w przybliżeniu opisać zależnością:

$$T \cong 0,4 * L \quad (145)$$

Natomiast położenie pierwszego maksimum funkcji przybliża zależność:

$$\arg \max (E_m) \cong 0,27 * L \quad (146)$$

Wartość asymptoty natomiast jest równa:

$$\lim_{\Delta L \rightarrow L} E_m(\Delta L) \cong \text{med}(E_R(L)), \quad (147)$$

gdzie E_R – oznacza wartość mediany błędu dopasowania dla obrazu rozmytego

Postać wielomianu uogólnionej funkcji aproksymującej charakterystyki oscylacyjne w ujemnym zakresie uzyskano z wykorzystaniem przytoczonej wcześniej w pracy metody aproksymacji Gaussa-Newtona. Uwzględniając zidentyfikowane parametry pierwszego maksimum funkcji oraz ich okresu możliwe jest określenie punktu zmiany opisu charakterystyki błędu z wykładniczej na oscylacyjną. Wykorzystano do tego następujące zależności opisujące człon inercyjny drugiego rzędu:


$$\omega_d = \frac{2\pi}{0,4 * L} \quad (148)$$

$$\omega_d = \omega_n \sqrt{1 - \zeta^2} \quad (149)$$


$$\omega_{dnorm} = 15,71, \quad (150)$$

$$t_{0norm} = \frac{\pi}{\omega_d} = 0.2. \quad (151)$$

Po znormalizowaniu względem asymptot i długości filtrów rozpatrywane funkcje tworzą skupioną strukturę, co przedstawiono na Rys. 6.3.3.24. Wyznaczona postać funkcji aproksymującej funkcje znormalizowane przedstawiona jest na Rys. 6.3.3.25



Rys. 6.3.3.24 Znormalizowana charakterystyka mediany błędu dopasowania obrazów uogólniająca funkcje oscylacyjne w ujemnym zakresie wartości ΔL



Rys. 6.3.3.25 Funkcja aproksymująca znormalizowany zbiór punktów tworzących charakterystyki opisujące oscylacje w ujemnym zakresie wartości ΔL

Wykres funkcji uzyskanej w procesie aproksymacji można opisać zależnością:

$$E_-^G(\Delta L) = \left(1 - \frac{e^{-a_0|\Delta L|}}{a_2} \cos(a_1|\Delta L|)\right) a_3 \quad (152)$$


Wartość współczynników $a_0, \dots, a_3$ funkcji przedstawia Tabela 6.3.3.3.

Tabela 6.3.3.3 Wartość współczynników funkcji $E(\Delta L_-^G)$


a_0	a_1	a_2	a_3
5,3632	-6,7877	1,1017	0,964

Błąd średniokwadratowy dla aproksymowanej uogólnionej i znormalizowanej postaci rozpatrywanych charakterystyk wynosi 0,16. Normalizacja sprowadza wartość asymptoty błędu dopasowania oraz długości filtra do wartości 1.

Na Rys. 6.3.3.26 Rys. 6.3.3.27 przedstawiono zbiorcze wyniki symulacji wpływu błędu estymat prędkości i kierunku ruchu, wykorzystane w jądrze filtra Wienera na medianę błędu dopasowania obrazów z wykorzystaniem metody RANSAC. Ze względu na duży zakres zmian amplitudy błędu dopasowania na wykresach zdecydowano się przedstawić ww. błąd w skali decybelowej.




Rys. 6.3.3.26 Charakterystyka mediany błędu dopasowania obrazów w funkcji $\Delta\theta$ i ΔL




Rys. 6.3.3.27 Charakterystyka mediany błędu dopasowania obrazów w funkcji $\Delta\theta$ i ΔL – rzut z góry

Na Rys. 6.3.3.28 i Rys. 6.3.3.29 przedstawiono zbiorcze wyniki symulacji wpływu błędu estymat prędkości i kierunku ruchu, wykorzystane w jądrze filtra Wienera na średni błąd dopasowania obrazów z wykorzystaniem metody RANSAC. Ze względu na duży zakres zmian amplitudy błędu dopasowania na wykresach zdecydowano się przedstawić ww. błąd w skali decybelowej.



Rys. 6.3.3.28 Charakterystyka średniego błędu dopasowania obrazów w funkcji $\Delta\theta$ i ΔL



Rys. 6.3.3.29 Charakterystyka średniego błędu dopasowania obrazów w funkcji $\Delta\theta$ i ΔL – rzut z góry

Na podstawie badań stwierdza się, że charakterystyka przedstawiona na Rys. 6.3.3.26 jest symetryczna względem zera dla osi przedstawiającej ujemne wartości błędu $\Delta\theta$.

Znajomość rozkładu funkcji $E(\Delta L \text{ i } \Delta\theta)$ błędu dopasowania ww. obrazów, a także wariancji estymat parametrów $\hat{L}, \hat{\theta}$ filtra Wienera oznaczonych jako $\sigma_L^2, \sigma_\theta^2$ umożliwia minimalizację otrzymywanego błędu dopasowania zgodnie z zależnością:

$$\arg \min_{x,y} \Gamma(x,y) := \arg \min_{x,y} \left(\iint_{x=-a-d, y=-b}^{x=a+d, y=b} f(x,y) dx dy \right), \quad (153)$$

gdzie a- połóż wielka elipsy błędu, b- połóż mała elipsy błędu, d-zadany margines obszaru minimalizacji.

