

LOTNICZA AKADEMIA WOJSKOWA

INSTYTUT NAVIGACJI

ROZPRAWA DOKTORSKA

**METODYKA OPRACOWANIA DANYCH POZYSKANYCH
Z NISKIEGO PUŁAPU NA POTRZEBY DETEKCJI
I KLASYFIKACJI WYBRANEJ GRUPY
PRZESZKÓD LOTNICZYCH**

Autor: mgr inż. Marta Lalak

Promotor: dr hab. inż. Damian Wierzbicki, prof. WAT

Dziedzina nauk inżynieryjno-technicznych
Dyscyplina naukowa: inżynieria lądowa, geodezja i transport

METODYKA OPRACOWANIA DANYCH POZYSKANYCH Z NISKIEGO PUŁAPU NA POTRZEBY DETEKCJI I KLASYFIKACJI WYBRANEJ GRUPY PRZESZKÓD LOTNICZYCH

Streszczenie

W pracy skupiono się na problematyce wykrywania i klasyfikacji przeszkód lotniczych w bliskim otoczeniu lotniska. Szczególną uwagę zwrócono na trudność w prawidłowym wykrywaniu niewielkich przeszkód lotniczych o wysmukłym i wydłużonym kształcie. Mimo, że istnieją zalecenia dotyczące technik zbierania danych o przeszkodach lotniczych, to wciąż rozwijane są algorytmy przetwarzania danych na potrzeby automatycznego wykrywania nietypowych przeszkód lotniczych, do których zaliczyć można obiekty o wysmukłym i wydłużonym kształcie. Dla uchwycenia tego rodzaju obiektów skala obrazu powinna być większa niż przy tradycyjnych lotach fotogrametrycznych, co zapewniają dane obrazowe z niskiego pułapu (z pułapu BSP). Niższa wysokość lotu BSP gwarantuje dużo większą skalę obrazu niż na zdjęciach lotniczych, a co za tym idzie możliwość uzyskania większej dokładności pozyskania danych. Główny problem badawczy przedstawiony w niniejszej rozprawie brzmi: jakie algorytmy przetwarzania danych pozyskanych z niskiego pułapu należy zastosować, aby wykryć i sklasyfikować nietypowe przeszkody lotnicze zgodnie z wymaganiami dokładnościowymi zawartymi w dokumentach EUROCONTROL i ICAO? Jako główny cel badań przyjęto opracowanie metod przetwarzania danych na potrzeby zbierania danych o przeszkodach lotniczych, w tym: opracowanie metody wyrównania jednoszeregowego bloku zdjęć pozyskanego z niskiego pułapu dla terenów niedostępnych, opracowanie metody podwyższenia dokładności pozycjonowania bezzałogowych statków powietrznych i produktów fotogrametrycznych oraz opracowanie metody automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych na podstawie gęstych chmur punktów i obrazów pozyskanych z niskiego pułapu. W ramach rozwiązania problemu badawczego opracowano autorski algorytm przetwarzania danych pozyskanych z niskiego pułapu na potrzeby zbierania danych o przeszkodach lotniczych, zgodnie z wymaganiami dokładnościowymi określonymi przez dokumenty EUROCONTROL i ICAO. Cel badań został osiągnięty poprzez: wykorzystanie punktów wiążących w procesie wyrównania jednoszeregowego bloku zdjęć, w oparciu o zmodyfikowaną metodę regresji liniowej; zastosowanie algorytmu metody SPP uwzględniającej produkty IGS dla podwyższenia dokładności pozycjonowania BSP wyposażonego w jednoczęstotliwościowy odbiornik GPS oraz poprzez wprowadzenie algorytmów automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych z użyciem gęstych chmur punktów oraz obrazów pozyskanych z niskiego pułapu. W oparciu o uzyskane wyniki badań stwierdzono, że opracowana metodyka pozwoliła na wykrycie przeszkód lotniczych z maksymalnymi różnicami pomiędzy otrzymanymi współrzędnymi (X, Y, Z), a współrzędnymi referencyjnymi wynoszącymi 0,05 m dla przeszkód lotniczych o wydłużonym kształcie oraz 0,7 m dla przeszkód lotniczych o wysmukłym kształcie. Otrzymane wyniki spełniają wymagania dokładnościowe.

Słowa kluczowe: przeszkody lotnicze, aerotriangulacja, metoda pozycjonowania kodowego SPP, detekcja, klasyfikacja, chmura punktów, BSP

METHODOLOGY OF DEVELOPMENT OF DATA OBTAINED FROM LOW ALTITUDE FOR THE PURPOSES OF DETECTION AND CLASSIFICATION OF A SELECTED GROUP OF AVIATION OBSTACLES

Abstract

The dissertation focuses on the problem of detection and classification of aviation obstacles in the close vicinity of the airport. Particular attention was paid to the difficulty of correctly detecting small aerial obstacles of slender and elongated shape. Although there are recommendations for aviation obstacle data collection techniques, data processing algorithms are still being developed for the automatic detection of atypical aviation obstacles, which include objects with a slender and elongated shape. To capture such objects, the image scale should be larger than in traditional photogrammetric flights, which is provided by image data from a low altitude (from the altitude of the UAV). The lower flight altitude of the UAV guarantees a much larger image scale than in aerial photography, and thus the possibility of greater data acquisition accuracy. The main research problem presented in this dissertation is: what algorithm for processing data acquired from the low altitude should be used to detect and classify atypical aviation obstacles in accordance with the accuracy requirements of EUROCONTROL and ICAO documents? The development of data processing methods for the collection of aviation obstacle data was adopted as the main objective of the research, including: the development of a method for adjustment a single-row block of images acquired from a low altitude for inaccessible areas, the development of a method for increasing the positioning accuracy of unmanned aerial vehicles and, as a result, photogrammetric products, and the development of a method for automatic detection and classification of atypical aviation obstacles on the basis of dense point clouds and images acquired from a low altitude. As part of the solution to the research problem, a proprietary algorithm was developed for processing data acquired from the low altitude for the collection of aviation obstacle data, in accordance with the accuracy requirements specified by EUROCONTROL and ICAO documents. The research goal was achieved by: the use of tie points in the adjustment process of a single-strip block of images, based on a modified linear regression method; the application of the SPP method algorithm taking into account IGS products for increasing the positioning accuracy of a UAV equipped with a single-frequency GPS receiver; and by introducing algorithms for automatic detection and classification of atypical aviation obstacles using dense point clouds and images acquired from a low altitude. Based on the results obtained, it was found that the developed methodology allowed the detection of aviation obstacles with maximum differences between the obtained coordinates (X, Y, Z) and the reference coordinates of 0.05 m for elongated-shaped obstacles and 0.7 m for slender-shaped obstacles. The obtained results conform to the accuracy requirements.

Key words: aviation obstacles, aerotriangulation, SPP coded positioning method, detection, classification, point cloud, UAV

SPIS TREŚCI

WYKAZ UŻYTYCH SKRÓTÓW WRAZ Z OBJAŚNIENIAMI.....	7
1. WPROWADZENIE	9
2. CYKL PUBLIKACJI. METODYKA BADAŃ, WYNIKI, DYSKUSJA I ANALIZA OTRZYMANYCH WYNIKÓW	21
2.1. METODYKA PRZETWARZANIA JEDNOSZEREGOWYCH BLOKÓW ZDJĘĆ Z REDUKCJĄ I OPTYMALIZACJĄ LICZBY FOTOPUNKTÓW W FOTOGRAMETRII BSP [Publikacja 1].....	24
2.1.1. Metodyka wyrównania jednoszeregowego bloku zdjęć pozyskanego z niskiego pułapu dla terenów niedostępnych – „optymalizacja aerotriangulacji”	24
2.1.2. Wyniki	28
2.1.3. Dyskusja i analiza otrzymanych wyników	33
2.2. METODYKA POPRAWY DOKŁADNOŚCI OKREŚLENIA POZYCJI BSP WYPOSAŻONYCH W JEDNOCZĘSTOTLIWOŚCIOWE ODBIORNIKI NA POTRZEBY ZBIERANIA DANYCH O PRZESZKODACH LOTNICZYCH [Publikacja 2]	36
2.2.1. Metodyka zwiększenia dokładności pozycjonowania BSP	36
2.2.2. Wyniki	37
2.2.3. Dyskusja i analiza otrzymanych wyników	41
2.3. METODYKA DETEKCJI I KLASYFIKACJI WYBRANYCH PRZESZKÓD LOTNICZYCH NA PODSTAWIE GĘSTEGO DOPASOWANIA OBRAZÓW BSP [Publikacja 3]	44
2.3.1. Metodyka detekcji przeszkód lotniczych o wydłużonym kształcie	44
2.3.2. Wyniki	52
2.3.3. Dyskusja i analiza otrzymanych wyników	53
2.4. AUTOMATYCZNE WYKRYWANIE NIETYPOWYCH PRZESZKÓD LOTNICZYCH NA PODSTAWIE OBRAZÓW Z BSP Z WYKORZYSTANIEM ALGORYTMU YOLO [Publikacja 4].....	55
2.4.1. Metodyka automatycznej detekcja i klasyfikacja nietypowych przeszkód lotniczych.....	55
2.4.2. Wyniki	60
2.4.3. Dyskusja i analiza otrzymanych wyników	64
3. WNIOSKI	67
LITERATURA	71
WYKAZ ZAŁĄCZNIKÓW	79

WYKAZ UŻYTYCH SKRÓTÓW WRAZ Z OBJAŚNIENIAMI

AIP – ang. *Aeronautical Information Publication*, zbiór informacji lotniczych

ALS – ang. *Airborne Laser Scanning*, lotniczy skaning laserowy

AP – ang. *Average Precision*, wskaźnik określający stosunek poprawnych detekcji do sumy poprawnych i fałszywych detekcji obiektów

BSP – bezzałogowy statek powietrzny

CLK – ang. *Clock Format*, format danych IGS zawierający precyzyjne wartości poprawki błędu zegara satelity/odbiornika GNSS

DCB – ang. *Differential Code Bias Format*, format danych IGS zawierający wartości opóźnień sprzętowych dla satelitów/odbiorników GNSS

EPH – ang. *Ephemeris Format*, format danych IGS zawierający głównie współrzędne satelitów GNSS, poprawki błędu zegarów satelitów GNSS, format efemerydy precyzyjnej

ETOD – ang. *Electronic Terrain and Obstacle Data*, elektroniczne dane o terenie i przeszkodach

EUROCONTROL – ang. *European Organisation for the Safety of Air Navigation*, Europejska Organizacja ds. Bezpieczeństwa Żeglugi Powietrznej

GNSS – ang. *Global Navigation Satellite System*, globalny system nawigacji satelitarnej

GPS – ang. *Global Positioning System*, globalny system pozycjonowania

ICAO – ang. *International Civil Aviation Organization*, Międzynarodowa Organizacja Lotnictwa Cywilnego

IGS – ang. *International GNSS Service*, międzynarodowy serwis GNSS

IONEX – ang. *Ionosphere Map Exchange Format*, format wymiany danych o stanie jonosfery w postaci globalnych map jonosfery

IoU – ang. *Intersection over Union*, wskaźnik dokładności określenia położenia oraz rozmiaru obiektu

LMP – ang. *Levenberg-Marquardt-Powell*, iteracyjny algorytm optymalizacji do rozwiązywania nieliniowych problemów z użyciem metody najmniejszych kwadratów

mAP – ang. *mean Average Precision*, średnia wartość wskaźnika określającego stosunek poprawnych detekcji do sumy poprawnych i fałszywych detekcji obiektów dla wielu celów

RANSAC – ang. *RAndom SAmples Consensus*, iteracyjna metoda stosowana w celu estymacji parametrów poszukiwanego modelu matematycznego obiektu w zbiorze danych zawierającym znaczną liczbę punktów nienależących do modelowanej powierzchni

RCNN – ang. *Regions with CNN features*, sieć splotowa bazująca na regionach

PZGiK – państwoowy zasób geodezyjny i kartograficzny, stanowi zbiór map oraz materiałów fotogrametrycznych, teledetekcyjnych, rejestrów, wykazów, informatycznych baz danych, katalogów danych geodezyjnych i innych opracowań powstałych w wyniku wykonania prac geodezyjnych i kartograficznych

RMSE – ang. *Root Mean Square Error*, błąd średniokwadratowy

RTK – ang. *Real Time Kinematic*, metoda pomiaru różnicowego GNSS wykonywana w czasie rzeczywistym z użyciem obserwacji fazowych

RTKLIB – oprogramowanie geodezyjne do opracowania obserwacji GNSS

RTK-OTF – ang. *Real Time Kinematic-On The Fly*, precyzyjna technika pomiarowa z szybkąinicjalizacją wyznaczenia pozycji odbiornika oraz wyznaczenia nieoznaczoności fazy dla obserwacji fazowych GNSS

SAR – ang. *Synthetic Aperture Radar*, radar z syntetyczną aperturą

SSD – ang. *Single Shot MultiBox Detector*, algorytm do wykrywania obiektów na obrazie

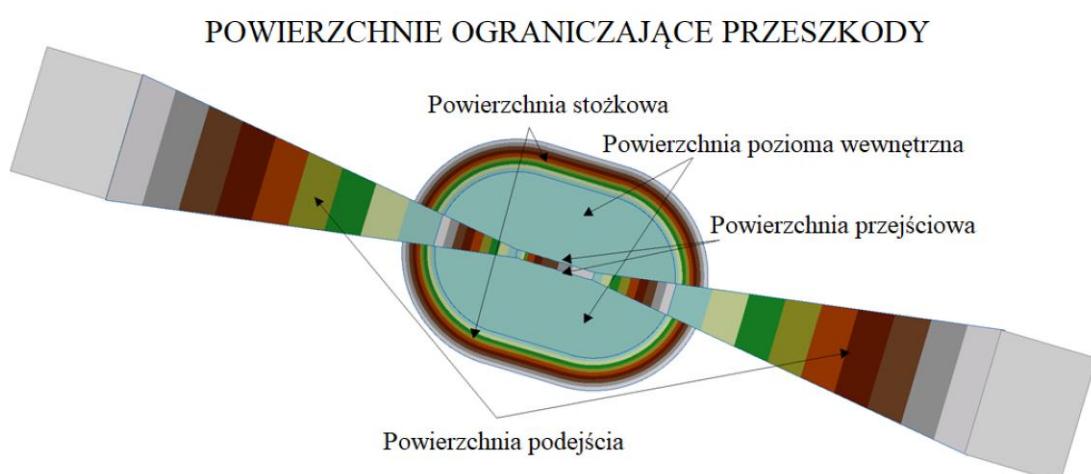
SPP – ang. *Single Point Positioning*, metoda pozycjonowania absolutnego z użyciem pomiarów kodowych GNSS

YOLO – ang. *You Only Look Once*, algorytm wykorzystujący sieci neuronowe do wykrywania obiektów

VTOL – ang. *Vertical Take-Off and Landing*, pionowy start i lądowanie statku powietrznego

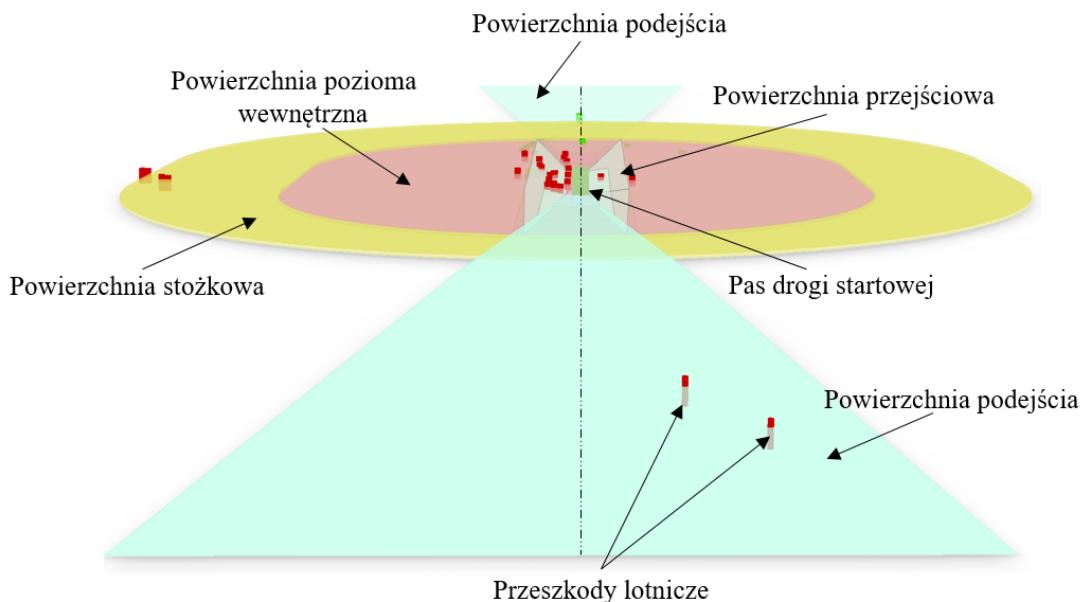
1. WPROWADZENIE

XXI wiek stał się symbolem rozwoju różnych gałęzi przemysłu, co wiąże się z coraz szybszym powiększaniem się terenów inwestycyjnych, wskutek czego zaobserwować można intensywne pojawianie się nowych obiektów (różnego rodzaju budowli itp.), nie tylko w dużych aglomeracjach miejskich, ale również na obszarach średnio zurbanizowanych oraz w pobliżu lotnisk. Z punktu widzenia bezpieczeństwa operacji lotniczych, obiekty ulokowane w bliskim otoczeniu lotniska mogą stanowić potencjalne zagrożenie dla operacji wykonywanych przez statki powietrzne. Dla zapewnienia bezpieczeństwa w przestrzeni powietrznej, na lotniskach i w ich otoczeniu, ustala się powierzchnie ograniczające przeszkody. Powierzchnie takie wyznaczane są na podstawie liczby i lokalizacji dróg startowych na lotnisku, cyfry kodu referencyjnego lotniska, kategorii podejścia do lądowania i wyposażenia lotniska we wzrokowe pomoce nawigacyjne [1]. Obiekty, które przewyższają powierzchnie ograniczające przeszkody mają bezpośredni wpływ na projektowanie procedur lotu i mogą powodować konieczność zwiększenia wysokości względnej oraz bezwzględnej przelotu. Obiekty, których wysokości są większe niż wysokości określone przez wyznaczone powierzchnie ograniczające przeszkody nazywane są przeszkodami lotniczymi [2]. Wymiary i nachylenia powierzchni ograniczających przeszkody określa się na podstawie Załącznika nr 3 do Rozporządzenia w sprawie przeszkód lotniczych, powierzchni ograniczających przeszkody oraz urządzeń o charakterze niebezpiecznym [1]. Do powierzchni ograniczających przeszkody zalicza się m. in.: powierzchnię stożkową, powierzchnię poziomą wewnętrzną, powierzchnię przejściową, powierzchnię podejścia [3] (Rys. 1).