Zakłada się, że: $\Delta L \rightarrow x \in \mathbb{R}$, $\Delta\theta \rightarrow y \in \mathbb{R}$, $a=\sigma_L$, $b=\sigma_\theta$

Parametr d pozwala na wyznaczenie nowej długości filtra L_{opt} , która będzie suboptymalna dla aktualnych niepewności estymat $\hat{L}, \hat{\theta}$ uzyskiwanych na podstawie działania układu nawigacji wizualno-bezwładnościowej oraz parametrów układu akwizycji obrazu.

Funkcja $f: \mathbb{R}^2 \rightarrow \mathbb{R}$ określona jest charakterystyką wyznaczoną dla $E: \mathbb{R}^2 \rightarrow \mathbb{R}$ dla obszaru wewnątrz elipsy błędu. Natomiast poza obszarem elipsy przyjmuje wartość 0, co można przedstawić w postaci:

$$f(x,y) = \begin{cases} med(E_m(\Delta L, \Delta\theta)) & \text{dla } \left(\frac{x-x_0}{a}\right)^2 + \left(\frac{y-y_0}{b}\right)^2 \leq 1 \\ 0 & \text{dla } \left(\frac{x-x_0}{a}\right)^2 + \left(\frac{y-y_0}{b}\right)^2 > 1 \end{cases} \quad (154)$$

Punkt (x_0, y_0) dla funkcji $f(x, y)$ stanowi środek elipsy, która w trakcie procesu optymalizacji jest przesuwana po dwuwymiarowej charakterystyce błędu dopasowania.

Wartości wariancji kierunku oraz modułu prędkości platformy uzyskiwane w kolejnych chwilach działania układu nawigacji wizualno-bezwładnościowej pozwalają na wyznaczenie maksymalnych błędów ΔL i $\Delta \theta$ na podstawie zależności (90). Ze względu na niesymetryczny rozkład błędu dopasowania dla ujemnych i dodatnich wartości ΔL zakłada się możliwość zmiany estymowanej wartości modułu prędkości branej jako podstawę do wyliczania parametrów filtra Wienera. Filtr ten ma za zadanie minimalizację wpływu rozmycia na błędy dopasowania. Zadanie to może być realizowane z różną skutecznością z pogorszeniem pierwotnego efektu włącznie, co oznacza, że uzyskiwany błąd dopasowania po filtracji może być większy niż przed jej zastosowaniem.

Wartość L długości filtra wyznaczana jest na podstawie minimalizacji dwuwymiarowej całki z funkcji zależności (153) zmiennych $\Delta L, \Delta \theta$ w obszarze powiększonym o pewien margines d .

Zakłada się, że czas akwizycji kamery, wysokość i prędkość lotu oraz rozdzielczość obrazu są stałe w czasie dla rozpatrywanego problemu.

W tabelach 1-10 przedstawiono wyniki całki liczonej na podstawie zależności ((153) dla różnych wariancji zmiennych $\Delta L, \Delta \theta$ oraz parametru $d \in (-1, 1), d \in \mathbb{N}$. Całka obliczana jest numerycznie, metodą prostokątów z wykorzystaniem dyskretnych danych opisujących charakterystykę przedstawioną na Rys. 6.3.3.26.

Wartość referencyjna stanowiąca dodatkowe kryterium oceny efektywności całego procesu optymalizacji uzyskiwana jest na podstawie następującej zależności:

$$\Gamma_{ref}(x, y) = \iiint_{x=-a, y=-b}^{x=a, y=b} f_{ref}(x, y) dx dy \quad (155)$$

$$f_{ref}(x, y) = \begin{cases} med(E_m(L)) & dla \left(\frac{x-x_0}{a} \right)^2 + \left(\frac{y-y_0}{b} \right)^2 \leq 1 \\ 0 & dla \left(\frac{x-x_0}{a} \right)^2 + \left(\frac{y-y_0}{b} \right)^2 > 1 \end{cases} \quad (156)$$

Punkt (x_0, y_0) dla funkcji $f_{ref}(x, y)$ stanowi środek elipsy. Funkcja $med(E_m(L))$ charakteryzuje medianę błędu dopasowania dwóch obrazów po rozmyciu filtrem o zadanej wartości L . Błąd ten charakteryzuje się stałym rozkładem dla całej płaszczyzny rozpiętej na punktach $x, y \in R$. Z tego względu możliwe jest przyjmowanie dowolnego punktu (x_0, y_0) .

Tabela 6.3.3.4 Wynik całki z zależności (153) dla $\sigma_x^2 = 1, \sigma_y^2=1$;

(x_0, y_0)	$\Gamma(x, y)$	$\mu(\Gamma(x, y))$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	1.8669	0,3734	16.4500	3,29
(0,0)	0.8659	0,1732		
(1,0)	1.8699	0,3740		

Tabela 6.3.3.5 Wynik całki z zależności (153) dla $\sigma_x^2 = 2, \sigma_y^2=1$;

(x_0, y_0)	$\Gamma(x, y)$	$\mu(\Gamma(x, y))$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	4.8504	0.6929	23.0300	3,29
(0,0)	2.5510	0.3644		
(1,0)	4.2024	0.6003		

Tabela 6.3.3.6 Wynik całki z zależności (153) dla $\sigma_x^2 = 3, \sigma_y^2=1$;

(x_0, y_0)	$\Gamma(x, y)$	$\mu(\Gamma(x, y))$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	10,1059	1,1229	29,61	3,29
(0,0)	7,3032	0,8115		
(1,0)	9,7895	1,0877		

Tabela 6.3.3.7 Wynik całki z zależności (153) dla $\sigma_x^2 = 4, \sigma_y^2=1$;

(x_0, y_0)	$\Gamma(x, y)$	$\mu(\Gamma(x, y))$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	16,45	1,49	36,19	3,29
(0,0)	16,46	1,50		
(1,0)	182,21	16,56		

Tabela 6.3.3.8 Wynik całki z zależności (153) dla $\sigma_x^2 = 5, \sigma_y^2=1$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	25,1065	42,77	1,93	3,29
(0,0)	186,6519		14,95	
(1,0)	190,4702		15,55	

Tabela 6.3.3.9 Wynik całki z zależności (153) dla $\sigma_x^2 = 1, \sigma_y^2=2$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	2,7262	23.0300	0,3895	3,29
(0,0)	1,2297		0,1757	
(1,0)	2,6929		0,3847	

Tabela 6.3.3.10 Wynik całki z zależności (153) dla $\sigma_x^2 = 2, \sigma_y^2=2$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	7.777	42,77	0,5982	3,29
(0,0)	4.2609		0,3278	
(1,0)	7.0857		0,5451	

Tabela 6.3.3.11 Wynik całki z zależności (153) dla $\sigma_x^2 = 3, \sigma_y^2=2$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	18.5644	62,51	0.9771	3,29
(0,0)	12.6781		0.6673	
(1,0)	16.9425		0.8917	

Tabela 6.3.3.12 Wynik całki z zależności (153) dla $\sigma_x^2 = 4, \sigma_y^2=2$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	35,1048	82,25	1,4042	3,29
(0,0)	30,29.11		1.2116	
(1,0)	203,3439		8,1338	

Tabela 6.3.3.13 Wynik całki z zależności (153) dla $\sigma_x^2 = 5, \sigma_y^2=2$;

(x_0, y_0)	$\Gamma(x, y)$	$\Gamma_{ref}(x, y)$	$\mu(\Gamma(x, y))$	$\mu(\Gamma_{ref}(x, y))$
(-1,0)	55,9909	101,99	1,8062	3,29
(0,0)	224,8157		7,2521	
(1,0)	510,5036		17,0168	

W większości przebadanych przypadków położeniem optymalnym jest pierwotny punkt $(x_0, y_0) = (0,0)$. Jednak w rozpatrywanych dwóch przypadkach o dużej wariancji tj. $\sigma_x^2=5$ oraz jednym z wariancją $\sigma_x^2=4$ położeniem korzystniejszym jest $(x_0, y_0) = (-1,0)$. Przypadki te potwierdzają możliwość optymalizacji parametrów filtru Wienera dla danych wejściowych w postaci estymowanych zmiennych losowych opisujących wektor ruchu platformy latającej. Kryterium optymalizacji stanowi minimum z zależności (153).

Ostateczna postać ogólnego opisu mediany błędu dopasowania obrazów przed i po filtracji usuwającej rozmycie w funkcji zmiennych $\Delta L, \Delta \theta$ wynikających z oszacowania wektora prędkości $\hat{V}$, w układzie nawigacji ma postać:

$$E_m(L, \Delta L, \Delta \theta) = \quad (157)$$

$$= \begin{cases} a_8 L \left(\frac{\Delta L}{\Delta L_{pg}} \right)^2 + E_m(L, \Delta \theta) & \Delta L_{pd} \leq \Delta L \leq \Delta L_{pg} \\ a_8 L + E_m(L, \Delta \theta) + \frac{E_{max} - E_m(L, \Delta \theta)}{E_{max}} \left(1 - \frac{e^{-a_0(\Delta L - \Delta L_{pg})}}{a_2} \cos(a_1(\Delta L - \Delta L_{pg})) \right) a_3 & dla \Delta L > \Delta L_{pg} \\ a_8 L \left(\frac{\Delta L_{pd}}{\Delta L_{pg}} \right)^2 + E_m(L, \Delta \theta) + (E_R(L) - E_m(L, \Delta \theta)) \left(1 - \frac{e^{-a_4|\Delta L - \Delta L_{pd}|}}{a_6} \cos(a_5|\Delta L - \Delta L_{pd}|) \right) a_7 & dla \Delta L < \Delta L_{pd} \end{cases}$$

Wartość współczynników $a_0, \dots, a_8$ wyznaczonej funkcji przedstawia Tabela 6.3.3.14.