Rys. 1. Powierzchnie ograniczające przeszkody [opr. wl. na podstawie 1]

Powierzchnia podejścia, powierzchnia przejściowa oraz powierzchnia stożkowa są powierzchniami nachylonymi, wznoszącymi się od pasa drogi startowej (Rys. 2). Powierzchnia pozioma wewnętrzna jest powierzchnią płaską, znajdująca się na stałej wysokości (Rys. 2).

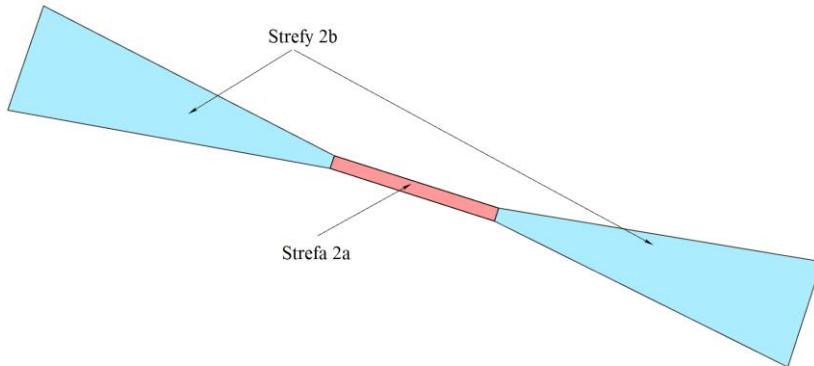


Rys. 2. Powierzchnie ograniczające przeszkody wraz z przeszkodami lotniczymi
[opr. wł. na podstawie 1]

W rejonie startów i lądowań oraz strefach podejścia do lądowania, płaszczyzna powierzchni podejścia określa wysokość do jakiej mogą sięgać obiekty w przestrzeni powietrznej w otoczeniu lotniska. Zatem kluczowe znaczenie mają dokładne dane o przeszkodach lotniczych, w szczególności ich lokalizacja i wysokość [4]. Obecnie stosowane przepisy, nakładają obowiązek zgłoszenia przeszkód lotniczych przez właścicieli nieruchomości, na których przeszkody lotnicze są posadowione [1]. Proces zgłoszenia przeszkód lotniczych jest procesem długotrwałym i złożonym, co wyklucza zapewnienie najwyższej aktualności danych dla utrzymania bezpieczeństwa w przestrzeni powietrznej. Jak wynika z przeprowadzonych wywiadów z zarządzającymi lotniskami zdarzają się sytuacje, kiedy przeszkody lotnicze nie są zgłoszone. W szczególności dotyczy to przeszkód lotniczych o charakterze tymczasowym (np. dźwigi budowlane). W przypadku występowania tego typu przeszkód lotniczych konieczne jest uzgodnienie posadowienia przeszkody lotniczej z zarządzającym lotniskiem, co również często jest pomijane. W związku z koniecznością zapewnienia bezpieczeństwa w przestrzeni powietrznej zarządzający lotniskiem kontroluje obiekty mogące stanowić przeszkody lotnicze. W tym celu przeprowadzana jest

inwentaryzacja wraz z weryfikacją wysokości obiektów względem obowiązujących powierzchni ograniczających przeszkode. Kontrola wykonywana jest tradycyjnymi metodami geodezyjnymi, co jest procesem bardzo czasochłonnym i w efekcie przy dużej liczbie przeskóde lotniczych może zostać niezachowana jak najwyższa aktualność danych. Obecnie nie ma skutecznej metody monitorowania przeskóde, która gwarantowałaby zarazem jak najwyższą aktualność danych, automatyzację procesu i dokładność. Istnieją zalecenia dotyczące sposobu pozyskiwania danych o przeskodach, gdzie przy gromadzeniu dużych zbiorów danych nacisk kładziony jest na dokładność danych i automatyzację procesów [5]. W związku z koniecznością zbierania i gromadzenia danych o przeskodach wyróżnia się kilka stref pokrycia, dla których zbiera się dane o przeskodach lotniczych [6]. Wśród nich wyróżnić można dwie strefy zbierania danych o przeskodach lotniczych – strefę 2a i 2b (Rys. 3), których występowanie pokrywa się z newralgicznymi fazami lotu samolotu, czyli startem i lądowaniem. W strefie 2 dokładność pozioma zbierania danych o przeskodach lotniczych wynosi 5 m, a dokładność pionowa wynosi 3 m [5, 7].

STREFY ZBIERANIA DANYCH O PRZESKODACH



Rys. 3. Strefy zbierania danych o przeskodach [opr. wł. na podstawie 5]

Istnieje kilka metod zbierania danych o przeskodach, w tym: ALS, SAR, fotogrametria lotnicza, fotogrametria satelitarna i pomiary naziemne. Każda z wymienionych metod charakteryzuje się określonymi właściwościami w ujęciu gromadzenia danych o przeskodach. Lotniczy skaning laserowy mimo, że daje możliwość automatyzacji procesu, to charakteryzuje się wysokimi kosztami eksploatacyjnymi i dlatego jest mniej osiągalny. Obrazy radarowe nie znajdują praktycznego wykorzystania przy ekstrakcji przeskóde z cyfrowych modeli powierzchni generowanych przez SAR. Fotogrametria lotnicza, do której zaliczyć można również pozyskiwanie danych przez bezzałogowe statki

powietrzne jest najbardziej wydajną techniką pozyskiwania danych, a algorytmy ekstrakcji obiektów stale ewoluują. Fotogrametria satelitarna znajduje zastosowanie dla obszarów wielkopowierzchniowych. Pomiar naziemny, jako ostatnia z metod zbierania danych o przeszkodach lotniczych, jest metodą najmniej efektywną i najbardziej pracochłonną. Zalecenia dotyczące wykorzystania odpowiedniej techniki do zbierania danych o przeszkodach lotniczych w poszczególnych strefach zbierania danych o przeszkodach lotniczych przedstawiono w Tab. 1.

Tab. 1. Zalecenia dotyczące metod pomiaru przeszkód lotniczych [opr. wł. na podstawie 5]

	ALS	SAR	Fotogrametria lotnicza	Fotogrametria satelitarna	Pomiary naziemne
Strefa 1	+	-	+	+	-
Strefa 2	++	-	+	+	o
Strefa 3	+/++	-	+/++	-	+
Strefa 4	+/++	-	+/++	-	++
Male grupy, pojedyncza przeszkoda	o/+	-	o/+	-	++

*objaśnienie:

„++” odpowiedni technicznie i bardzo opłacalny

„+” odpowiedni technicznie, ale nie najbardziej opłacalny

„o” odpowiedni technicznie, ale bardzo niski stosunek kosztów do korzyści

„-” niespełnienie wymagań technicznych i bardzo niski stosunek kosztów do korzyści

Dla strefy 2 zbierania danych o przeszkodach lotniczych, w przypadku konieczności opracowania dużego zbioru danych, zaleca się wykorzystanie ALS ze względu na możliwości techniczne i dużą efektywność. Ponadto fotogrametria lotnicza i fotogrametria satelitarna są również odpowiednie technicznie, jednak mniej opłacalne. Pomiary naziemne są mało efektywną metodą zbierania danych o przeszkodach w tej strefie. Zobrazowania radarowe nie spełniają wymagań technicznych dla zbierania danych o przeszkodach lotniczych.

Mimo usystematyzowania wymagań i technik pozyskiwania danych o przeszkodach lotniczych, wciąż w sferze rozwoju pozostaje automatyzacja mechanizmów ich pozyskiwania i przetwarzania danych [5]. Dużym wyzwaniem staje się wykrycie niewielkich przeszkód, które charakteryzują się wydłużonym kształtem (np. kominy przemysłowe, wieżowce) i wysmukłym kształtem (np. anteny, maszty) [5]. Dla uchwycenia takiego rodzaju obiektów koniecznym jest, żeby skala obrazu była większa niż w przypadku tradycyjnych lotów badawczych, a to wymaga niższej wysokości lotu i może być zapewnione przez zastosowanie BSP. Dotychczas zalecane techniki wykrywania przeszkód lotniczych opierały się na ALS. Jednak w tym przypadku nie można było wykluczyć

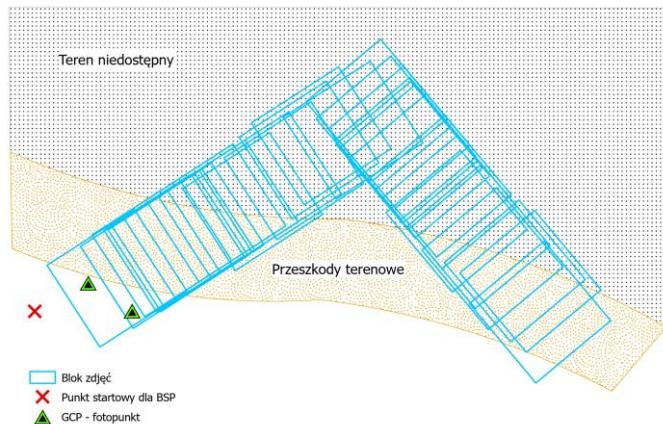
pominięcia niewielkiej przeszkody lotniczej [5], a kontrola wykrytych obiektów przeprowadzana była przy wykorzystaniu tradycyjnych pomiarów naziemnych, przez co cały proces stawał się długi i żmudny oraz mało efektywny, szczególnie przy obrazowaniu obszarów wielkopowierzchniowych. Dla zapewnienia bezpieczeństwa w przestrzeni powietrznej ważne jest, aby dane o przeszkodach aktualizowane były regularnie i w zależności od potrzeb, a ALS nie zapewnia wysokiej rozdzielczości czasowej pozyskiwania danych. Najnowsze wytyczne [5] dotyczące pozyskiwania danych o przeszkodach wskazują na wykorzystanie danych z lotów na małych wysokościach (250 m), co zapewniają BSP. Dzięki temu można uzyskać dużo większą skalę obrazu, niż ta która jest uzyskiwana w przypadku tradycyjnych lotów fotogrametrycznych. Przy niższej wysokości lotu, osiągana dokładność pozyskanych danych o przeszkodach lotniczych (X, Y, Z) będzie najwyższa.

Zapewnienie bezpieczeństwa w przestrzeni powietrznej dotyczy nie tylko lotnisk, ale również lądowisk i innych miejsc startów i lądowań, na których może być wykonywane lądowanie w tzw. terenie przygodnym. W tym przypadku wybór miejsca do lądowania dla zaplanowanej misji często przeprowadza się na podstawie wstępного rozpoznania w terenie. W zależności od typu statku powietrznego wybierane jest miejsce, aby zapewnić bezpieczne warunki podczas lądowania. Miejsce takie powinno obejmować obszar zgodny z wymiarami danego typu statku powietrznego i powinno być wolne od przeszkód terenowych. Zabezpieczenie przygodnego lądowania do realizacji celów operacyjnych z uwagi na konieczność szybkiego i efektywnego działania może zostać przeprowadzone przy wykorzystaniu BSP, bez konieczności prowadzenia rekonesansu w terenie przez grupę rozpoznawczą. Produkty fotogrametryczne powstałe w wyniku przetworzenia danych obrazowych mogą zostać wykorzystane do pozyskania danych na temat przeszkód, a tym samym do wyboru odpowiedniego miejsca do lądowania.

W ostatnich latach zauważa się dynamiczny wzrost realizacji opracowań fotogrametrycznych [8-9] z niskiego pułapu (z BSP [10]) z możliwością generowania m. in. gęstej i dokładnej chmury punktów, tworzenia prawdziwej ortofotomapy tzw. „true ortho” o rozdzielczości przestrzennej poniżej 0,05 m. Potencjał BSP został dostrzeżony przez sektor lotniczy, gdzie znajduje zastosowanie m. in. w zapewnieniu bezpieczeństwa w przestrzeni powietrznej [5]. Dziedzina fotogrametrii, teledetekcji i geoinformacji ma szerokie spektrum narzędzi, które może być wykorzystane przy monitorowaniu przeszkód lotniczych, w tym przy określaniu ich położenia i wysokości. Na szczególną uwagę

zasługuje problematyka związana z detekcją przeszkodek lotniczych o wydłużonym i wysmukłym kształcie. Mimo najnowszych rekomendacji dotyczących technik zbierania danych o tego rodzaju przeszkodech lotniczych, gdzie wskazuje się możliwość pozyskiwania danych za pomocą BSP, brak jest jednoznacznych rozwiązań dotyczących metodyki przetwarzania danych pozyskanych z BSP w celu zbierania danych o przeszkodech, a istniejące algorytmy wciąż są modyfikowane. Zatem istotny problem badawczy stanowią algorytmy przetwarzania danych pozyskanych z BSP na potrzeby zbierania danych o przeszkodech lotniczych. Wybór metody zbierania danych o przeszkodech lotniczych wpływa na dokładność tych danych. Wykorzystanie BSP do pozyskania danych na temat przeszkodek lotniczych wiąże się z cyklem opracowania danych – począwszy od prac polowych, czyli nalotu fotogrametrycznego i pomiaru osnowy fotogrametrycznej, po prace kameralne związane z opracowaniem danych fotogrametrycznych. Każdy etap prac ma wpływ na dokładność otrzymanych produktów fotogrametrycznych, takich jak gęsta chmura punktów, ortofotomapa czy numeryczny model pokrycia terenu. W pierwszej kolejności liczba i rozmieszczenie punktów osnowy fotogrametrycznej mają wpływ na wyniki wyrównania bloku fotogrametrycznego. Ponadto metoda i dokładność wyznaczenia pozycji BSP ma bezpośredni wpływ na dokładność pozyskanych danych i w efekcie produktów fotogrametrycznych. W kolejnych etapach wybór metodyki przetwarzania danych przy pracach związanych z wykrywaniem obiektów i ich cech charakterystycznych ma ogromne znaczenie, biorąc pod uwagę potrzebę uzyskania określonych dokładności dla współrzędnych (X, Y, Z).

Zbieranie danych o przeszkodech lotniczych prowadzone jest na obszarach o różnym ukształtowaniu i pokryciu terenu. Często z uwagi na różnorodność ukształtowania terenu, obszar opracowania jest niedostępny, przez co niemożliwe jest przeprowadzenie pomiarów naziemnych (Rys. 4). Przy zastosowaniu technologii BSP do uzyskania produktów fotogrametrycznych o określonej dokładności, dotychczas niezbędny był naziemny pomiar osnowy fotogrametrycznej, co na obszarze o ograniczonym dostępie było warunkiem nie do spełnienia.



Rys. 4. Pojedynczy blok na terenie niedostępny [opr. wl.]

Dla prawidłowego wyrównania bloku zdjęć (aerotriangulacji), ważne jest zapewnienie równomiernego rozmieszczenia punktów osnowy na całym obszarze opracowania [11-13]. Problem badawczy stanowi kwestia związaną z aerotriangulacją przy niewielkiej liczbie fotopunktów i wynikającym z tego niepełnym pokryciu obszaru opracowania [14]. Istnieją liczne badania mające na celu znalezienie odpowiedzi na pytanie jaka liczba i konfiguracja rozmieszczenia fotopunktów byłaby optymalna dla osiągnięcia wymaganych dokładności [11, 13, 15-18]. Mimo badań w tym zakresie, wyniki są niejednoznaczne i wciąż w sferze rozwoju pozostaje dostosowanie rozmieszczenia punktów osnowy fotogrametrycznej dla zachowania prawidłowej geometrii bloku zdjęć. Obecnie coraz powszechniej stosowana metoda pozycjonowania RTK może pozwolić na zmniejszenie liczby fotopunktów. Jednak zastosowanie tej metody wiąże się z ograniczeniami wynikającymi z konieczności zapewnienia ciągłej łączności między stacją bazową i odbiornikiem ruchomym. W niskobudżetowych pokładowych odbiornikach GPS do określenia pozycji BSP w czasie rzeczywistym stosuje się metodę pozycjonowania absolutnego SPP [19]. W przypadku tej metody wykorzystywane są odbiorniki jednoczestotliwościowe, zabudowane na platformie BSP [20]. Mimo, iż metoda ta jest najbardziej rozpowszechniona, to charakteryzuje się niską dokładnością pozycjonowania, sięgającą nawet do 10 m [21-22]. Istnieją badania [23], które pokazują możliwość osiągnięcia większej dokładności pozycjonowania BSP wyposażonych w odbiorniki GPS. Obecnie rozwój technologii BSP w zastosowaniach fotogrametrycznych wiąże się z możliwością wykorzystania algorytmów numerycznych poprawiających pozycjonowanie platformy w czasie rzeczywistym oraz realizacji niezbędnych analiz nawigacyjnych w trybie post-processingu.