Tabela 6.3.3.14 Wartość współczynników funkcji $E_m(L, \Delta L, \Delta \theta)$

a_0	a_1	a_2	a_3	a_4	a_5	a_6	a_7	a_8
0,4788	0,8496	0,9813	367,8237	5,3632	-6,7877	1,1017	0,964	0,2975

$$\Delta L_{pd} = -0,2L \quad (158)$$

$$\Delta L_{pg} = f_{pp}(L, \Delta \theta) + 0,1L + 7 \quad (159)$$

$$f_{pp}(L, \Delta \theta) = -0.03478 L \Delta \theta \quad (160)$$

$$E_{max} = 400 \quad (161)$$

$$E_m(L, \Delta \theta) = \begin{cases} 0,0059(\Delta \theta)^2 - 0.0231\Delta \theta + 0.0850 & dla \Delta \theta \neq 0 \\ 0 & dla \Delta \theta = 0 \end{cases} \quad (162)$$

7. PODSUMOWANIE

Problem badawczy związany jest z dwoma zagadnieniami wpisującymi się w temat dysertacji. Pierwszy z nich związany jest z wpływem zjawiska rozmycia obrazu na dokładność określania położenia obiektu nawigacji przy wykorzystaniu lokalnych cech oraz filtracji Wienera. Drugi z wpływem obserwacji ruchomych obiektów w przestrzeni pomiędzy obiektem nawigacji oraz obserwowanym terenem na dokładność określania położenia obiektu nawigacji.

Dostępne w literaturze algorytmy przetwarzania obrazów, które są rozpatrywane w pracy, w zastosowaniu do nawigacji wizualnej obiektów szybkich, tj. takich które powodują rozmycie obrazu degradujące dokładność nawigacji, mogą zostać zmodyfikowane w taki sposób, aby zminimalizować negatywny wpływ zakłóceń pochodzących od ww. rozmycia.

Rozpatrywane algorytmy nawigacji wizualno-bezwładnościowej platform latających, które są dostępne w literaturze, narażone są na zwiększenie błędu określania położenia w wyniku obserwacji ruchomych obiektów w przestrzeni pomiędzy obiektem nawigacji i obserwowanym terenem. W pracy zaproponowano autorskie rozwiązanie sprzętowo-programowe, które zmniejsza wpływ ww. zjawiska na uzyskiwaną dokładność określania położenia w układzie nawigacji. W proponowanym rozwiązaniu dane i sygnały dostarczające informacji z kamery, układu bezwładnościowego oraz wysokościomierza laserowego przetwarzane są w oparciu o opracowany model matematyczny.

Obecnie możliwa jest implementacja coraz bardziej dokładnych wersji algorytmów wizyjnych. Czas realizacji tych algorytmów na dostępnych procesorach jest jednak czynnikiem ograniczającym ich wykorzystanie w zastosowaniach nawigacyjnych dla szybkich platform latających. W przypadku tych zastosowań konieczne jest podejście zapewniające konsensus pomiędzy zakładaną dokładnością obliczeń, wynikającą m.in. z liczby śledzonych cech obrazowych, a czasem realizacji procesu. Większość przeanalizowanych na podstawie literatury rozwiązań bazuje na numerycznych metodach optymalizacji, które wymagają wielu iteracji dla uzyskania użytecznych wyników pozwalających na nawigację z dokładnością zbliżoną do nawigacji satelitarnej. Stąd liczba cech śledzonych w algorytmach wizyjnych jest niewielka w stosunku do typowej liczby cech możliwych do wykrycia na obrazach terenu. Wiąże się to z podatnością tych algorytmów na zakłócenia. Istotna jest zwłaszcza wrażliwość algorytmów wizyjnych układów z pojedynczą kamerą na zakłócenia w strukturze obserwowanej sceny w postaci ruchomych obiektów pojawiających się w kadrze. Ze względu na ruch kamery oraz potencjalny ruch obiektów w terenie w pracy zaproponowano rozwiązanie zwiększające odporność układów wizualno-bezwładnościowych na ww. zakłócenia. Przedstawiona w pracy metoda odnosi się do terenów względnie płaskich i pozwala na użycie wysokościomierzy, które są zazwyczaj tańsze od radarów i lidarów. Nawet punktowa znajomość głębi sceny oraz dostęp do aktualnie estymowanych w układzie wizualno-bezwładnościowym parametrów ruchu obiektu pozwala na filtrację cech obrazowych w odniesieniu do prędkości obserwowanych na aproksymowanej płaszczyźnie obiektów i prędkości samego układu obserwacji. Autorski algorytm oparty o rozszerzony filtr Kalmana

pozwała na estymowanie odległości do terenu z uwzględnieniem możliwości występowania zakłóceń w postaci elementów pokrycia terenowego, które ze względu na swoją wysokość są odrzucane.

Kamera rozpatrywanego systemu nawigacyjnego rejestruje dane obrazowe w innym czasie i w odmiennych warunkach środowiskowych od warunków występujących w trakcie akwizycji obrazu stanowiącego wzorzec terenowy. Implikuje to konieczność stosowania algorytmów skutecznych przy bardzo niekorzystnych uwarunkowaniach sygnału do szumu. W pracy zdecydowano się przeanalizować w tym aspekcie metody statystyczne, które pozwalają na lokalne dopasowania możliwie podobnych do siebie elementów obrazu. Rozpatrywany algorytm RANSAC został poddany badaniu ukierunkowanemu na ocenę dokładności dopasowania dwóch obrazów przy występowaniu zakłócenia związanego z ruchem platformy z kamerą względem obserwowanego terenu. Zjawisko to ma negatywny wpływ na liczbę wykrywanych na obrazie cech charakterystycznych stanowiących populację, na bazie której wyznaczane jest dopasowanie oraz na jakość samego dopasowania. Z tego względu zdecydowano się na zastosowanie w pracy algorytmu pozwalającego na rekonstrukcję obrazu, który minimalizuje ww. negatywny efekt rozmycia. Zdecydowano się na wyznaczanie parametrów funkcji PSF stanowiących podstawę filtru Wienera na podstawie estymowanych parametrów kinematycznych platformy. Ze względu na występujące błędy estymacji tych parametrów możliwe jest ograniczenie skuteczności filtracji i wprowadzanie na obrazie zmian, które degradują skuteczność statystycznego algorytmu dopasowania. W pracy przeanalizowano wpływ estymacji parametrów wektora prędkości platformy na ww. aspekty, co jest elementem innowacyjnym pracy. Wnioski z badań potwierdzają zasadność stosowania algorytmu rekonstrukcji obrazu, przy określonych granicznych wartościach błędów estymacji parametrów ruchu platformy z kamerą.

Ze względu na ograniczone możliwości organizacyjne realizacji przedstawionych badań w warunkach rzeczywistych w pracy wielokrotnie posłużono się badaniami symulacyjnymi. Wyniki tych badań odnoszono do wybranych przypadków zarejestrowanych podczas badań w warunkach rzeczywistych. W ten sposób uzyskano możliwość formułowania uogólnionych wniosków dotyczących rozpatrywanych problemów badawczych.

W pracy sformułowano autorski model opisu wpływu błędów przyjętych parametrów filtru Wienera na jakość dopasowania rozumianą jako średnią odległość cech na dwóch obrazach. Model ten pozwala na analizę zagadnienia dla różnych niepewności pomiarowych oraz różnych wartości rozmycia pierwotnego.

Wykorzystując wyznaczoną charakterystykę na podstawie danych z symulacji oraz wyznaczonego modelu zdecydowano się przedstawić metodę minimalizacji negatywnego wpływu ww. błędów na jakość dopasowania. Autorska metoda pozwala w procesie iteracyjnym na wyznaczenie najkorzystniejszych parametrów filtru Wienera dysponując informacją o wariancji danych wejściowych.

Wyniki badań potwierdzają realizację zarówno celów pomocniczych, jak również postawionej hipotezy.