Metodyka pozyskiwania danych o przeszkodach jest równie ważna jak proces ich przetwarzania. W wyniku nalotu fotogrametrycznego z niskiego pułapu i w procesie

przetwarzania danych, otrzymuje się gęstą chmurę punktów, ortofotomapę czy numeryczny model pokrycia terenu. Powstała gęsta chmura punktów opisuje obiekty 3D i na jej podstawie można dokonać detekcji obiektów przestrzennych. Dostępne komercyjne oprogramowanie, pozwalające na wykrywanie obiektów, znaczco ogranicza rolę operatora w opracowaniu produktów 3D. Rozwój algorytmów detekcji i klasyfikacji obiektów na podstawie nieuporządkowanej chmury punktów daje możliwość wykrywania obiektów jakimi są przeszkody lotnicze. Przetwarzanie chmur punktów 3D opiera się na procesie segmentacji, której celem jest skupienie punktów o podobnej charakterystyce w jednorodne regiony. Proces ten może być pomocny w analizie danych przestrzennych, takich jak lokalizowanie i rozpoznawanie obiektów, klasyfikacja i wyodrębnianie cech tych obiektów [24-25]. Generalnie badane obiekty i ich elementy posiadają unikalne cechy geometryczne, w związku z czym cechy geometryczne 3D są wykorzystywane jako podstawowe informacje w wykrywaniu obiektów i kategoryzacji ich podelementów [26]. Chmury punktów 3D doskonale nadają się do określania właściwości geometrycznych obiektów, a BSP dostarczające zdjęcia o bardzo dużym pokryciu i wysokiej rozdzielczości, pozwalają na wygenerowanie bardzo gęstej chmury punktów 3D w minimalnym czasie i przy bardzo niewielkim nakładzie finansowym [27]. Zatem chmury punktów 3D pozyskane z niskiego pułapu stają się coraz powszechniej wykorzystywane do badań lokalizacji obiektów 3D. Metoda wykrywania obiektów z chmur punktów zależy od charakterystyki badanych obiektów. W przypadku wykrywania budynków z chmur punktów 3D proces odbywa się poprzez identyfikację płaskich segmentów, ponieważ większość elementów budynków, to płaskie powierzchnie [28]. Płaskie segmenty ze swoimi cechami geometrycznymi mogą pomóc w wykrywaniu i określaniu cech obiektów. W praktyce stosuje się wiele podejść do segmentacji, takich jak podejście oparte na regionie (np. wzrost regionu, podział i łączenie), podejście oparte na klastrach (np. K-średnie, średnie przesunięcie) i podejście oparte na grafach [18-19]. Jednak wybór odpowiedniego podejścia do segmentacji zależy od aplikacji i rodzaju funkcji dostępnych do segmentacji. Istnieje wiele metod, algorytmów i rozwiązań możliwych do zastosowania na poszczególnych etapach modelowania obiektów 3D [9]. Jarząbek-Rychard i in. [31] w swojej pracy konfrontują wydajność estymatora RANSAC z metodą rosnących płaszczyzn. Przeprowadzone testy, polegające na detekcji połaci dachowych w danych z chmury punktów pozwalają stwierdzić, iż RANSAC jest rozwiązaniem lepszym w przypadku segmentacji modeli nieskomplikowanych geometrycznie. Algorytm RANSAC pozwala na iteracyjne modelowanie płaszczyzn w zbiorze danych zawierających znaczną (nawet przekraczającą połowę obserwacji) liczbę

błędów grubych, czyli punktów nienależących do modelowanej powierzchni. Metoda rozwinięta została początkowo dla celów widzenia komputerowego, pozwalając na odporną identyfikację obiektów [32]. Zaimplementowany algorytm umożliwia wyodrębnienie kolejnych płaszczyzn dominujących, reprezentowanych przez największą liczbę punktów. Zaletą metody jest jej odporność – punkty stanowiące przypadkowe odbicia od powierzchni bądź położone w bliskim sąsiedztwie estymowanej płaszczyzny, lecz należące do innego obiektu nie ulegają błędnej klasyfikacji.

Do wykrycia przeszkód lotniczych można użyć obrazów pozyskanych za pomocą BSP. Jest to możliwe dzięki modelom głębokiego uczenia i segmentacji semantycznej, które służą do automatycznego wykrycia obiektu na podstawie danych obrazowych o wysokiej rozdzielczości. Detekcję obiektów opartą na głębokim uczeniu można podzielić na dwie kategorie: dwuetapową i jednoetapową. Seria RCNN (RCNN [33], Fast RCNN [34] i Faster RCNN [35]), to dwuetapowy algorytm, który pod względem dokładności przewyższa wiele innych algorytmów wykrywania. Jednak tego rodzaju podejście wymagają większych mocy obliczeniowych, co powoduje wydłużenie czasu przetwarzania danych. Z punktu widzenia kategorii jednoetapowej wyróżnić można algorytm SSD [36-37] i algorytm YOLO zaproponowany przez Redmona i in. [38]. Algorytm YOLO, rozwiązuje wykrywanie obiektów jako problem regresji i wyświetla lokalizację i klasyfikację obiektu w sieci typu „end-to-end”, w jednym kroku. Z uwagi na szybkość wykrywania z wykorzystaniem tej metody, obecnie jest jednym z najczęściej wykorzystywanych algorytmów. Ze względu na pojawiający się błąd w dokładności wykrywania niewielkich celów, algorytm YOLO jest stale rozwijany. Na uwagę zasługuje YOLOv3, który wykorzystuje metodę grupowania K-srednich, aby automatycznie wybrać najlepszą początkową ramkę regresji dla zbioru danych. Ta wersja algorytmu YOLO [39] jest przystosowana do poprawy dokładności wykrywania małych obiektów. W przeciwieństwie do innych metod, metody uczenia głębokiego dają możliwość automatycznego wyodrębnienia cech niskiego i wysokiego poziomu [40-41].

Proces zbierania danych o przeszkodach lotniczych na podstawie danych pozyskanych z niskiego pułapu jest procesem złożonym. Każdy z poszczególnych etapów ma wpływ na dokładność danych o przeszkodach lotniczych. Począwszy od liczby i rozmieszczenia punktów osnowy fotogrametrycznej, które wpływają na wyniki wyrównania bloku zdjęć. Następnie poprzez wybór metody pozycjonowania BSP, która wpływa na wyniki dokładności określenia pozycji BSP. Finalnie poprzez metodę

wykrywania obiektów z gęstej chmury punktów, aż po fuzję algorytmu uczenia głębokiego bazującego na obrazie i algorytmu klasyfikacji chmury punktów. W niniejszej rozprawie problem badawczy brzmi: jakie algorytmy przetwarzania danych pozyskanych z niskiego pułapu należy zastosować, aby wykryć i sklasyfikować nietypowe przeszkody lotnicze zgodnie z wymaganiami dokładnościowymi zawartymi w dokumentach EUROCONTROL i ICAO [5, 7]?

W związku z powyższym głównym celem badań opisanych w niniejszej rozprawie było opracowanie metod przetwarzania danych pozyskanych z bezzałogowych statków powietrznych na potrzeby zbierania danych o przeszkodach lotniczych.

Celami pośrednimi było:

- opracowanie metody wyrównania jednoszeregowego bloku zdjęć pozyskanych z niskiego pułapu dla terenów niedostępnych,
- opracowanie metody podwyższenia dokładności pozycjonowania bezzałogowych statków powietrznych wyposażonych w odbiorniki jednocześnie częstotliwościowe, a przez to dokładności produktów fotogrametrycznych, na potrzeby zbierania danych o przeszkodach lotniczych, bez pomiaru fotopunktów,
- opracowanie metody automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych na podstawie gęstych chmur punktów oraz obrazów pozyskanych z niskiego pułapu.

Z powyższego wynika teza, że **przetwarzanie danych pozyskanych z niskiego pułapu poprzez zastosowanie algorytmu poprawy pozycjonowania BSP, algorytmu filtracji i segmentacji chmury punktów oraz algorytmu sieci neuronowej pozwoli na detekcję i identyfikację przeszkód lotniczych z dokładnością zgodną z wymaganiami EUROCONTROL i ICAO.**

Prawidłowe wykrycie przeszkód lotniczych ma fundamentalne znaczenie dla zapewnienia bezpieczeństwa operacji lotniczych. Aby spełnić wymagania wykrywanych przeszkód lotniczych, konieczny jest dobór odpowiednich technik wykrywania i przetwarzania danych. W wyniku przetwarzania danych pozyskanych za pomocą BSP powstają produkty fotogrametryczne takie jak chmura punktów czy ortofotomapa. Poprzez zastosowanie algorytmów działających na chmurze punktów i na obrazie możliwe

jest wykrycie przeszkód lotniczych. Podczas realizacji projektu badawczego postawiono zatem cztery hipotezy:

H1: Uwzględnienie dodatkowych parametrów w procesie aerotriangulacji pozwala na podwyższenie dokładności wyrównania bloku jednoszeregowego przy ograniczonej liczbie fotopunktów dla terenów niedostępnych, przy zastosowaniu niskobudżetowych bezzałogowych statków powietrznych, wyposażonych w jednociąstotliwościowe odbiorniki GPS.

H2: Zastosowanie algorytmu metody pozycjonowania absolutnego SPP z użyciem produktów IGS pozwoli na zwiększenie dokładności wyznaczenia pozycji bezzałogowego statku powietrznego dla pozyskiwania danych o przeszkodach lotniczych.

H3: Segmentacja chmur punktów zmodyfikowanym algorytmem RANSAC poprzez zastosowanie odpowiedniej filtracji i segmentacji gęstej chmury punktów pozwoli na wykrycie przeszkód lotniczych z dokładnością zgodną z przepisami EUROCONTROL i ICAO.

H4: Zastosowanie metody detekcji i klasyfikacji nietypowych przeszkód lotniczych z wykorzystaniem głębokich sieci neuronowych pozwoli na zwiększenie dokładności identyfikacji oraz poprawności klasyfikacji przeszkód lotniczych.

Badania przeprowadzono w taki sposób, aby kolejno realizować założone cele pośrednie, które prowadziły do realizacji głównego celu postawionego w niniejszej rozprawie. Postawione hipotezy stanowiły podstawę opracowania autorskiej metody przetwarzania danych pozyskanych z niskiego pułapu na potrzeby zbierania danych o przeszkodach lotniczych, a wykonane analizy umożliwiły weryfikację hipotez.

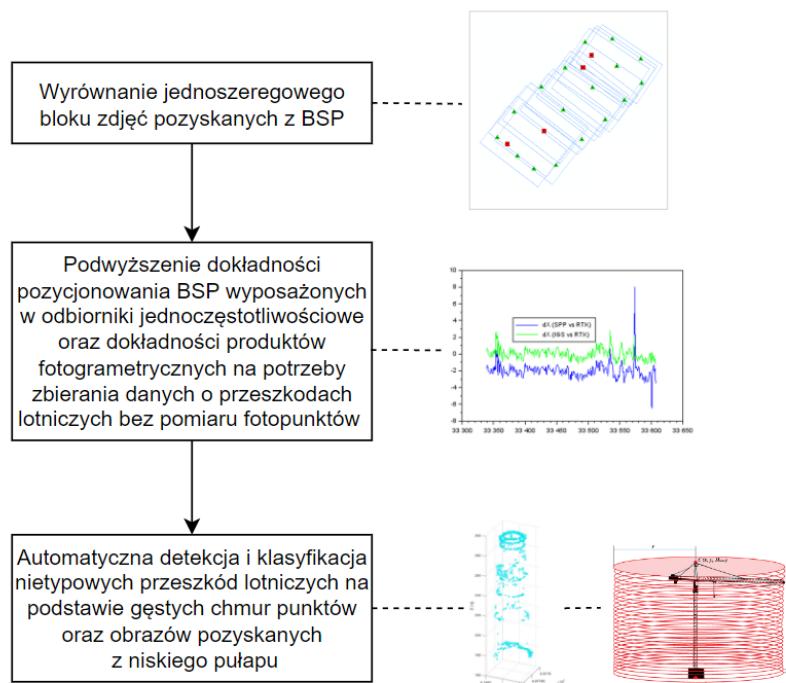
W dalszej części, autoreferat składa się z rozdziału 2, w którym opisano cykl czterech publikacji. W podrozdziałach od 2.1. do 2.4. przedstawiono metodykę badań, wyniki, dyskusję i analizę otrzymanych wyników dla każdej z publikacji. Rozdział 3 zawiera kompleksowe podsumowanie całego cyklu publikacji. Do autoreferatu dołączono cykl publikacji, składający się na niniejszą rozprawę doktorską (Załączniki 1-4).

2. CYKL PUBLIKACJI. METODYKA BADAŃ, WYNIKI, DYSKUSJA I ANALIZA OTRZYMANYCH WYNIKÓW

- [Publikacja 1]** **Lalak M.** (70%), Wierzbicki D. (15%), Kędzierski M. (15%), *Methodology of processing single-strip blocks of imagery with reduction and optimization number of ground control points in UAV photogrammetry*, Remote Sensing 2020, 12(20), 3336, DOI: 10.3390/rs12203336.
- [Publikacja 2]** **Lalak M.** (90%), Krasuski K. (5%), Wierzbicki D. (5%), *Methodology to improve the accuracy of the determination of the position of UAV equipped with single-frequency receivers for the purposes of gathering data about aviation obstacles*, Scientific Journal of Silesian University of Technology, Series Transport 2023, 119, 83-104, ISSN: 0209-3324, DOI: 10.20858/sjsutst.2023.119.5.
- [Publikacja 3]** **Lalak M.** (80%), Wierzbicki D. (20%), *Methodology of detection and classification of selected aviation obstacles based on UAV dense image matching*, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2022, 15, 1869-1883, DOI: 10.1109/JSTARS.2022.3149105.
- [Publikacja 4]** **Lalak M.** (80%), Wierzbicki D. (20%), *Automated detection of atypical aviation obstacles from UAV images using a YOLO algorithm*, Sensors 2022, 22(17), 6611, DOI: 10.3390/s22176611.

Cykl składa się z czterech publikacji, które prezentują kolejne etapy algorytmu postępowania, mającego na celu opracowanie metodyki przetwarzania danych pozyskanych z BSP dla wykrycia i określenia wysokości przeszkód lotniczych o wydłużonym i wysmukłym kształcie (nietypowych przeszkód lotniczych) (Rys. 5). W pierwszej publikacji przedstawiono wyniki badań dotyczące wyrównania jednoszeregowego bloku zdjęć pozyskanego z niskiego pułapu na potrzeby zbierania danych o przeszkodach lotniczych. Pozyskane dane stanowiły podstawę do wyboru miejsca do lądowania w tzw. terenie przygodnym, przy ograniczonym dostępie do obszaru opracowania. Badania

przeprowadzono w oparciu o dwie metody. Pierwsza z nich, prezentująca autorskie podejście do użycia punktów wiążących w procesie wyrównania, opiera się na zmodyfikowanej metodzie regresji liniowej. Druga metoda, opiera się na jednej z metod optymalizacji nieliniowej – zmodyfikowanym algorytmie LMP. W drugiej publikacji przedstawiono wyniki badań dotyczące podwyższenia dokładności pozycjonowania BSP wyposażonych w odbiorniki jednoczestotliwościowe, a w efekcie podwyższenia dokładności produktów fotogrametrycznych na potrzeby zbierania danych o przeszkodach lotniczych, bez pomiaru fotopunktów. Zwiększenie dokładności pozycjonowania BSP wykonano na podstawie algorytmu metody SPP z użyciem produktów IGS. W trzeciej publikacji przedstawiono wyniki badań na temat detekcji i klasyfikacji nietypowych przeszkód lotniczych (o wydłużonym kształcie) na podstawie danych pozyskanych z BSP. Badania przeprowadzono na chmurze punktów, przy użyciu nowego algorytmu klasyfikacji i filtracji chmury punktów oraz modyfikacji algorytmu RANSAC. W czwartej publikacji przedstawiono wyniki badań dotyczące automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych (o wysmukłym kształcie) na podstawie danych pozyskanych z BSP. W badaniach zastosowano fuzję algorytmu YOLOv3 do detekcji obiektów na obrazie oraz zmodyfikowanej metody klasyfikacji i filtracji chmury punktów, zaprezentowanej w trzeciej publikacji z cyku.



Rys. 5. Proces przetwarzania danych pozyskanych z niskiego pułapu na potrzeby zbierania danych o przeszkodach lotniczych [opr. wł.]

Wspólną cechą powyższych publikacji są eksperymenty badawcze, których wyniki pozwoliły zoptymalizować proces przetwarzania danych pozyskanych z niskiego pułapu na potrzeby zbierania danych o przeszkodach lotniczych. Spójny cykl publikacji stanowi rozwiązanie problemu badawczego związanego z metodyką przetwarzania danych pozyskanych z niskiego pułapu na podstawie autorskich rozwiązań w zakresie poprawy dokładności: wyrównania bloku zdjęć, pozycjonowania BSP, filtracji oraz segmentacji gęstych chmur punktów, a także implementacji algorytmów głębokiego uczenia na potrzeby detekcji i klasyfikacji przeszkód lotniczych zgodnie z wymaganiami EUROCONTROL i ICAO [5, 7].

2.1. METODYKA PRZETWARZANIA JEDNOSZEREGOWYCH BLOKÓW ZDJĘĆ Z REDUKCJĄ I OPTYMALIZACJĄ LICZBY FOTOPUNKTÓW W FOTOGRAMETRII BSP [Publikacja 1]

2.1.1. Metodyka wyrównania jednoszeregowego bloku zdjęć pozyskanego z niskiego pułapu dla terenów niedostępnych – „optymalizacja aerotriangulacji”

W pierwszej publikacji przedstawiono rezultaty badań, których celem było opracowanie metody wyrównania jednoszeregowego bloku zdjęć pozyskanego z niskiego pułapu dla terenów niedostępnych. Badania przeprowadzono w oparciu o dwie metody. Pierwsza z nich, prezentująca autorskie podejście do wykorzystania punktów wiążących w procesie wyrównania, opierała się na zmodyfikowanej metodzie regresji liniowej. Druga metoda opierała się na jednej z metod optymalizacji nieliniowej – zmodyfikowanym algorytmie LMP.