8. BIBLIOGRAFIA

- [1] Boozer DD, Fellerhoff JR. Terrain-Aided Navigation Test Results in the AFTI/F-16 Aircraft. *Navigation – Journal of The Institute of Navigation*. 1988;35(2):161-175. DOI:10.1002/j.2161-4296.1988.tb00949.x
- [2] Enns R. Terrain-aided navigation using the Viterbi algorithm. *Journal of Guidance, Control, and Dynamics*. 1995;18(6):1444-1449. DOI:10.2514/3.21566
- [3] Han Y, Wang B, Deng Z, Fu M. An improved TERCOM-based algorithm for gravity-aided navigation. *IEEE Sensors Journal*. 2016;16(8):2537-2544. DOI: 10.1109/JSEN.2016.2518686
- [4] Hua Z, Xiulin H. A height-measuring algorithm applied to TERCOM radar altimeter. In: *Proc. of the 3rd International Conference on Advanced Computer Theory and Engineering (ICACTE)*; 20-22 August 2010; Chengdu (China). New York: IEEE, 2010. p. (V5-43)-(V5-46). DOI:10.1109/ICACTE.2010.5579215
- [5] Wei E, Dong C, Liu J, Tang S. An improved TERCOM algorithm for gravity-aided inertial navigation system. *Journal of Geomatics*. 2017;42(6):29-31. DOI:10.14188/j.2095-6045.2016190
- [6] Naimark L, Webb H, Wang T. Vision-Aided Navigation for Aerial Platforms. In: *Proc. of the ION 2017 Pacific PNT Meeting*; 1-4 Mai 2017; Honolulu (USA). Manassas: ION, 2017. p. 70-76. DOI: 10.33012/2017.15051
- [7] Yang C, Vadlamani A, Soloviev A, Veth M, Taylor C. Feature matching error analysis and modeling for consistent estimation in vision-aided navigation. *Navigation*. 2018;65:609-628. DOI:10.1002/navi.265628
- [8] Carr JR, Sobek JS. Digital Scene Matching Area Correlator (DSMAC). In: *Proc. of 24th Annual Technical Symposium, SPIE 0238, Image Processing for Missile Guidance*; 23 December 1980; San Diego (USA). Bellingham: SPIE, 1980. DOI:10.1117/12.959130
- [9] Irani GB, Christ JP. Image processing for Tomahawk scene matching. *Johns Hopkins APL Technical Digest*. 1994;15(3):250-264.
- [10] Turek P, Bużantowicz W. Image matching constraints in unmanned aerial vehicle terrain-aided navigation. In: *Proc. of the 2nd Aviation and Space Congress*; 18-20 September 2019; Cedzyna (Poland). p. 206-208.
- [11] Brown LG. A survey of image registration techniques. *ACM Computing Surveys*. 1992;24(4):325-376. DOI: 10.1145/146370.146374
- [12] Zitová B, Flusser J. Image registration methods: A survey. *Image and Vision Computing*. 2003;21(11):977-1000. DOI:10.1016/S0262-8856(03)00137-9
- [13] Bouchiha R, Besbes K. Automatic Remote-Sensing Image Registration Using SURF. *International Journal of Computer Theory and Engineering*. 2013;5(1):88-92. DOI:10.7763/IJCTE. 2013.V5.653
- [14] Kashif M, Deserno TM, Haak D, Jonas S. Feature description with SIFT, SURF, BRIEF, BRISK, or FREAK? A general question answered for bone age assessment. *Computers in Biology and Medicine*. 2016;68:67-75. DOI: 10.1016/j.combiomed.2015.11.006
- [15] Lindeberg T. Scale-space theory: A basic tool for analysing structures at different scales. *Journal of Applied Statistics*. 1994;21(2):224-270. DOI:10.1080/01676369408839296
- [16] Lowe DG. Distinctive Image Features from Scale-Invariant Keypoints. *International Journal of Computer Vision*. 2004;60:91-110. DOI:10.1023/B:VISI.0000029664.99615.94
- [17] Bay H, Ess A, Tuytelaars T, Van Gool L. Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*. 2008;110(3):346-359. DOI: 10.1016/j.cviu.2007.09.014
- [18] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features. In: *Proc. of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*; 8-14 December 2001; Kauai (USA). p. (I-511)-(I-518). DOI:10.1109/CVPR.2001.990517
- [19] Rublee E, Rabaud V, Konolige K, Bradski G. ORB: An efficient alternative to SIFT or SURF. In: *Proc. of the 13th International Conference on Computer Vision*; 6-13 November 2011; Barcelona (Spain). p. 2564-2571. DOI:10.1109/ICCV.2011.6126544
- [20] Rosten E, Drummond T. Machine Learning for High-Speed Corner Detection. In: Leonardis A, Bischof H, Pinz A, editors. *Proc. of the 9th European Conference on Computer Vision 2006 – Lecture Notes in Computer Science*, vol. 3951. Berlin-Heidelberg: Springer; 2006. p. 430-443. DOI: 10.1007/1174402334
- [21] McIlroy P, Rosten E, Taylor S, Drummond T. Deterministic sample consensus with multiple match hypotheses. In: *Proc. of the 21st British Machine Vision Conference*; 31 August– 3 September 2010; Aberystwyth (UK). pp. 111.1-111.11. DOI: 10.5244/C.24.111