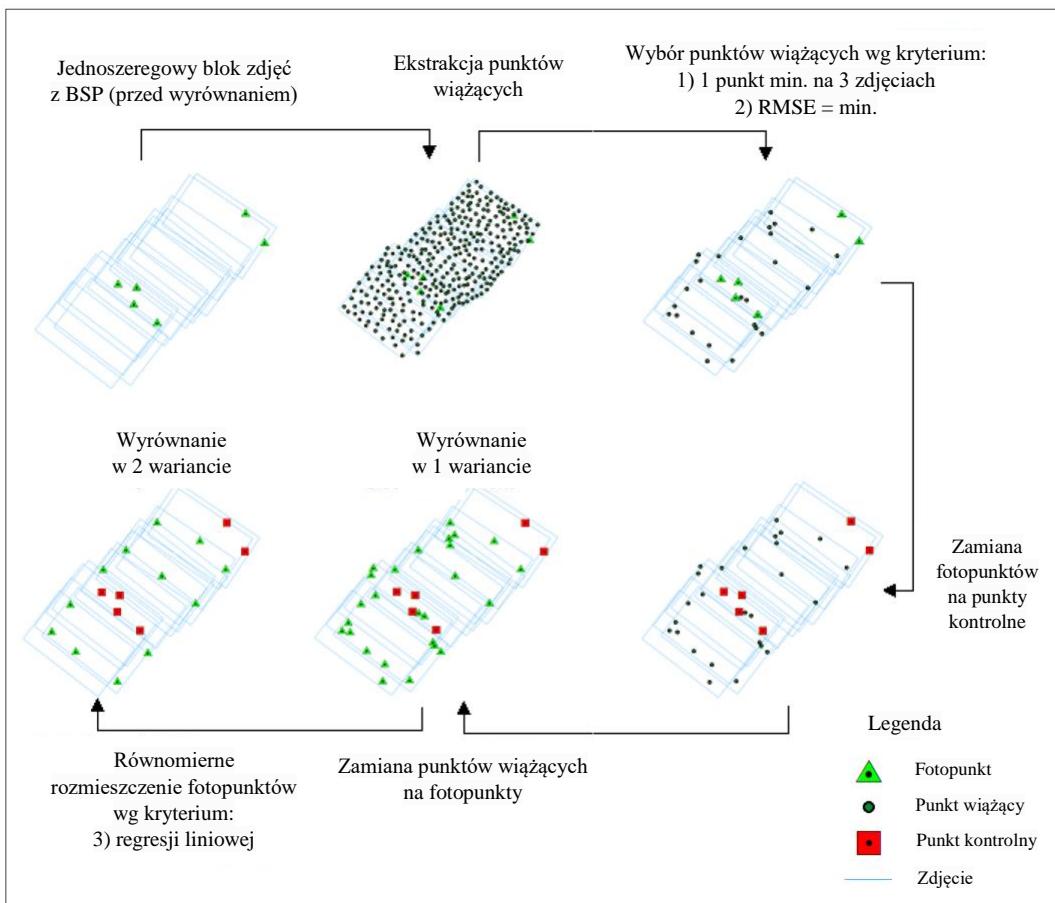
Wyrównanie bloku zdjęć (aerotriangulacja) jest procesem podczas, którego wyznaczane są elementy orientacji zewnętrznej każdego zdjęcia (elementy liniowe i kątowe). Wykorzystywana do wyrównania metoda niezależnych wiązek polega na wyznaczeniu bezpośrednich relacji pomiędzy współrzędnymi obrazowymi fotopunktów i punktów wiążących pomierzonymi na zdjęciu, a współrzędnymi terenowymi fotopunktów. Podczas realizacji tego procesu metodą niezależnych wiązek, z matematycznego punktu widzenia, konieczne jest wykorzystanie fundamentalnego w fotogrametrii równania kolinearności. Można je sformułować jako nieliniowy problem najmniejszych kwadratów, który ma na celu zminimalizowanie całkowitego błędu między współrzędnymi obserwowanego punktu obrazu, a przewidywanymi lokalizacjami cech [42]. Aerotriangulacja zdjęć jest procesem stosowanym od wielu lat, jednak strategie obliczeniowe ewoluują i są stale modyfikowane w celu poprawy dokładności wyników wyrównania. Podstawą automatycznej aerotriangulacji cyfrowej jest wyszukiwanie, pomiar i przenoszenie punktów wiążących na dwóch lub więcej obrazach, zawierających ten sam fragment powierzchni, przy wykorzystaniu jednej z metod korelacji obrazów.

Autorska metoda wyrównania jednoszeregowego bloku zdjęć opierała się na zagęszczeniu osnowy fotogrametrycznej, punktami wiążącymi wygenerowanymi podczas wyrównania całego bloku (w punkcie wyjściowym). Spośród punktów wiążących wybrano punkty wg następujących kryteriów:

- 1) jeden punkt minimum na 3 zdjęciach;

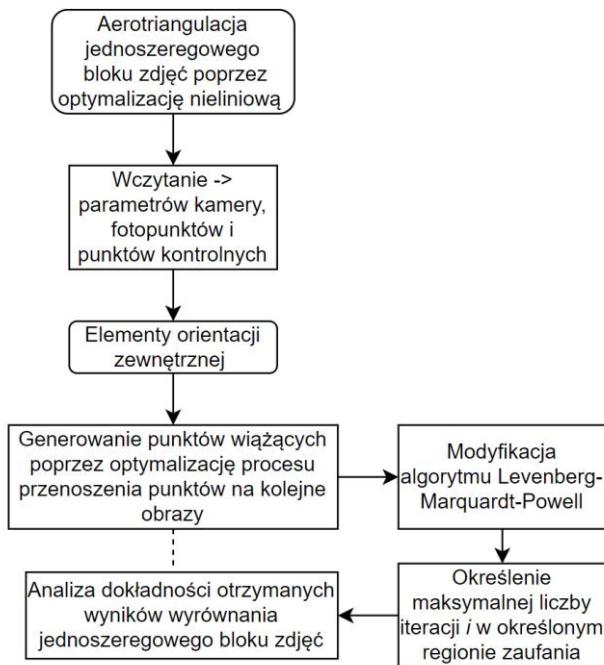
- 2) punkty o najmniejszym błędzie średniokwadratowym (RMSE = minimum);
- 3) punkty równomiernie rozmieszczone na obszarze opracowania (zmodyfikowana metoda regresji liniowej [43]).

Wykorzystując zależność liniową między danymi, posłużono się klasycznym modelem regresji liniowej w celu zapewnienia równomiernego rozmieszczenia punktów wiążących na badanym obszarze. Niedostępność terenu spowodowała, że na obszarze opracowania pomierzono niewielką liczbę fotopunktów. Wobec tego faktu, do dalszych badań wykorzystano punkty wiążące wygenerowane w procesie aerotriangulacji cyfrowej całego bloku. Punkty te były przypadkowo rozmieszczone na całym obszarze testowym. Aby zapewnić równomierne rozmieszczenie punktów wiążących na obszarze opracowania, wykorzystano metodę regresji liniowej, opierającą się na zależności liniowej, w której krzywa dopasowywana jest do danych, czyli współrzędnych tłowych punktów wiążących. W celu doboru punktów wiążących wykorzystano metodę najmniejszych kwadratów, dzięki czemu wyznaczono prostą $y_i = ax_i + b$. Równomiernie rozmieszczone punkty wiążące przekształcono na fotopunkty, a wcześniej pomierzone w terenie fotopunkty przekształcono na punkty kontrolne (Rys. 6). Dzięki opracowanej metodzie dokonano wyrównania jednoszeregowego bloku zdjęć przy użyciu fotopunktów, równomiernie rozmieszczonych na całym obszarze opracowania.



Rys. 6. Proces zagęszczenia osnowy fotogrametrycznej na podstawie punktów wiążących [opr. wł.]

Druga z zastosowanych metod wyrównania jednoszeregowego bloku zdjęć opierała się na optymalizacji nieliniowej, poprzez modyfikację algorytmu LMP (Rys. 7). Algorytm wykorzystano w procesie orientacji wzajemnej obrazów pozyskanych z niskiego pułapu. Wyznaczane elementy orientacji zewnętrznej obrazów: liniowe i kątowe, przyjęto jako elementy stałe, a algorytm LMP pozwolił na optymalizację przenoszenia punktów wiążących na kolejne obrazy tak, żeby błąd przenoszenia tych punktów był jak najmniejszy.



Rys. 7. Aerotriangulacja jednoszeregowego bloku zdjęć za pomocą modyfikacji algorytmu LMP
[opr. wł.]

Algorytm LMP w procesie orientacji wzajemnej obrazów pozyskanych z niskiego pułapu pozwolił na optymalizację przenoszenia punktów wiążących na kolejne obrazy. Inicjalizację procesu rozpoczęto od wczytania parametrów kamery, fotopunktów i punktów kontrolnych. Wybrano takie same parametry kamery dla całego opracowywanego bloku. Po wykonaniu autokalibracji określono parametry początkowe dla procesu optymalizacji przenoszenia punktów wiążących na kolejne obrazy. Empirycznie zmodyfikowano region zaufania lokalizacji punktów wiążących, w określonych przedziałach przewidywania. Kluczową zawartością algorytmu regionu zaufania jest to, jak obliczyć krok próbny regionu zaufania i jak zdecydować, czy krok próbny powinien zostać zaakceptowany. Region zaufania jest dostępny na początku, następnie konstruowany jest przybliżony model, który jest rozwijany w obszarze zaufania, dając rozwiązanie s , które nazywa się krokiem próbnym. Kolejno wybierana jest funkcja, która służy do aktualizacji następnego regionu zaufania i do wyboru nowego punktu iteracji [44]. Promień regionu zaufania ma kluczowe znaczenie dla powodzenia kroku. Jeśli region jest zbyt duży, model może nie dać dobrego przybliżenia. W praktyce promień obszaru zaufania jest wybierany na podstawie powodzenia modelu. Jeśli model jest wiarygodny, to znaczy, że dokładnie przewiduje lokalizację punktu wiążącego.

2.1.2. Wyniki

Badania przeprowadzono na podstawie dwóch niezależnych zestawów danych. Pierwszy z nich pozyskano za pomocą BSP Trimble UX-5, natomiast drugi zestaw pozyskano za pomocą systemu VTOL WingtraOne. Obie platformy wyposażone były w jednczęstotliwościowe odbiorniki GPS, rejestrujące dane z częstotliwością 10 Hz. Dane pozyskano z pułpu 250 m nad powierzchnią terenu. Pokrycie poprzeczne i podłużne zdjęć wynosiło 75%. Na obszarze opracowania zaprojektowano i pomierzono sygnalizowane fotopunkty. Punkty te pomierzono z wykorzystaniem techniki RTK z użyciem obserwacji GNSS. Tylko częściowa dostępność do obszaru opracowania spowodowała, że pomierzono niewielką liczbę fotopunktów. Wobec tego faktu do dalszych badań wykorzystano punkty wiążące, wygenerowane w procesie aerotriangulacji cyfrowej całego bloku. Punkty te były przypadkowo rozmieszczone na całym obszarze testowym. Aby zapewnić równomierne rozmieszczenie punktów wiążących na obszarze opracowania, wykorzystano metodę regresji liniowej, opierającą się na zależności liniowej, w której krzywa dopasowywana jest do danych czyli współrzędnych (X, Y) punktów wiążących. Dla pierwszego zestawu danych wyróżniono cztery bloki testowe. Wyrównanie dla każdego z nich prowadzono w dwóch wariantach, gdzie punkty kontrolne stanowiły punkty pomierzonej osnowy fotogrametrycznej, natomiast fotopunkty wybierano spośród punktów wiążących wygenerowanych w trakcie wyrównania całego bloku. Wyboru fotopunktów w pierwszym wariantie, dokonywano na podstawie dwóch kryteriów: jeden punkt wiążący minimum na trzech zdjęciach i punkty o najmniejszych błędach średniokwadratowych. Po automatycznej selekcji punktów wiążących, prowadzono selekcję wizualną i do dalszego opracowania wybierano punkty położone w miejscowościach charakterystycznych, jednoznacznie identyfikowalnych na zdjęciach. Drugi wariant stanowiło wyrównanie tego samego bloku zdjęć, co w wariantie pierwszym, przy wykorzystaniu tych samych punktów kontrolnych. Z kolei fotopunkty, wybierano na podstawie dodatkowego kryterium regresji liniowej. Wykorzystanie zależności liniowej zapewniało równomierność rozmieszczenia fotopunktów na obszarze opracowania, ze szczególnym uwzględnieniem krawędzi bloku zdjęć.

Tab. 2. Podsumowanie wyrównania bloków testowych [opr. wl.]

Opis	1 blok testowy	2 blok testowy	3 blok testowy
	1 wariant/ 2 wariant	1 wariant/ 2 wariant	1 wariant/ 2 wariant
Warunki pogodowe	zachmurzenie umiarkowane		
Liczba zdjęć	12	25	13
Błąd średni typowego spostrzeżenia σ_0 [μm]/[pix]	7,0/1,4 6,3/1,3	7,3/1,5 6,9/1,4	7,9/1,6 7,5/1,5
Liczba fotopunktów	26/13	43/17	46/17
Liczba punktów kontrolnych	6	4	4
Liczba punktów wiążących	1 509/1 545	2 483/2 604	2 422/2 450
Wartość odchylenia standardowego a priori współrzędnych (X, Y, Z) fotopunktów i punktów kontrolnych (X, Y, Z) [m]	0,03		
Odchylenie standardowe współrzędnych [m]:	X	0,12/0,09	0,12/0,12
	Y	0,14/0,12	0,13/0,11
	Z	0,05/0,04	0,05/0,05
RMSE współrzędnych fotopunktów [m]:	X	0,04/0,04	0,04/0,03
	Y	0,04/0,03	0,05/0,04
	Z	0,19/0,17	0,18/0,17
RMSE współrzędnych punktów kontrolnych [m]:	X	0,05/0,02	0,05/0,03
	Y	0,03/0,01	0,08/0,05
	Z	0,22/0,09	0,16/0,09
MX ₀ [m]	0,13/0,12	0,12/0,09	0,09/0,09
MY ₀ [m]	0,11/0,09	0,10/0,08	0,11/0,08
MZ ₀ [m]	0,08/0,09	0,08/0,08	0,12/0,10
M ω [°]	0,054/0,043	0,047/0,042	0,056/0,054
M φ [°]	0,046/0,036	0,040/0,040	0,066/0,046
M κ [°]	0,011/0,009	0,009/0,009	0,014/0,008

W Tab. 2 przedstawiono wyniki wyrównania trzech bloków testowych. Błąd średni typowego spostrzeżenia (σ_0) dla wyrównania pierwszego bloku ukształtował się na poziomie 7,0 μm w pierwszym wariantie i 6,3 μm w drugim wariantie. Dla wyrównania drugiego bloku, σ_0 ukształtował się na poziomie 7,3 μm w pierwszym wariantie i 6,9 μm w wariantce drugim. W wyniku wyrównania trzeciego bloku otrzymano błąd średni typowego spostrzeżenia na poziomie 7,9 μm w pierwszym wariantie i 7,5 μm w wariantce drugim. W wyniku wyrównania otrzymano również błędy średnokwadratowe (liczone z poprawek wyrównawczych) położenia fotopunktów dla współrzędnych X, Y, które dla pierwszego bloku wynosiły odpowiednio 0,04 m w pierwszym wariantie wyrównania oraz 0,03-0,04 m w drugim wariantie. Z kolei dla współrzędnej Z wartość ta wynosiła 0,19 m w pierwszym wariantie i 0,17 m w drugim wariantie wyrównania. Dla drugiego bloku zdjęć wartość RMSE dla współrzędnych poziomych wynosiła 0,04-0,05 m w pierwszym wariantie wyrównania i 0,03-0,04 m w drugim wariantie wyrównania. Natomiast dla współrzędnej Z wartość ta wynosiła 0,18 m w pierwszym wariantie

i 0,17 m w drugim wariantie wyrównania. Dla trzeciego bloku zdjęć wartość RMSE dla współrzędnych poziomych wynosiła 0,04-0,05 m w pierwszym wariantie wyrównania i 0,03-0,05 m w drugim wariantie wyrównania. Natomiast dla współrzędnej Z wartość ta wynosiła 0,19 m w pierwszym wariantie i 0,22 m w drugim wariantie wyrównania. W odniesieniu do niezależnych punktów kontrolnych wartości błędów średniokwadratowych (liczonych jako różnice między współrzędnymi wyznaczonymi w wyniku wyrównania, a współrzędnymi wyznaczonymi z pomiarów terenowych) dla współrzędnych poziomych dla pierwszego bloku zdjęć ukształtowały się w przedziale 0,03-0,05 m w wariantie pierwszym i 0,01-0,02 m w wariantie drugim. Dla współrzędnej Z wartość ta wynosiła 0,22 m w wariantie pierwszym i 0,09 m w wariantie drugim. Dla drugiego bloku zdjęć wartość RMSE dla współrzędnych poziomych wyniosła 0,05-0,08 m w pierwszym wariantie i 0,03-0,05 m w drugim wariantie wyrównania. Dla współrzędnej Z wartość ta wyniosła 0,16 m w pierwszym wariantie i 0,09 m w wariantie drugim wyrównania. Dla trzeciego bloku zdjęć wartość RMSE dla współrzędnych poziomych wyniosła 0,04-0,08 m w pierwszym wariantie i 0,02 m w drugim wariantie wyrównania. Dla współrzędnej Z wartość ta wyniosła 0,14 m w pierwszym i 0,10 m w drugim wariantie wyrównania. W odniesieniu do dokładności wyznaczenia współrzędnych terenowych środków rzutów (X_0 , Y_0 , Z_0) dla pierwszego bloku testowego wartość odchyleń standardowych otrzymanych z wyrównania ukształtowała się w granicach 0,08-0,13 m w pierwszym wariantie i 0,09-0,12 m w drugim wariantie wyrównania. Dla drugiego bloku testowego wartość odchyleń standardowych uzyskanych z wyników wyrównania ukształtowała się w granicach 0,08-0,12 m w pierwszym wariantie i 0,08-0,09 m w drugim wariantie wyrównania. Dla trzeciego bloku testowego wartości odchyleń standardowych z wyników wyrównania ukształtowały się w granicach 0,09-0,12 m w pierwszym wariantie i 0,08-0,10 m w drugim wariantie wyrównania. Biorąc pod uwagę dokładność wyznaczenia elementów kątowych orientacji zewnętrznej (ω , φ , κ), uzyskane wartości odchyleń standardowych ukształtowały się dla pierwszego bloku testowego w przedziale 0,011-0,054° w pierwszym wariantie i 0,009-0,043° w drugim wariantie wyrównania. Dla drugiego bloku testowego wartości odchyleń standardowych ukształtowały się w przedziale 0,009-0,047° w pierwszym wariantie i 0,009-0,042° w drugim wariantie wyrównania. Dla trzeciego bloku testowego wartości odchyleń standardowych ukształtowały się w przedziale 0,014-0,066° w pierwszym wariantie i 0,008-0,054° w drugim wariantie wyrównania. Na podstawie uzyskanych wyników wyrównania trzech bloków testowych w dwóch wariantach stwierdzono, że drugi wariant wyrównania

poprawił wyniki wyrównania średnio o 16%. W związku z czym czwarty blok testowy wyrównano z zastosowaniem drugiego wariantu (wg autorskiej metody). Uzyskane wyniki porównano z wynikami wyrównania metodą LMP (Tab. 3).

Tab. 3. Porównanie wyników wyrównania bloku zdjęć zmodyfikowaną metodą regresji liniowej i metodą LMP [opr. wł.]

Opis	Metoda regresji liniowej		Metoda LMP
	IV blok testowy		
Warunki pogodowe	zachmurzenie umiarkowane		
Liczba zdjęć	12	12	
Błąd średni typowego spostrzeżenia σ_0 [μm]/[pix]	5,5/1,1	4,2/0,9	
Liczba fotopunktów	12	2	
Liczba punktów kontrolnych	5	3	
Wartość odchylenia standardowego apriori współrzędnych (X, Y, Z) fotopunktów i punktów kontrolnych [m]	0,03		
Odchylenie standardowe współrzędnych [m]:	X	0,27	0,21
	Y	0,32	0,18
	Z	0,36	0,20
RMSE współrzędnych (X, Y, Z) fotopunktów [m]:	X	0,04	0,03
	Y	0,03	0,03
	Z	0,13	0,04
RMSE współrzędnych (X, Y, Z) punktów kontrolnych [m]:	X	0,07	0,07
	Y	0,09	0,08
	Z	0,12	0,12
MX ₀ [m]		0,08	0,09
MY ₀ [m]		0,09	0,08
MZ ₀ [m]		0,11	0,11
M ω [°]		0,083	0,076
M φ [°]		0,085	0,073
M κ [°]		0,021	0,018

Na podstawie wyników wyrównania bloku zdjęć (Tab. 3) metodą regresji liniowej stwierdzono, że dla czwartego bloku zdjęć błąd średni typowego spostrzeżenia ukształtował się na poziomie 5,5 μm , wartość RMSE położenia fotopunktów (X, Y, Z) wynosiła 0,03-0,13 m, wartość RMSE położenia punktów kontrolnych (X, Y, Z) wyniosła 0,07-0,12 m. Dla wyznaczenia współrzędnych terenowych środków rzutów (X₀, Y₀, Z₀) uzyskane wartości odchyleń standardowych ukształtowały się na poziomie 0,08-0,11 m, a dla elementów kątowych orientacji zewnętrznej (ω , φ , κ) 0,021-0,085°. Metoda LMP pozwoliła na uzyskanie następujących wyników wyrównania: błąd średni typowego spostrzeżenia ukształtował się na poziomie 4,2 μm , wartość RMSE położenia fotopunktów (X, Y, Z) wynosiła 0,03-0,04 m, wartość RMSE położenia punktów kontrolnych (X, Y, Z) wyniosła 0,07-0,12 m. Dla wyznaczenia współrzędnych terenowych środków rzutów (X₀, Y₀, Z₀) uzyskane wartości odchyleń standardowych ukształtowały się na poziomie 0,08-0,11 m, a dla elementów kątowych orientacji zewnętrznej (ω , φ , κ) 0,018-0,076°.

W celu potwierdzenia wiarygodności otrzymanych wyników wyrównania bloku dwiema metodami, dokonano analizy statystycznej wyników. W tym celu określono przedziały ufności o prawdopodobieństwie 95% [45] dla uzyskanych błędów średniokwadratowych współrzędnych (X , Y , Z) fotopunktów i punktów kontrolnych. Wyznaczono przedział ufności dla średniej w populacji o rozkładzie normlanym $N(m, \sigma)$. Przedział ufności dla parametru m tego rozkładu obliczono ze wzoru [45]:

$$P\left(\bar{X} - t_{\alpha, n-1} \frac{S(x)}{\sqrt{n-1}} < m < \bar{X} + t_{\alpha, n-1} \left(\frac{S(x)}{\sqrt{n-1}}\right)\right) = 1 - \alpha \quad (1)$$

gdzie:

n – liczебность próby losowej;

\bar{X} – średnia z próby losowej;

S – odchylenie standardowe z próby;

t_α – ma rozkład Studenta z $n - 1$ stopniami swobody.

Dla autorskiej metody wyrównania jednoszeregowego bloku zdjęć, opartej o zmodyfikowaną metodę regresji liniowej przedział ufności RMSE fotopunktów dla współrzędnej X mieścił się w granicach: $0,04 < m < 0,07$. Dla współrzędnej Y przedział ufności RMSE wyniósł $0,03 < m < 0,06$. Dla współrzędnej Z , przedział ufności to $0,09 < m < 0,13$. Przedziały ufności RMSE obliczono również dla współrzędnych (X , Y , Z) punktów kontrolnych. Obliczono, iż przedział ufności RMSE dla współrzędnej X mieścił się w granicach: $0,04 < m < 0,08$. Dla współrzędnej Y , przedział ufności wyniósł $0,02 < m < 0,12$. Dla współrzędnej Z przedział ufności to $0,09 < m < 0,15$. Na podstawie otrzymanych wyników można zauważyc, że uzyskane wyniki spełniają zadane kryterium poziomu ufności. Dla metody opartej o zmodyfikowany algorytm LMP przedział ufności wartości RMSE dla współrzędnych X fotopunktów mieścił się w granicach: $-0,10 < m < 0,15$. Dla współrzędnej Y przedział ufności wyniósł $-0,09 < m < 0,16$. Dla współrzędnej Z przedział ufności, to $-0,21 < m < 0,29$. Przedziały ufności RMSE współrzędnej X dla punktów kontrolnych mieścił się w granicach: $0,04 < m < 0,10$. Dla współrzędnej Y przedział ufności wyniósł $0,02 < m < 0,14$. Dla współrzędnej Z , przedział ufności to $0,11 < m < 0,15$. Uzyskane wyniki potwierdzają spełnienie zadanego kryterium przedziału ufności.

2.1.3. Dyskusja i analiza otrzymanych wyników

Na podstawie uzyskanych wyników wyrównania jednoszeregowego bloku zdjęć dokonano ich analizy, porównując wyniki wyrównania przeprowadzonego niezależnie dwiema metodami. Ponadto wyniki odniesiono do dotychczas prowadzonych badań prezentowanych w literaturze. Wyrównanie bloku zdjęć autorską metodą, opierającą się na zmodyfikowanej metodzie regresji liniowej przeprowadzono w dwóch wariantach. Na podstawie analizy wyników wyrównania trzech bloków zdjęć stwierdzono poprawę dokładności wyrównania w drugim wariantie (równomierne rozmieszczenie fotopunktów) dla pierwszego bloku zdjęć średnio o 24%, dla drugiego bloku zdjęć średnio o 16%, dla trzeciego bloku zdjęć średnio o 26%. W drugim wariantie wyrównania wartość błędu średniego typowego spostrzeżenia zmniejszyła się średnio o 17%. Wartość RMSE położenia fotopunktów (X, Y, Z) zmniejszyła się średnio o 14%, a wartość RMSE położenia punktów kontrolnych (X, Y, Z) zmniejszyła się średnio o 51%. Wartość odchylenia standardowego współrzędnych terenowych środków rzutów (X_0, Y_0, Z_0) zmniejszyła się średnio o 11%. Z kolei wartość odchylenia standardowego dla elementów kątowych (ω, φ, κ) zmniejszyła się średnio o 17%. Drugi wariant wyrównania zapewnił równomierne rozmieszczenie fotopunktów, co przełożyło się na poprawę dokładności wyrównania średnio o 16%. Uzyskane wyniki wyrównania potwierdziły zasadność wykorzystania zmodyfikowanej metody regresji liniowej w procesie wyrównania jednoszeregowego bloku zdjęć. Ponadto przeprowadzona analiza statystyczna wyników potwierdziła powszechnie występującą w fotogrametrii regułę, iż wartości błędów średniokwadratowych dla współrzędnej pionowej Z są większe niż dla współrzędnych poziomych (X, Y). Dodatkowo w ramach analizy, porównano wyniki wyrównania bloku zdjęć autorską metodą zmodyfikowanej regresji liniowej z wynikami wyrównania zmodyfikowanym algorytmem LMP. Biorąc pod uwagę: błąd średni typowego spostrzeżenia, RMSE położenia fotopunktów (X, Y, Z), RMSE położenia punktów kontrolnych (X, Y, Z), odchylenie standardowe współrzędnych terenowych środków rzutów (X_0, Y_0, Z_0) i odchylenie standardowe dla elementów kątowych (ω, φ, κ), stwierdzono nieznacznie gorsze wyniki wyrównania autorską metodą w porównaniu do wyrównania algorytmem LMP. W literaturze znaleźć można opracowania badające wpływ rozmieszczenia punktów osnowy fotogrametrycznej na dokładność wyrównania bloku zdjęć [11-13]. Prezentowane w nich wyniki badań potwierdzają zwiększenie dokładności wyników wyrównania przy równomiernym rozmieszczeniu punktów osnowy fotogrametrycznej. Autorska metoda wyrównania zmodyfikowaną metodą

regresji liniowej jest zgodna z tą zasadą. Z uwagi na fakt, że w publikacji pierwszej rozpatrywano szczególny przypadek wyrównania bloku zdjęć jakim jest blok jednoszeregowy, zwrócono uwagę również na zapewnienie pokrycia fotopunktami i punktami kontrolnymi krawędzi bloku. W literaturze istnieją badania pokazujące poprawę wyników wyrównania bloku przy zapewnieniu pokrycia właśnie na krawędziach [16, 45]. Ponadto analiza stanu wiedzy wykazała, że dotychczas prowadzono badania również nad wpływem konfiguracji rozmieszczenia fotopunktów i punktów kontrolnych [45-46], jednak wyniki są niejednoznaczne, dlatego wciąż pojawiają się nowe opracowania w tym temacie. Autorzy [45] prezentują wyrównanie w trzech różnych konfiguracjach fotopunktów i punktów kontrolnych, przy zastosowaniu różnych oprogramowań. Wyniki wskazują, że wykorzystanie dodatkowych parametrów wyrównania, wyraźnie wpływa na poprawę wyników wyrównania. Podobne wnioski przedstawiono w pracy Rango i in. [46]. Wyniki wyrównania jednoszeregowego bloku zdjęć zmodyfikowanym algorytmem LMP, potwierdziły pojawiające się we wcześniejszych pracach badawczych wnioski o zasadności zastosowania algorytmu LMP [47-49]. Autorska metoda wyrównania jednoszeregowego bloku zdjęć w porównaniu do drugiej metody, bazującej na zmodyfikowanym algorytmie LMP dała nieznacznie gorsze wyniki wyrównania, średnio o 16%.

Reasumując, głównym celem badań w publikacji pierwszej było opracowanie metody wyrównania jednoszeregowych bloków zdjęć z niskiego pułapu, przy ograniczonym dostępie do całego obszaru opracowania. Skutkiem ograniczonego dostępu do obszaru opracowania był brak możliwości założenia i pomiaru osnowy fotogrametrycznej na całym obszarze badań. Pierwsza metoda badawcza opierała się na autorskim podejściu do wyrównania bloku jednoszeregowego przy wykorzystaniu punktów wiążących. Dobór punktów wiążących odbywał się w oparciu o zmodyfikowaną metodę regresji liniowej, co miało zapewnić równomierność rozlożenia punktów na całym obszarze. Druga metoda badawcza opierała się na jednej z metod optymalizacji nieliniowej – zmodyfikowanym algorytmie LMP. Wyrównanie bloku zdjęć obiema metodami przeprowadzono z uwzględnieniem dodatkowych parametrów. W niniejszej publikacji rozwiązano problem badawczy związany z wyrównaniem jednoszeregowego bloku zdjęć na potrzeby zbierania danych o przeszkodach lotniczych. Ponadto poruszono problematykę ograniczonego dostępu do obszaru opracowania, przez co niemożliwe jest pokrycie całego obszaru punktami osnowy fotogrametrycznej. Autorska metoda wyrównania jednoszeregowego bloku zdjęć umożliwiła uzyskanie zbliżonych dokładności wyrównania jak w przypadku

zmodyfikowanego algorytmu LMP, dzięki czemu możliwe jest podniesienie dokładności generowanych produktów fotogrametrycznych takich jak chmura punktów i ortofotomapa. Na podstawie przeprowadzonych badań stwierdzono, że **uwzględnienie dodatkowych parametrów w procesie aerotriangulacji pozwoliło na podwyższenie dokładności wyrównania bloku jednoszeregowego przy ograniczonej liczbie fotopunktów dla terenów niedostępnych, przy zastosowaniu niskobudżetowych bezzałogowych statków powietrznych, wyposażonych w jednoczestotliwościowe odbiorniki GPS.**

2.2. METODYKA POPRAWY DOKŁADNOŚCI OKREŚLENIA POZYCJI BSP WYPOSAŻONYCH W JEDNOCZĘSTOTLIWOŚCIOWE ODBIORNIKI NA POTRZEBY ZBIERANIA DANYCH O PRZESZKODACH LOTNICZYCH [Publikacja 2]

2.2.1. Metodyka zwiększenia dokładności pozycjonowania BSP

W drugiej publikacji przedstawiono wyniki badań, których celem było opracowanie metody zwiększenia dokładności pozycjonowania bezzałogowych statków powietrznych wyposażonych w odbiorniki jednoczestotliwościowe, a przez to dokładności produktów fotogrametrycznych, na potrzeby zbierania danych o przeszkodach lotniczych, bez pomiaru fotopunktów. Badania przeprowadzono w oparciu o dwie metody. Pierwsza z nich, prezentująca klasyczne rozwiązanie nawigacyjne dla metody kodowej SPP z użyciem danych nawigacyjnym GPS. Druga metoda, przedstawiająca algorytm metody SPP z użyciem produktów IGS (tj. efemerydy precyzyjnej EPH, precyzyjnych zegarów CLK, formatu IONEX, formatu DCB, formatu ANTEX). Dla tych dwóch metod przeprowadzono wyrównanie fotogrametrycznego bloku zdjęć bez pomiaru fotopunktów. Na podstawie otrzymanych wyników dokonano analizy dokładności pozycjonowania BSP oraz wyrównania bloku zdjęć.

W pracy do określenia pozycji BSP zastosowano dwie metody, tj. klasyczne rozwiązanie nawigacyjne dla metody kodowej SPP z użyciem danych nawigacyjnym GPS oraz algorytm metody SPP z użyciem produktów IGS. Metoda pozycjonowania kodowego SPP z użyciem danych nawigacyjnych GPS z efemerydy pokładowej została zrealizowana w oparciu o podstawowe równanie obserwacyjne [50-51]. Algorytm pozycjonowania z tego równania jest klasycznym rozwiązaniem pozycji w metodzie kodowej SPP. Z równania wyznaczane są współrzędne BSP w układzie geocentrycznym XYZ w postaci parametrów (X, Y, Z). Algorytm metody pozycjonowania SPP z użyciem produktów IGS bazuje na podstawowym równaniu obserwacyjnym [52-53], gdzie wyznaczane są współrzędne pozycji BSP. Algorytm pozycjonowania z tego równania jest rozwiązaniem pozycji w metodzie kodowej SPP, w którym zastosowano produkty IGS.

2.2.2. Wyniki

Badania przeprowadzono na podstawie jednego zestawu danych, które pozyskano za pomocą BSP typu VTOL WingtraOne. Platforma wyposażona była w jednczęstotliwościowy odbiornik GPS, rejestrujący dane z częstotliwością 10 Hz. Nalot zrealizowano w otoczeniu lotniska Radom-Sadków. Cały blok testowy składał się z 850 obrazów położonych w 35 szeregach, pozyskanych z wysokości 250 m nad powierzchnią terenu. Pokrycie poprzeczne i podłużne zdjęć wynosiło 75%.

Poprawę dokładności wyznaczenia pozycji bezzałogowego statku powietrznego na potrzeby zbierania danych o przeszkodach przeprowadzono z wykorzystaniem metody SPP oraz metody SPP + IGS. Dla tych dwóch metod przeprowadzono wyrównanie bloku zdjęć bez pomiaru osnowy fotogrametrycznej. Na podstawie otrzymanych wyników dokonano analizy dokładności pozycjonowania BSP oraz wyrównania bloku zdjęć. W ramach analizy uzyskanych wyników badań obliczono dokładności pozycjonowania BSP. W pierwszej kolejności określono błędy pozycji, czyli porównano wyznaczone współrzędne BSP z pozycją referencyjną lotu obliczoną z techniki różnicowej RTK-OTF [54]. W tym celu błędy pozycji obliczono jak poniżej [55-56]:

$$dX = \begin{cases} X_{SPP} - X_{RTK} \\ X_{IGS} - X_{RTK} \end{cases} \quad (2)$$

$$dY = \begin{cases} Y_{SPP} - Y_{RTK} \\ Y_{IGS} - Y_{RTK} \end{cases} \quad (3)$$

$$dZ = \begin{cases} Z_{SPP} - Z_{RTK} \\ Z_{IGS} - Z_{RTK} \end{cases} \quad (4)$$

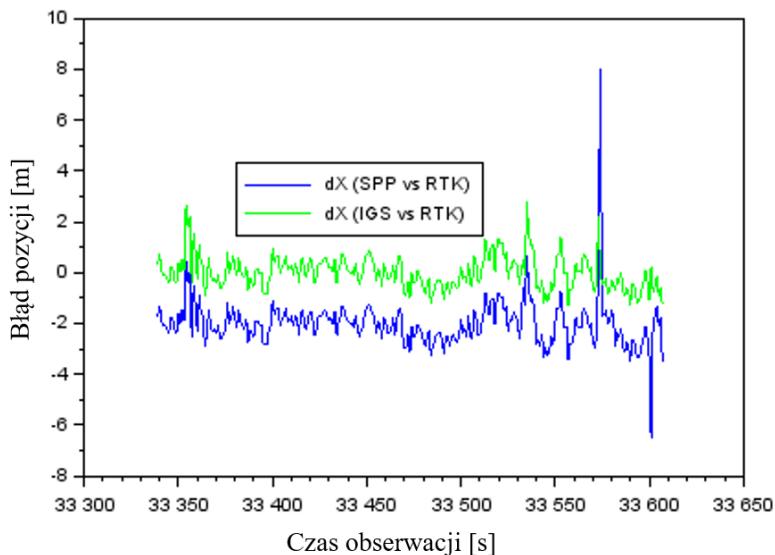
gdzie:

(dX, dY, dZ) – błędy pozycji;

$(X_{SPP}, Y_{SPP}, Z_{SPP})$ – współrzędne BSP z równania obserwacyjnego dla metody kodowej SPP;

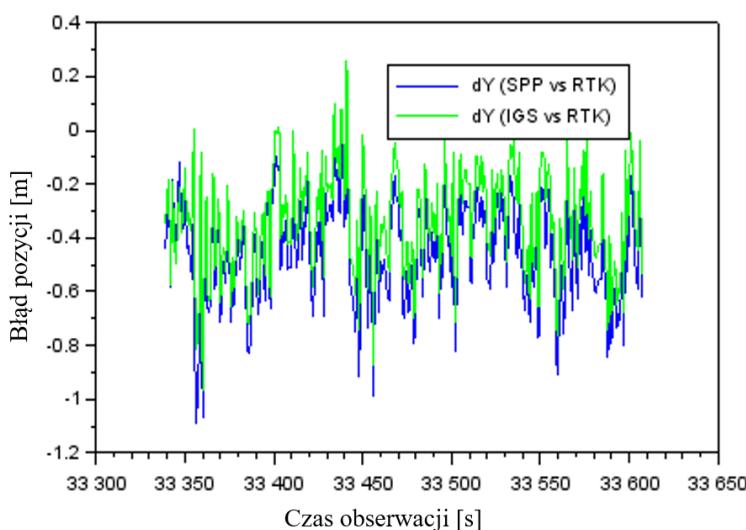
$(X_{IGS}, Y_{IGS}, Z_{IGS})$ – współrzędne BSP z równania obserwacyjnego dla metody kodowej SPP z użyciem produktów IGS;

$(X_{RTK}, Y_{RTK}, Z_{RTK})$ – współrzędne referencyjne lotu BSP z rozwiązania RTK-OTF.