- [22] Calonder M, Lepetit V, Strecha C, Fua P. BRIEF: Binary Robust Independent Elementary Features. In: Daniilidis K, Maragos P, Paragios N, editors. Proc. of the 11th European Conference on Computer Vision 2010 –Lecture Notes in Computer Science, vol. 6314. Berlin-Heidelberg: Springer; 2010. p. 778-792. DOI:10.1007/978-3-642-15561-156
- [23] Alcantarilla PF, Bartoli A, Davison AJ. KAZE Features. In: Fitzgibbon A, Lazebnik S, Perona P, Sato Y, Schmid C, editors. Proc. of the 13th European Conference on Computer Vision 2010 –Lecture Notes in Computer Science, vol. 7577. Berlin-Heidelberg: Springer; 2012. p. 214-227. DOI:10.1007/978-3-642-33783-316
- [24] Perona P, Malik J. Scale-space and edge detection using anisotropic diffusion. IEEE Transactions on Pattern Analysis and Machine Intelligence. 1990;12(7):629-639. DOI:10.1109/34.56205
- [25] Weickert J. Efficient image segmentation using partial differential equations and morphology. Pattern Recognition. 2001;34:1813–1824. DOI:10.1016/S0031-3203(00)00109-6
- [26] Charbonnier P, Blanc-Feraud L, Aubert G, Barlaud M. Deterministic edge-preserving regularization in computed imaging. IEEE Transactions on Image Processing. 1997;6(2): 298-311. DOI: 10.1109/83.551699
- [27] Matas J, Chum O, Urban M, Pajdla T. Robust wide baseline stereo from maximally stable extremal regions. In: Proc. of the 13th British Machine Vision Conference; 2-5 September 2002; Cardiff (UK). pp. 384-396.
- [28] Chaumette F. Image moments: a general and useful set of features for visual servoing. IEEE Transactions on Robotics. 2004;20(4):713-723. DOI:10.1109/TRO.2004.829463
- [29] Fischler MA, Bolles RC. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. Communications of the ACM. 1981;24(6):381–395.
- [30] Wang Z, Bovik AC. Mean squared error: love it or leave it?. IEEE Signal Processing Magazine. 2009;26(1): 98-117. DOI: 10.1109/MSP.2008.930649
- [31] Wang Z, Bovik AC, Sheikh HR, Simoncelli EP. Image quality assessment: from error visibility to structural similarity. IEEE Transactions on Image Processing. 2004;13(4):600-612
- [32] Hore A, Ziou D. Image quality metrics: PSNR vs. SSIM. In: Proc. of the 20th IAPR International Conference on Pattern Recognition; 23-26 August 2010; Istanbul (Turkey). p. 2366-2369. DOI: 10.1109/ICPR.2010.579
- [33] D. Weber, C. Gühmann and T. Seel, "Neural Networks Versus Conventional Filters for Inertial-Sensor-based Attitude Estimation," 2020 IEEE 23rd International Conference on Information Fusion (FUSION), 2020, pp. 1-8, doi: 10.23919/FUSION45008.2020.9190634
- [34] S Madgwick, "An efficient orientation filter for inertial and inertial/magnetic sensor arrays," Report x-io and University of Bristol (UK), vol. 25, pp. 113-118.
- [35] Oh, Juhyun; Sung, Chang-Ky; Lee, Jungshin; Lee, Sang W.; Lee, Sang J.; Yu, Myeong-Jong. 2019. "Accurate Measurement Calculation Method for Interferometric Radar Altimeter-Based Terrain Referenced Navigation" Sensors 19, no. 7: 1688, doi: 10.3390/s19071688
- [36] W. y. Kong, G. K. Egan and T. Cornall, "Feature Based Navigation for UAVs," 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2006, pp. 3539-3543, doi: 10.1109/IROS.2006.281640.
- [37] O. Yakimenko and R. Decker, "On the development of an image-matching navigation algorithm for aerial vehicles," 2017 IEEE Aerospace Conference, 2017, pp. 1-9, doi: 10.1109/AERO.2017.7943742.
- [38] H. -m. Chen, Z. Xiong, R. Wang and J. -y. Liu, "Research on scheme and algorithm of high-precision fault-tolerant integrated navigation for HALE UAV," 2010 3rd International Symposium on Systems and Control in Aeronautics and Astronautics, 2010, pp. 768-773, doi: 10.1109/ISSCAA.2010.5632218.
- [39] Chen Zhao and Jiaqi Yang and Yang Xiao and Zhiguo Cao, "Comparative evaluation of 2D feature correspondence selection algorithms", Journal of Latex Class Files, 2015, vol 14, no. 8.
- [40] P. Turek, S. Grzywiński, and W. Bużantowicz, 'Selected Issues and Constraints of Image Matching in Terrain-Aided Navigation: A Comparative Study', Artificial Intelligence. IntechOpen, Sep. 22, 2021. doi: 10.5772/intechopen.95039.
- [41] Z. Huang, X. Tang, S. Zou, Z. Huang, L. Li and J. Shang, "Image Tracking of Rotating Scene Based on Fusion of MEMS-IMU Data and Vision Data", IOP Conference Series: Materials Science and Engineering, Volume 612, doi: 10.1088/1757-899X/612/4/042051.
- [42] M. Brossard, S. Bonnabel, A. Barrau, "Unscented Kalman Filter on Lie Groups for Visual Inertial Odometry", IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) 2018, Oct 2018, Madrid, Spain., hal-01735542v2.
- [43] T. Qin, P. Li, S. Shen, "Vins-mono: A robust and versatile monocular visual-inertial state estimator", IEEE Transactions on Robotics 34.4 (2018): 1004-1020. DOI:10.1109/tro.2018.2853729.