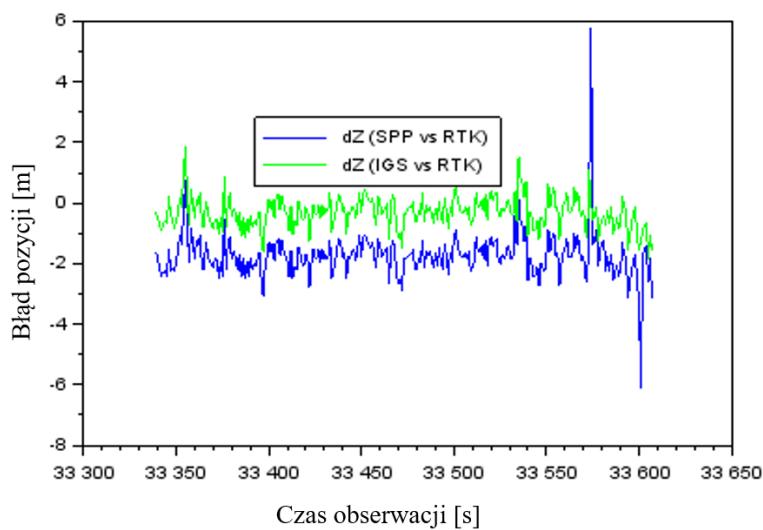
Rys. 8. Błędy pozycji BSP wzdłuż osi X [opr. wl.]

Na Rys. 8 pokazano błędy pozycji wzdłuż osi X (2) dla reprezentatywnego lotu BSP. Wartości błędów pozycji wzdłuż osi X dla porównania współrzędnych z równaniem dla klasycznej metody kodowej SPP i techniki RTK-OTF wynoszą od -6,5 m do +8,1 m z wartością średnią równą -2,1 m. Z kolei błędy pozycji dla równania dla metody kodowej SPP z użyciem produktów IGS dla porównania uzyskanych współrzędnych i techniki RTK-OTF wynoszą od -1,3 m do +2,8 m z wartością średnią równą -0,1 m. Na podstawie porównania można stwierdzić, że zastosowanie produktów IGS w metodzie SPP umożliwiło poprawę dokładności wyznaczenia pozycji BSP wzdłuż osi X o około 95% względem klasycznego rozwiązania SPP.



Rys. 9. Błędy pozycji wzdłuż osi Y [opr. wl.]

Na Rys. 9 przedstawiono błędy pozycji wzdłuż osi Y na podstawie równania (3). Wartości błędów pozycji wzdłuż osi Y dla porównania współrzędnych z równaniem dla klasycznej metody kodowej SPP i techniki RTK-OTF wynoszą od -1,1 m do +0,2 m z wartością średnią równą -0,5 m. Z kolei błędy pozycji dla równania dla metody kodowej SPP z użyciem produktów IGS dla porównania uzyskanych współrzędnych i techniki RTK-OTF wynoszą od -1,0 m do +0,3 m z wartością średnią równą -0,3 m. Na podstawie porównania można stwierdzić, że zastosowanie produktów IGS w metodzie SPP umożliwiło poprawę dokładności wyznaczenia pozycji BSP wzdłuż osi Y o 40% względem klasycznego rozwiązania SPP.



Rys. 10. Błędy pozycji wzdłuż osi Z [opr. wł.]

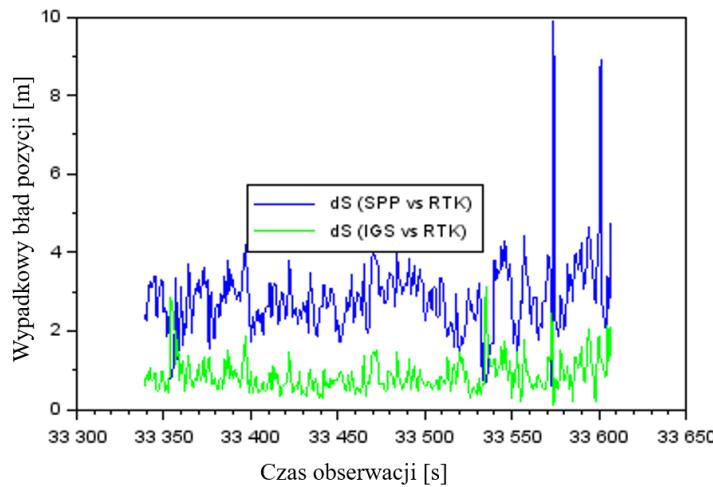
Na Rys. 10 przedstawiono błędy pozycji wzdłuż osi Z na podstawie równania (4). Wartości błędów pozycji wzdłuż osi Z dla porównania współrzędnych z równaniem dla klasycznej metody kodowej SPP i techniki RTK-OTF wynoszą od -6,1 m do +5,8 m z wartością średnią równą -1,7 m. Z kolei błędy pozycji dla równania metody kodowej SPP z użyciem produktów IGS dla porównania otrzymanych współrzędnych i techniki RTK-OTF wynoszą od -1,8 m do +1,8 m z wartością średnią równą -0,3 m. Na podstawie porównania można stwierdzić, że zastosowanie produktów IGS w metodzie SPP umożliwiło poprawę dokładności wyznaczenia pozycji BSP wzdłuż osi Z o ponad 80% względem klasycznego rozwiązania SPP.

W aspekcie zbierania danych o przeszkodach lotniczych przy użyciu BSP szczególnie istotnym elementem jest określenie wypadkowej dokładności platformy w przestrzeni 3D. Na tej podstawie konieczne jest obliczenie parametru dokładności pozycjonowania BSP w przestrzeni 3D jak zapisano poniżej [57]:

$$dS = \begin{cases} \sqrt{dX_{SPP}^2 + dY_{SPP}^2 + dZ_{SPP}^2} \\ \sqrt{dX_{RTK}^2 + dY_{RTK}^2 + dZ_{RTK}^2} \end{cases} \quad (5)$$

gdzie:

dS – wypadkowa dokładność wyznaczenia pozycji BSP i zarazem wektor przesunięcia współrzędnych XYZ w przestrzeni 3D pomiędzy rozwiązaniem z równania dla klasycznej metody SPP i metody SPP z użyciem produktów IGS, a pozycją referencyjną lotu z techniki RTK-OTF.



Rys. 11. Wypadkowe błędy pozycji w przestrzeni 3D [opr. wl.]

Na Rys. 11 pokazano wyniki wyznaczenia parametru dS dla pozycji BSP. I tak w przypadku porównania współrzędnych z równania dla klasycznej metody kodowej SPP i techniki RTK-OTF wartości parametru dS wynoszą od 0,6 m do 9,9 m z wartością średnią równą 2,8 m. Natomiast tak w przypadku porównania współrzędnych z równania dla klasycznej metody kodowej SPP i techniki RTK-OTF wartości parametru dS wynoszą od 0,1 m do 3,2 m z wartością średnią równą 0,9 m. Porównując uzyskane wyniki parametru dS stwierdzono, że zastosowanie produktów IGS w metodzie SPP umożliwiło redukcję parametru dS o około 67% względem klasycznego rozwiązania nawigacyjnego SPP.

Dane obrazowe pozyskane podczas nalotu zostały opracowane za pomocą specjalistycznych narzędzi fotogrametrycznych. Dokonano wyrównania bloku obrazów pozyskanych z niskiego pułapu w oparciu o algorytm wyrównania metodą niezależnych wiązek. Następnie zdefiniowano orientację wewnętrzną obrazów oraz wprowadzono przybliżone elementy orientacji zewnętrznej każdego obrazu. Punkty wiążące wygenerowano automatycznie z wykorzystaniem strategii cyfrowej korelacji obrazów opartej na metodzie najmniejszych kwadratów. Wyrównanie bloku przeprowadzono bez

pomiaru fotopunktów dla dwóch wariantów metody pozycjonowania BSP. Pierwszy wariant zakładał pozycjonowanie BSP metodą kodową SPP, natomiast drugi wariant zakładał pozycjonowanie BSP metodą kodową SPP z użyciem produktów IGS. Uzyskane wyniki w pierwszym i drugim wariantie porównano na podstawie obliczonych dokładności elementów liniowych (MX_0 , MY_0 , MZ_0) i kątowych orientacji zewnętrznej ($M\omega$, $M\varphi$, $M\kappa$) wyrównywanych bloków zdjęć (Tab. 4).

Tab. 4. Podsumowanie wyrównania bloków testowych [opr. wł.]

Opis	1 wariant: wyrównanie bez fotopunktów (pozycjonowanie SPP)	2 wariant: wyrównanie bez fotopunktów (pozycjonowanie SPP + IGS)	Wyrównanie z fotopunktami
MX_0 [m]	3,16	2,31	0,14
MY_0 [m]	4,08	3,22	0,13
MZ_0 [m]	7,22	1,98	0,17
$M\omega$ [°]	0,243	0,215	0,061
$M\varphi$ [°]	0,211	0,172	0,068
$M\kappa$ [°]	0,256	0,194	0,078

Na podstawie wyników wyrównania bloku zdjęć (Tab. 4) stwierdzono, że wyrównanie w pierwszym wariantie (pozycjonowanie SPP, bez udziału fotopunktów) pozwoliło na uzyskanie wartości odchyлеń standardowych dla współrzędnych terenowych środków rzutów (X_0 , Y_0 , Z_0) na poziomie 3,16-7,22 m, a dla elementów kątowych orientacji zewnętrznej (ω , φ , κ) 0,211-0,256°. Dla drugiego wariantu wyrównania (pozycjonowanie SPP+IGS, bez udziału fotopunktów) wartości odchyłeń standardowych dla współrzędnych terenowych środków rzutów (X_0 , Y_0 , Z_0) ukształtowały się na poziomie 1,98-3,22 m, natomiast wartości odchyłeń standardowych dla elementów kątowych orientacji zewnętrznej (ω , φ , κ) wyniosła od 0,172-0,215°. Na podstawie porównania wariantu pierwszego i drugiego stwierdzono poprawę wyników wyrównania w wariantie pozycjonowania metodą SPP z użyciem produktów IGS średnio o 38%. Wyrównanie bloku zdjęć z fotopunktami pozwoliło na uzyskanie wartości odchyłeń standardowych dla współrzędnych terenowych środków rzutów (X_0 , Y_0 , Z_0) na poziomie 0,13-0,17 m, a dla elementów kątowych orientacji zewnętrznej (ω , φ , κ) 0,061-0,078°.

2.2.3. Dyskusja i analiza otrzymanych wyników

Na podstawie uzyskanych wyników pozycjonowania BSP przeprowadzonego dwiema metodami: metodą kodową SPP oraz algorytmem metody SPP z użyciem produktów IGS dokonano ich porównania, co umożliwiło ocenę dokładności pozycjonowania. Wyniki odniesiono do dotychczas prowadzonych badań prezentowanych w literaturze. Zastosowanie metody pozycjonowania BSP poprzez użycie algorytmu metody

SPP z użyciem produktów IGS pozwoliło na znaczne zwiększenie dokładności wyznaczenia pozycji BSP dla pozyskania danych o przeszkodach lotniczych, wzdłuż osi X o 95%, wzdłuż osi Y o 40%, oraz wzdłuż osi Z o 80%. Wyznaczenie pozycji BSP na podstawie algorytmu metody SPP z użyciem produktów IGS pozwoliło na zwiększenie dokładności wyrównania bloku zdjęć dla elementów liniowych orientacji zewnętrznej średnio o 58% i elementów kątowych orientacji zewnętrznej średnio o 18%. W efekcie, przedstawiona w niniejszej pracy metodyka zwiększenia dokładności pozycjonowania BSP pozwoliła na uzyskanie dokładności wyrównania bloku bez pomiaru punktów osnowy fotogrametrycznej na poziomie wyższym niż 3,22 m. Dotychczasowe prace naukowe w tematyce określenia pozycji BSP dla jednoczestotliwościowego odbiornika GPS, w większości wskazywały na konieczność zakładania i pomiaru osnowy fotogrametrycznej na obszarze opracowania, w celu zwiększenia dokładności generowanych produktów fotogrametrycznych [11-13]. W badaniach, szczególną uwagę zwracano na wpływ liczby fotopunktów i ich rozmieszczenia na całym obszarze opracowania [14-17, 58]. Wiele wyników badań jest niejednoznacznych w tej kwestii, dlatego temat związany z dokładnością określenia pozycji BSP, a w efekcie dokładnością generowanych produktów fotogrametrycznych wciąż ewoluje. Shahbazi i in. [17] w swoich badaniach pokazują możliwość osiągnięcia wysokiej dokładności wyrównania bloku pozyskanego z BSP wyposażonego w odbiornik GPS. Wyniki eksperymentu badawczego przedstawione w pracy Himanshu i in. [59] pokazały podniesienie dokładności wyznaczenia pozycji BSP metodą rozwiązania SPP wzbogaconą o filtr Kalmana, gdzie uzyskano wyniki określenia pozycji BSP z dokładnością wyższą niż 10 m. W artykule Angrisano i in. [60] zaprezentowano podwyższenie dokładności metody absolutnej pozycjonowania BSP, opierając algorytm wyznaczenia pozycji na modelu średniej ważonej. Dzięki czemu, mimo trudnego do pomiaru obszaru miejskiego uzyskano dokładność poziomą poniżej 10 m.

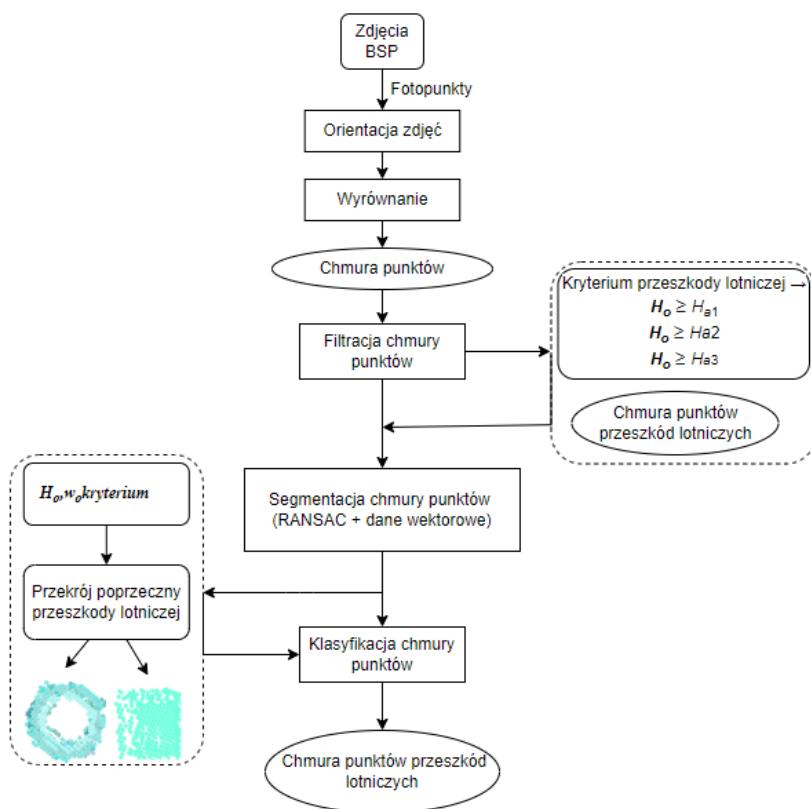
Podsumowując głównym celem badań w drugiej publikacji z cyklu było opracowanie metody zwiększenia dokładności pozycjonowania BSP na podstawie algorytmu metody SPP z użyciem produktów IGS, a pośrednio dzięki opracowanej metodzie, dokładności produktów fotogrametrycznych. Badania przeprowadzono w oparciu o dwie metody. Pierwsza z nich, prezentująca klasyczne rozwiązanie nawigacyjne dla metody kodowej SPP z użyciem danych nawigacyjnym GPS. Druga metoda, przedstawiająca algorytm metody SPP z użyciem produktów IGS (tj. efemerydy precyzyjnej, precyzyjnych zegarów, formatu IONEX, formatu DCB, formatu ANTEX). Dla tych dwóch metod przeprowadzono

wyrównanie fotogrametrycznego bloku zdjęć bez pomiaru fotopunktów. Na podstawie przeprowadzonych badań stwierdzono, że **zastosowanie algorytmu metody pozycjonowania absolutnego SPP z użyciem produktów IGS pozwoliło na zwiększenie dokładności wyznaczenia pozycji bezzałogowego statku powietrznego dla pozyskiwania danych o przeszkodach lotniczych.**

2.3. METODYKA DETEKCJI I KLASYFIKACJI WYBRANYCH PRZESZKÓD LOTNICZYCH NA PODSTAWIE GĘSTEGO DOPASOWANIA OBRAZÓW BSP [Publikacja 3]

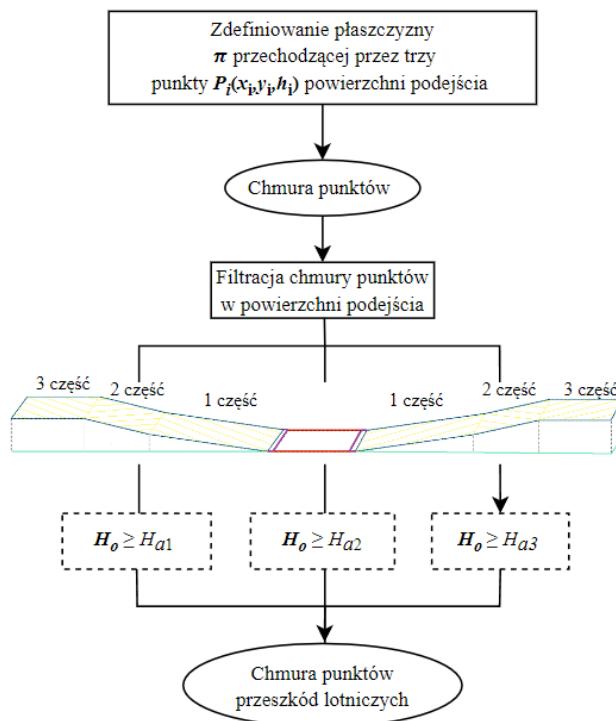
2.3.1. Metodyka detekcji przeskód lotniczych o wydłużonym kształcie

W trzeciej publikacji przedstawiono rezultaty badań, których celem było opracowanie metody detekcji przeskód lotniczych o charakterystycznym wydłużonym kształcie, zlokalizowanych w bliskim otoczeniu lotniska. Badania przeprowadzono w oparciu o modyfikację algorytmu RANSAC i autorski algorytm klasyfikacji przeskód lotniczych na podstawie chmury punktów (Rys. 12). Etap pierwszy detekcji obiektów stanowiła automatyczna filtracja chmury punktów, gdzie jako kryterium filtracji przyjęto wysokość przeskódy lotniczych, przebijających powierzchnie ograniczające przeskody. Następnie przeprowadzono segmentację chmury punktów stanowiących przeskody lotnicze przy wykorzystaniu zmodyfikowanego algorytmu RANSAC. W końcowym etapie detekcji zastosowano nowy algorytm klasyfikacji chmury punktów, mający na celu określenie rodzaju przeskódy lotniczej. Jako kryterium przyjęto stosunek wysokości obiektu do jego szerokości i zależności geometryczne obiektu w przekroju poprzecznym.



Rys. 12. Schemat detekcji przeskód lotniczych [opr. wl.]

Opracowana metoda detekcji przeszkodek lotniczych opierała się na filtracji nieprzetworzonej chmury punktów, która miała na celu wskazanie punktów, które mogą stanowić element przeszkodek lotniczej. Filtrację chmury punktów realizowano w otoczeniu lotniska dla obszaru zawierającego się w powierzchni ograniczającej przeszkodek, zwanej powierzchnią podejścia. Zasadniczym celem filtracji punktów było automatyczne wykrycie punktów, które przecinały płaszczyznę powierzchni podejścia. Zastosowanie kryterium wysokości pozwoliło na wykrycie punktów, które mogą należeć do przeszkodek lotniczych (Rys. 13).



Rys. 13. Schemat filtracji chmury punktów [opr. wl.]

Pierwszy etap filtracji chmury punktów polegał na zdefiniowaniu płaszczyzny, która będzie jednoznacznie identyfikowała punkty należące do powierzchni podejścia. W tym celu wykorzystano równanie płaszczyzny π (6) przechodzącej przez trzy punkty. Każde trzy niewspółliniowe punkty $P_i(x_i, y_i, h_i)$, gdzie $i = 1, 2, 3$, wyznaczają dokładnie jedną płaszczyznę π , która ją zawiera. Równanie tej płaszczyzny ma postać [61]:

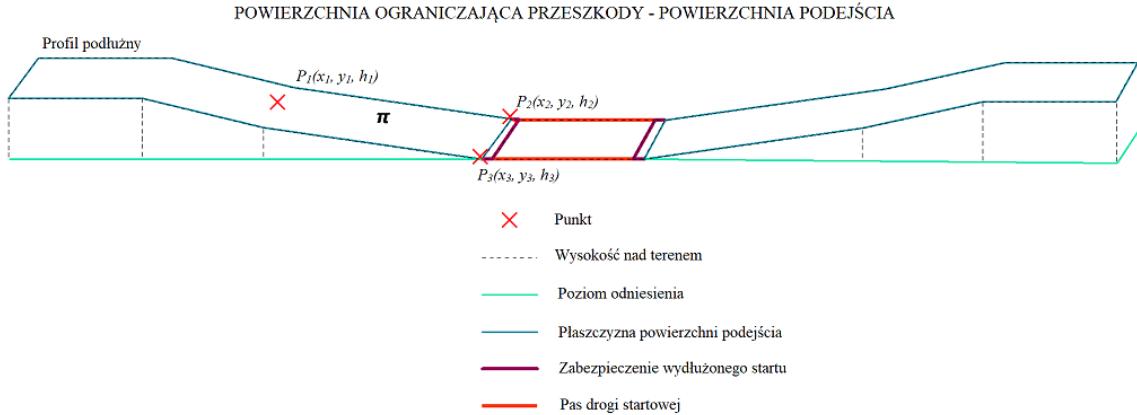
$$\pi: \begin{vmatrix} x - x_1 & y - y_1 & h - h_1 \\ x - x_2 & y - y_2 & h - h_2 \\ x - x_3 & y - y_3 & h - h_3 \end{vmatrix} = 0 \quad (6)$$

gdzie:

x, y, h – parametry równania płaszczyzny π ;

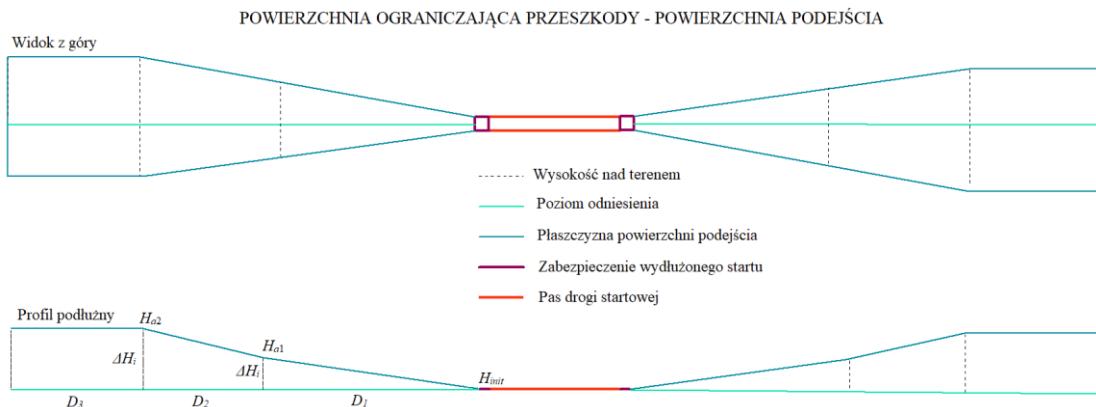
$x_{1-3}, y_{1-3}, h_{1-3}$ – współrzędne trzech punktów nie współliniowych.

Jako punkt $P_1(x_1, y_1, h_1)$ oraz punkt $P_2(x_2, y_2, h_2)$ przyjęto skrajne punkty, będące początkiem powierzchni podejścia (Rys. 14). Jako punkt $P_3(x_3, y_3, h_3)$ przyjęto punkt leżący na końcu powierzchni podejścia, przechodzący przez oś drogi startowej w odległości D od krawędzi pasa drogi startowej.



Rys. 14. Powierzchnia podejścia – profil podłużny [opr. wl.]

Po zdefiniowaniu płaszczyzn π powierzchni podejścia, przefiltrowano chmurę punktów, przyjmując za główne kryterium filtracji wysokość punktów (H). Obiekt w przestrzeni powietrznej znajdujący się w powierzchni podejścia posiada określoną wysokość (H_o). Jeśli H_o będzie równa bądź większa od wysokości powierzchni podejścia wtedy obiekt uznawany jest za przeszkodę lotniczą (Rys. 15).



Rys. 15. Powierzchnia ograniczająca przeszkody – powierzchnia podejścia (rzut z góry i przekrój poprzeczny) [opr. wl.]

Dla pierwszej części powierzchni podejścia obiekt będzie przeszkodą jeśli [62]:

$$H_o \geq H_{a1} \quad (7)$$

gdzie:

H_o – wysokość przeszkody lotniczej;

H_{a1} – wysokość powierzchni podejścia dla pierwszej płaszczyzny.

Wysokość pierwszej części powierzchni podejścia obliczono na podstawie następującego wzoru [62]:

$$H_{a1} = D_i \cdot i + H_{init} \quad (8)$$

gdzie:

D_i – odległość od pasa drogi startowej;

i – spadek;

H_{init} – wysokość n. p. m. na końcu pasa drogi startowej.

Dla drugiej części powierzchni podejścia obiekt będzie przeszkodą jeśli [62]:

$$H_o \geq H_{a2} \quad (9)$$

gdzie:

H_o – wysokość przeszkody lotniczej;

H_{a2} – wysokość powierzchni podejścia dla drugiej płaszczyzny.

Wysokość powierzchni podejścia obliczono na podstawie następującego wzoru [62]:

$$H_{a2} = D_i \cdot i + H_{a1} \quad (10)$$

gdzie:

D_i – odległość od pasa drogi startowej;

i – spadek;

H_{init} – wysokość n. p. m. na końcu pasa drogi startowej.

Dla trzeciej płaszczyzny podejścia obiekt będzie przeszkodą jeśli [62]:

$$H_o \geq H_{a3} \quad (11)$$

gdzie:

H_o – wysokość przeszkody lotniczej;

H_{a3} – wysokość powierzchni podejścia dla trzeciej płaszczyzny.

Wysokość trzeciej płaszczyzny powierzchni podejścia, która jest powierzchnią poziomą jest równa maksymalnej wysokości drugiej płaszczyzny i jest stała [62].

$$H_{a3} = \text{constans} \quad (12)$$

gdzie:

H_{a3} – wysokość powierzchni podejścia dla trzeciej płaszczyzny.

Punkty powyżej wyznaczonych płaszczyzn zostały sklasyfikowane jako punkty stanowiące przeszkodę lotniczą.

Drugą część metody stanowiła ekstrakcja płaskich cech przy użyciu zmodyfikowanego algorytmu RANSAC, działającego na punktach nienaziemnych sklasyfikowanych w poprzednim kroku. Modyfikacja algorytmu RANSAC polegała na dodaniu nowego parametru danych wektorowych, definiującego kształt i atrybuty obiektów (przeszkód lotniczych). Proces ten rozpoczął się od implementacji danych wektorowych o obiektach 2D na podstawie ortofotomapy. Atrybuty obiektów 2D zostały bezpośrednio wczytane do segmentowanych chmur punktów. Znajomość geometrii badanych obiektów umożliwiła precyzyjne dopasowanie chmury punktów do bazy danych o przeszkodach lotniczych i zapisanie atrybutów z warstwy 2D do struktury każdej segmentowanej chmury punktów. Etap inicjalizacji polegał na wyborze w sposób losowy minimalnego zbioru punktów, niezbędnego do jednoznacznego wyznaczenia parametrów estymowanego modelu geometrycznego. Jest to najmniejsza liczba k danych niezbędnych do jednoznacznego zdefiniowania założonego modelu geometrycznego. W przypadku ekstrakcji płaszczyzn, minimalny zbiór składa się z trzech punktów. Realizacja algorytmu rozpoczyna się od wylosowania wstępnie ustalonej liczby T_{iter} minimalnych zbiorów s_t (13) [31], która w trakcie algorytmu jest sukcesywnie modyfikowana [31].

$$s_t \in \{S \subset P, |S| = k\} \rightarrow M_t \quad (13)$$

gdzie:

s_t – minimalne zbiory punktów;

S – płaszczyzna;

P – zbiór punktów;

k – liczba danych;

M_t – model płaszczyzny przechodzącej przez trzy punkty.

W dalszej kolejności dla każdego ze zbiorów obliczane są parametry modelu M_t (w rozpatrywanym przypadku modelem jest płaszczyzna przechodząca przez trzy punkty). Zidentyfikowany model stanowi hipotezę, która podlega sprawdzeniu w następnym kroku – teście. Etap testu wymaga ustalenia wartości parametru m_d , określającego maksymalną odległość testowanego punktu od hipotetycznego modelu. Jeżeli punkt spełnia kryterium odległości, dodany zostaje do tzw. zbioru CS (ang. Consensus Set). W tej pracy zbiór składa się z danych, które uznane zostały za należące do rozpatrywanej płaszczyzny [31]:

$$CS_t \in \{p \in P, d(M_t, p) < m_d\} \quad (14)$$

$$d(M_i, p) \quad (15)$$

gdzie:

CS_t – minimalne zbiory punktów;

p – punkt;

P – zbiór punktów;

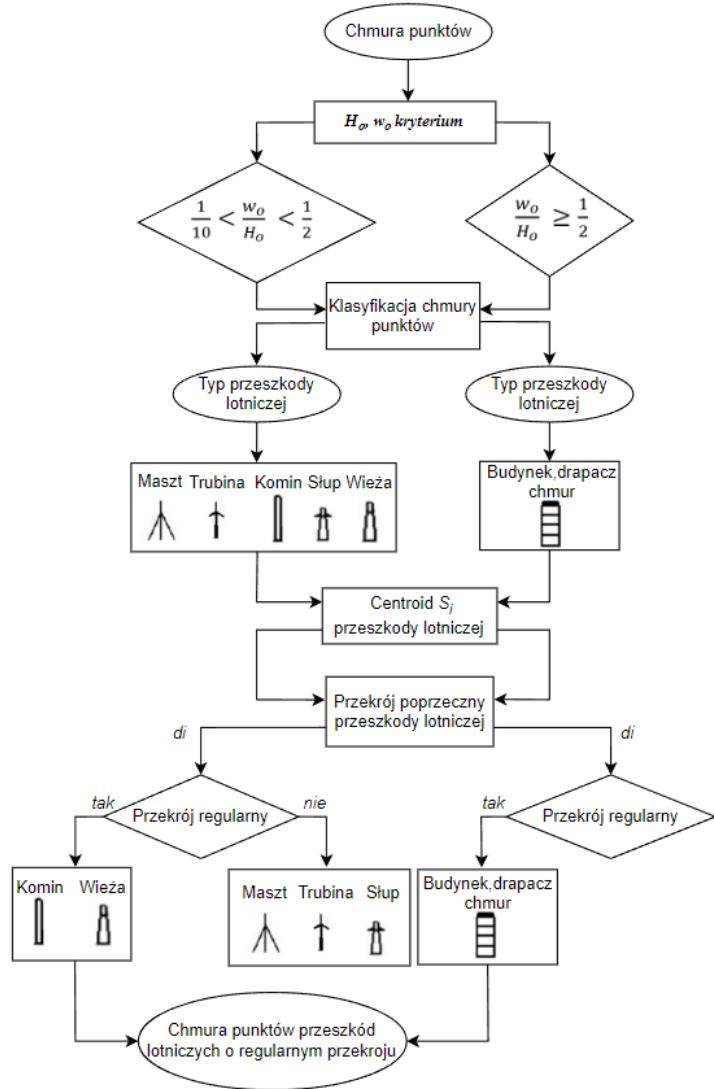
d – odległość punktu od założonego modelu;

m_d – maksymalną odległość testowanego punktu od hipotetycznego modelu;

M_i – założony model płaszczyzny przechodzącej przez trzy punkty.

Po wykonaniu testu (14) dla wszystkich danych, wybrany jest kolejny zbiór minimalny i w oparciu o niego powtórzona zostaje sekwencja dwóch kroków – hipotezy i testu. W przypadku znalezienia zbioru CS , zawierającego większą liczbę punktów od poprzedniego, dotychczasowy zbiór zastąpiony zostaje liczniejszym i zmodyfikowaną zostaje wartość T_{iter} (liczba próbek zbiorów minimalnych). Po skończonej identyfikacji pierwszej płaszczyzny opisany proces zostaje powtórzony z wyłączeniem punktów do niej zakwalifikowanych. Identyfikacja kolejnych płaszczyzn zostaje zakończona, gdy liczba punktów niedodanych do żadnej z nich jest mniejsza od założonej wartości progowej t_{rest} .

Ostatnią część opracowanej metody detekcji stanowiła klasyfikacja chmury punktów, mająca na celu selekcję przeszkód lotniczych reprezentujących grupę przeszkód o wydłużonym kształcie. Jako pierwsze kryterium klasyfikacji przyjęto wysokość obiektów określoną na podstawie chmur punktów. Drugie kryterium klasyfikacyjne bazowało na własnościach geometrycznych obiektów tworzonych przez chmury punktów (Rys. 16).



Rys. 16. Proces klasyfikacji przeszkód lotniczych [opr. wl.]

Przyjęto, że dla obiektów należących do grupy przeszkód: masztów, turbin wiatrowych, kominów, wież, słupów energetycznych i wieżowców, stosunek szerokości w_o obiektu do jego wysokości H_o [63] powinien zawierać się w następującym przedziale [62]:

$$\frac{1}{10} < \frac{w_o}{H_o} < \frac{1}{2} \quad (16)$$

gdzie:

w_o – szerokość przeszkody;

H_o – wysokość przeszkody.

Dla przeszkód lotniczych należących do grupy budynków stosunek szerokości w_o obiektu do jego wysokości H_o powinien zawierać się w przedziale [62]:

$$\frac{w_o}{H_o} \geq \frac{1}{2} \quad (17)$$

gdzie:

w_o – szerokość przeszkody;

H_o – wysokość przeszkody.