- [44] K. Ram, C. Kharyal, S. S. Harithas, K. M. Krishna, "RP-VIO: robust plane-based visual-inertial odometry for dynamic environments", 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS) (pp. 9198-9205). IEEE.
- [45] C. Debeunne and D. Vivet, "A Review of Visual-LiDAR Fusion based Simultaneous Localization and Mapping," *Sensors*, vol. 20, no. 7, p. 2068, Apr. 2020, doi: 10.3390/s20072068.
- [46] B. Garigipati, N. Strokina, R. Ghabcheloo, "Evaluation and comparison of eight popular Lidar and Visual SLAM algorithms:", 2022, 25th International Conference on Information Fusion (FUSION) (pp. 1-8). IEEE
- [47] Z. Sjanic and F. Gustafsson, "Simultaneous navigation and synthetic aperture radar focusing," in *IEEE Transactions on Aerospace and Electronic Systems*, vol. 51, no. 2, pp. 1253-1266, April 2015, doi: 10.1109/TAES.2015.120820.
- [48] H. Wang, C. Zhang, Y. Song, B. Pang, and G. Zhang, "Three-Dimensional Reconstruction Based on Visual SLAM of Mobile Robot in Search and Rescue Disaster Scenarios," *Robotica*, vol. 38, no. 2, pp. 350–373, 2020.
- [49] Taketomi, T., Uchiyama, H. & Ikeda, S. "Visual SLAM algorithms: a survey from 2010 to 2016", *IPST Compute Vis Appl* 9, 16 (2017), doi.org/10.1186/s41074-017-0027-2
- [50] B. D. Lucas and T. Kanade, "An iterative image registration technique with an application to stereo vision," in *Proceedings of the International Joint Conference on Artificial Intelligence*, Vancouver, BC, Canada, 1981, pp. 674–679
- [51] Z. Li, J. Wang, J. Gao, B. Li, and F. Zhou, "A Vondrak Low Pass Filter for IMU Sensor Initial Alignment on a Disturbed Base," *Sensors*, vol. 14, no. 12, pp. 23803–23821, Dec. 2014, doi: 10.3390/s141223803.
- [52] Y. Yin, J. Zhang, M. Guo, X. Ning, Y. Wang, and J. Lu, "Sensor Fusion of GNSS and IMU Data for Robust Localization via Smoothed Error State Kalman Filter," *Sensors*, vol. 23, no. 7, p. 3676, Apr. 2023, doi: 10.3390/s23073676.
- [53] G. de Alteriis et al., "Innovative Fusion Strategy for MEMS Redundant-IMU Exploiting Custom 3D Components," *Sensors*, vol. 23, no. 5, p. 2508, Feb. 2023, doi: 10.3390/s23052508.
- [54] W. Zhao, X. Sun, Y. Rong, J. Duan, J. Chen, L. Song, Q. Pan, "Optimization on the Precision of the MEMS-Redundant IMU Based on Adhesive Joint Assembly", *Mathematical Problems in Engineering*, vol. 2020, Article ID 8855141, 9 pages, 2020. doi.org/10.1155/2020/8855141
- [55] C. Forster, L. Carlone, F. Dellaert and D. Scaramuzza, "On-Manifold Preintegration for Real-Time Visual-Inertial Odometry," in *IEEE Transactions on Robotics*, vol. 33, no. 1, pp. 1-21, Feb. 2017, doi: 10.1109/TRO.2016.2597321.
- [56] J. Ribeiro-Gomes, J. Gaspar, A. Bernardino., "Event-based feature tracking in a visual inertial odometry framework", *Frontiers in Robotics and AI*, 2023, 10, 994488.
- [57] H. Longuet-Higgins, "A computer algorithm for reconstructing a scene from two projections", *Nature* 293, 133–135, 1981, doi.org/10.1038/293133a0.
- [58] J. Dereziński, „Algebry i grupy Liego”, Katedra Metod Matematycznych Fizyki Uniwersytet Warszawski, Warszawa, 31 marca 2022
- [59] 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.
- [60] Z. Zhang, „A flexible new technique for camera calibration.,” *IEEE Transactions on pattern analysis and machine intelligence*, pp. 1330-1334, 2000.
- [61] W. H. Richardson, "Bayesian-Based Iterative Method of Image Restoration". *Journal of the Optical Society of America*. 62 (1): 55–59, 1972, doi:10.1364/JOSA.62.000055
- [62] L. B. Lucy, "An iterative technique for the rectification of observed distributions". *Astronomical Journal*. 79 (6): 745–754., 1974, doi:10.1086/111605.
- [63] N. Wiener, "Extrapolation, Interpolation, and Smoothing of Stationary Time Series", New York: Wiley. , 1949, ISBN 978-0-262-73005-1.
- [64] D. P. Mitchell, A. N. Netravali, "Reconstruction filters in computer-graphics " *ACM SIGGRAPH International Conference on Computer Graphics and Interactive Techniques*. Vol. 22. pp. 221–228, August 1988. doi:10.1145/54852.378514. ISBN 0-89791-275-6.
- [65] B. Hu, L. Li, J. Qian, "Perceptual quality evaluation for motion deblurring", *IET Comput. Vis.*, 12: 796-805, 2018, doi.org/10.1049/iet-cvi.2017.0478
- [66] M. Eldib, M. Hegazy, Y. Mun, M. Cho, M. Cho, and S. Lee, "A Ring Artifact Correction Method: Validation by Micro-CT Imaging with Flat-Panel Detectors and a 2D Photon-Counting Detector," *Sensors*, vol. 17, no. 2, p. 269, Jan. 2017, doi: 10.3390/s17020269.

- [67] Y. Tian, J. Wang, J. Liu, and X. Guo, "Restoration of Spatially Variant Blurred Images with Wide-Field Telescope Based on Deep Learning," *Sensors*, vol. 23, no. 7, p. 3745, Apr. 2023, doi: 10.3390/s2307374.
- [68] M. Tico and M. Vehvilainen, "Estimation of motion blur point spread function from differently exposed image frames," 2006 14th European Signal Processing Conference, Florence, Italy, 2006, pp. 1-4.
- [69] A.Okabe, B. Boots, K.Sugihara, S. N. Chiu, "Spatial Tessellations: Concepts and Applications of Voronoi Diagrams -2nd Edition", September 2009, Wiley,- 696, ISBN: 978-0-470-31785-3
- [70] M. Burri, J. Nikolic, P. Gohl, T. Schneider, J. Rehder, S. Omari, M. Achtelik and R. Siegwart, The EuRoC micro aerial vehicle datasets, *International Journal of Robotic Research*, DOI: 10.1177/0278364915620033, early 2016
- [71] The EuRoC MAV Dataset - <https://projects.asl.ethz.ch/datasets/doku.php?id=kmavvisualinertialdatasets>