Przyporządkowane do odpowiednich grup przeskód chmury punktów poddano klasyfikacji z uwzględnieniem ich przekroju poprzecznego. W tym celu dla każdego obiektu wyznaczono jego centroid S_i , obliczając jego współrzędne (x_s, y_s) na podstawie następujących wzorów [64]:

$$x_s = \frac{\sum x_i}{n} \quad (18)$$

$$y_s = \frac{\sum y_i}{n} \quad (19)$$

gdzie:

x_s, y_s – współrzędne x, y centroidu;

x_i, y_i – współrzędne x, y punktu w chmurze punktów,

n – liczba punktów w chmurze punktów badanego obiektu.

Badane obiekty sklasyfikowano na podstawie odległości d_i (Rys. 17a, 17b) każdego punktu chmury punktów od centroidu S_i obiektu.



Rys. 17. Przekrój poprzeczny przeszkody lotniczej: (a) w kształcie koła, (b) w kształcie wieloboku [opr. wł.]

Na podstawie odległości punktów skrajnych chmury punktów, stanowiących krawędź obiektu, zdefiniowano grupę obiektów o przekroju regularnym i o przekroju nieregularnym. Dla obiektów o przekroju regularnym przyjęto, że jeżeli odległość od punktów skrajnych chmury punktów stanowiących krawędź obiektu jest stała, wtedy obiekty kwalifikowano do obiektów o przekroju poprzecznym w kształcie koła (Rys. 17a). Natomiast jeżeli odległość od punktów skrajnych chmury punktów stanowiących krawędź obiektu nie była stała, wtedy obiekty kwalifikowano do tych, których przekrój stanowił wielobok (Rys. 17b). Wobec powyższego obiekty z grupy kominów, wież, budynków i wieżowców kwalifikowano jako

obiekty o regularnym przekroju. Do obiektów o przekroju o nieregularnym kształcie zaliczono maszty, turbiny wiatrowe i słupy energetyczne. Do dalszych badań wykorzystano obiekty sklasyfikowane jako obiekty o regularnym przekroju.

2.3.2. Wyniki

Badania opisane w publikacji trzeciej przeprowadzono w bliskim otoczeniu lotniska Łask. Dane obrazowe pozyskano za pomocą BSP Trimble UX-5. Platforma wyposażona była w jednczęstotliwościowy odbiornik GPS, rejestrujący dane z częstotliwością 10 Hz. W skład kampanii pomiarowej wchodziło 30 bloków testowych, gdzie na każdy blok składało się średnio około 600 obrazów. Dane pozyskano z wysokości 250 m nad powierzchnią terenu. Naloty wykonano w kierunku wschód – zachód, przy założeniu, że pokrycie poprzeczne i podłużne wynosi 75%. Na obszarze opracowania zaprojektowano i pomierzono sygnalizowane fotopunkty. Wszystkie punkty zostały pomierzone z wykorzystaniem techniki RTK z użyciem obserwacji GNSS. Współrzędne terenowe fotopunktów zostały wyznaczone z błędem średnim $m_{x,y,z} = \pm 0,03$ m.

Na podstawie zdjęć pozyskanych z niskiego pułapu wygenerowano gęstą chmurę punktów na podstawie, której przeprowadzono detekcję przeszkód lotniczych i określono ich cechy geometryczne. Autorska metoda detekcji przeszkód lotniczych składała się z trzech zasadniczych etapów. Pierwszy z nich, to filtracja chmury punktów na podstawie wysokości – wstępna identyfikacja przeszkód lotniczych, następnie segmentacja chmury punktów 3D z wykorzystaniem zmodyfikowanego algorytmu RANSAC, uzupełnionego o dwuwymiarowe dane wektorowe przeszkód lotniczych w celu zwiększenia dokładności procesu segmentacji. Ostatni etap to klasyfikacja przeszkód lotniczych wg przyjętego kryterium wysokości i przekroju poprzecznego.

Dokładność wpasowania chmury punktów zbadano na podstawie danych referencyjnych zawartych w bazie eTOD. Określenie dokładności wpasowania chmury punktów przeprowadzono na podstawie wpasowania w płaszczyznę poziomą (współrzędne X, Y) oraz wpasowanie w płaszczyznę pionową (współrzędna Z). W tym celu obliczono: parametr dx jako różnicę pomiędzy otrzymaną współrzędną X, a współrzędną referencyjną X_{ref} , parametr dy jako różnicę pomiędzy otrzymaną współrzędną Y, a współrzędną referencyjną Y_{ref} oraz parametr dz jako różnicę pomiędzy otrzymaną współrzędną Z, a współrzędną referencyjną Z_{ref} . Analizę dokładności przeprowadzono dla ośmiu wykrytych przeszkód lotniczych (Tab. 5).

Tab. 5. Wartości statystyczne charakteryzujące dokładność wpasowania chmury punktów
[opr. w.l.]

Przeszkoda lotnicza	Parametr d_x [m]	Parametr d_y [m]	Parametr d_z [m]
Komin przemysłowy 1	0,02	0,03	0,03
Komin przemysłowy 2	0,03	0,01	0,04
Komin przemysłowy 3	0,02	0,02	0,02
Budynek 1	0,04	0,03	0,03
Budynek 2	0,05	0,04	0,02
Budynek 3	0,03	0,02	0,04
Budynek 4	0,02	0,05	0,04
Wieża ciśnień	0,02	0,03	0,03

Na podstawie otrzymanych wyników (Tab. 5) wpasowania chmury punktów stwierdzono, że różnica pomiędzy obliczoną wartością współrzędnej X, a wartością referencyjną mieściła się w przedziale 0,02-0,05 m. Różnica ta dla współrzędnej Y mieściła się w przedziale 0,01-0,05 m. Natomiast różnica dla współrzędnej Z mieściła się w przedziale 0,02-0,04 m. Uzyskane wyniki pozwalają potwierdzić skuteczność opracowanej metody detekcji przeszkoł lotniczych o wydłużonym kształcie z maksymalną różnicą pomiędzy otrzymanymi współrzędnymi poziomymi (X, Y), a współrzędnymi referencyjnymi wynoszącą 0,05 m, a dla współrzędnej pionowej (Z) 0,04 m.

2.3.3. Dyskusja i analiza otrzymanych wyników

Na podstawie wyników detekcji przeszkoł lotniczych o wydłużonym kształcie dokonano oceny jej dokładności. W tym celu uzyskane współrzędne (X, Y, Z) wykrytych przeszkoł lotniczych porównano ze współrzędnymi zawartymi w bazie eTOD. Wyniki odniesiono do aktualnego stanu wiedzy w zakresie wykrywania przeszkoł lotniczych. Metoda detekcji przeszkoł lotniczych o charakterystycznym wydłużonym kształcie, zlokalizowanych w bliskim otoczeniu lotniska, bazująca na modyfikacji algorytmu RANSAC i autorskim algorytmie klasyfikacji przeszkoł lotniczych na podstawie chmury punktów pozwoliła na ich prawidłowe wykrycie. Dla wykrytych przeszkoł lotniczych o wydłużonym kształcie uzyskano maksymalną różnicę pomiędzy otrzymanymi współrzędnymi (X, Y, Z), a współrzędnymi referencyjnymi wynoszącą 0,05 m. Uzyskane wyniki potwierdziły wcześniejsze występujące w literaturze wnioski, że algorytm RANSAC jest metodą wystarczającą do badania obiektów nieskomplikowanych geometrycznie [31]. Pomimo tych ograniczeń, przedstawiona metoda zapewnia wymaganą dokładność wykrywania przeszkoł lotniczych w płaszczyźnie poziomej 5 m i płaszczyźnie pionowej 3 m, biorąc pod uwagę strefę 2b zbierania danych o przeszkołach lotniczych [5, 7].

W badaniach Mitsevich [65] uzyskano dokładność wyznaczania przeszkód lotniczych na poziomie od 0,30 m do 0,50 m, gdzie do detekcji przeszkód lotniczych zastosowano trójwymiarowe modele wektorowe zintegrowane z danymi satelitarnymi. Pomimo uzyskania zadowalających wyników, przedstawiona metoda posiada pewne ograniczenia. Pierwszym ograniczeniem proponowanej metody, jak również innych podobnych algorytmów bazujących na wartościach statystycznych obrazu jest to, że może nie działać na niektórych konkretnych przykładach obrazów np. pozyskanych w bardzo złych warunkach atmosferycznych. W przypadku, gdy tylko część obiektu widocznego na obrazie będzie przesłonięta silną mgłą zastosowanie algorytmu spowoduje negatywne zaburzenie odwzorowania barw na obrazie, a w konsekwencji zdegraduje jakość spektralną obrazu. Kolejne ograniczenie wynikało z zawężenia badań do przeszkód lotniczych, które stanowiły obiekty wydłużone. Opracowana metoda znajduje zastosowanie przy badaniu obiektów, do których mogą należeć kominy przemysłowe, wieżowce itp.

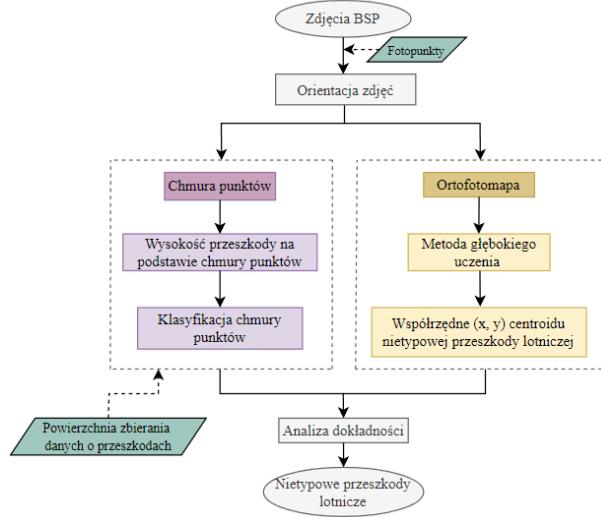
Reasumując głównym celem badań w niniejszej publikacji było opracowanie metody detekcji przeszkód lotniczych o charakterystycznym wydłużonym kształcie, zlokalizowanych w bliskim otoczeniu lotniska. Badania przeprowadzono w oparciu o modyfikację algorytmu RANSAC i autorski algorytm klasyfikacji przeszkód lotniczych na podstawie chmury punktów. Pierwszy etap opierał się na automatycznej filtracji chmury punktów, prowadzonej na podstawie wysokości przeszkód lotniczych przebijających powierzchnię ograniczającą przeszkody. Następnie przeprowadzono segmentację chmury punktów stanowiących przeszkody lotnicze, przy wykorzystaniu zmodyfikowanego algorytmu RANSAC. W końcowym etapie detekcji zastosowano nowy algorytm klasyfikacji chmury punktów, mający na celu określenie rodzaju przeszkody lotniczej. Jako kryterium przyjęto stosunek wysokości obiektu do jego szerokości i zależności geometryczne obiektu w przekroju porzecznym. Zastosowanie nowatorskiego podejścia do wykrywania przeszkód lotniczych na podstawie chmury punktów 3D, poprzez modyfikację algorytmu RANSAC w połączeniu z algorytmem klasyfikacji oraz filtracji chmury punktów pozwoliło na wykrycie przeszkód lotniczych o charakterystycznym, wydłużonym kształcie w bliskim otoczeniu lotniska. Na podstawie przeprowadzonych badań stwierdzono, że **segmentacja chmur punktów zmodyfikowanym algorytmem RANSAC poprzez zastosowanie odpowiedniej filtracji i segmentacji gęstej chmury punktów pozwoliła na wykrycie przeszkód lotniczych z dokładnością zgodną z przepisami EUROCONTROL i ICAO.**

2.4. AUTOMATYCZNE WYKRYWANIE NIETYPOWYCH PRZESZKÓD LOTNICZYCH NA PODSTAWIE OBRAZÓW Z BSP Z WYKORZYSTANIEM ALGORYTMU YOLO [Publikacja 4]

2.4.1. Metodyka automatycznej detekcja i klasyfikacja nietypowych przeszkód lotniczych

W czwartej publikacji przedstawiono wyniki badań, których celem było opracowanie metody automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych na podstawie danych pozyskanych z BSP. W badaniach wykorzystano nowe podejście do wykrywania obiektów, opierające się na fuzji algorytmu YOLOv3 do detekcji na obrazie i autorskiego algorytmu klasyfikacji chmury punktów (Rys. 18). Połączenie danych obrazowych i chmury punktów stanowiło podstawę do wykrycia przeszkód lotniczych i określenia jej wysokości.

W niniejszej pracy do badań zastosowano ortofotomapę oraz chmurę punktów powstałe w wyniku przetworzenia danych pozyskanych z niskiego pułapu. Ortofotomapa stanowiła bazę do wykrycia nietypowych przeszkód lotniczych na obrazie, prowadzonego przy pomocy algorytmu YOLOv3, który bazuje na splotowej sieci neuronowej CNN. Na podstawie wykrytych obiektów na ortofotomapiie wyznaczono ich współrzędne (x , y) centroidu C_i . Na podstawie tych współrzędnych, wyznaczono obiekty w chmurze punktów. W dalszej części badań zdefiniowano strefę 2b zbierania danych o przeszkodach, na podstawie której określono, które z wykrytych obiektów przebijają powierzchnie stref i tym samym biorą udział w następnym etapie badań. W tym celu wyznaczono wysokości nietypowych przeszkód lotniczych na podstawie chmury punktów. Wysokości określono na podstawie algorytmu, zakładającego iteracyjne przeszukiwanie chmury punktów względem wyznaczonego centroidu przeskody lotniczej. Wykryte przeskody lotnicze poddano klasyfikacji. Jako cechę charakterystyczną definiującą przeskodę nietypową przyjęto ich wysmukły kształt oraz nieregularny przekrój poprzeczny. Analizę dokładności opracowanej metody wykonano na podstawie przeprowadzonych eksperymentów i danych o przeszkodach lotniczych zawartych w eTOD oraz w suplementach, zawierających informacje o tymczasowych przeszkodach lotniczych w otoczeniu lotnisk.



Rys. 18. Schemat detekcji nietypowych przeszkód lotniczych [opr. wl.]

Detekcję nietypowych przeszkód lotniczych opartą na analizie obrazu wykonano przy wykorzystaniu algorytmu YOLOv3. W wyniku opracowania danych pozyskanych z BSP wygenerowano ortofotomapę, która stała się źródłem danych do utworzenia zbioru danych o nietypowych przeszkodach lotniczych. Algorytm YOLOv3 wykryte na obrazach obiekty oznaczał obwiedniami (ramkami granicznymi). Sieć YOLO została zoptymalizowana i przeszkolona na opracowanych zbiorach danych, po czym dokonano sprawdzenia skuteczności wykrywania obiektów. Wykrycie tymczasowych przeszkód lotniczych przy wykorzystaniu algorytmu YOLOv3 pozwoliło na określenie współrzędnych (x, y) centroidu C_i każdej przeszkody. Określenie współrzędnych centroidu dla przeszkody, która w przekroju poprzecznym była nieprzecinającym się wielokątem zdefiniowanym przez N wierzchołków $(x_0, y_0), (x_1, y_1), \dots, (x_{n-1}, y_{n-1})$ jest punktem (C_x, C_y) , obliczono wg poniższego wzoru [66]:

$$C_x = \frac{1}{6A} \sum_{i=0}^{n-1} (x_i + x_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (20)$$

$$C_y = \frac{1}{6A} \sum_{i=0}^{n-1} (y_i + y_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (21)$$

gdzie:

x_i, y_i – współrzędne x, y wierzchołków wielokąta;

A – obszar podpisany wielokąta;

$C(x, y)$ – centroid wielokąta.

Obszar podpisany wielokąta obliczono wg wzoru [66]:

$$A = \frac{1}{2} \sum_{i=0}^{n-1} (x_i - x_{i+1}y_i) \quad (22)$$

gdzie:

x_i, y_i – współrzędne x, y wierzchołków wielokąta.

Współrzędne (x, y) centroidu C_i przeszkód, które w przekroju są elipsą ze skrajnymi punktami A_i, B_i o znanych współrzędnych (x, y), obliczono wg poniższego wzoru [67]:

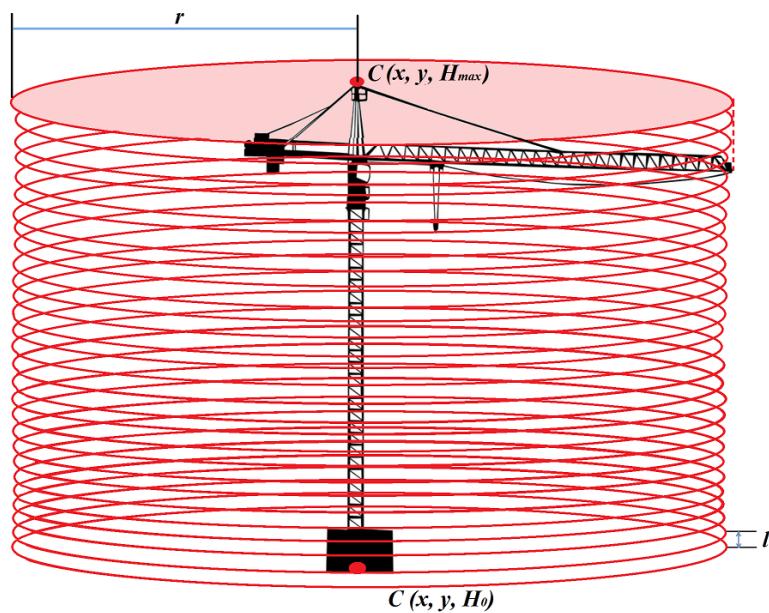
$$C_i = \left(\frac{x_A + x_B}{2}, \frac{y_A + y_B}{2} \right) \quad (23)$$

gdzie:

x_A, y_A – współrzędne x, y skrajnego punktu elipsy A;

x_B, y_B – współrzędne x, y skrajnego punktu elipsy B.

Wyznaczenie współrzędnych centroidu każdej z wykrytych przeszkód było kluczowe dla kolejnego etapu badań, czyli wyznaczenia wysokości przeszkód lotniczych. Określenie wysokości H_{max} przeszkode nietypowej polegało na iteracyjnym przeszukiwaniu chmury punktów w celu wykrycia najwyższego punktu należącego do badanego obiektu. Przedmiotem badań były nietypowe przeszkode lotnicze, do których zakwalifikowano m. in. dźwig budowlany, turbiny wiatrowe i słupy energetyczne. Aby określić wysokość dźwigu budowlanego, wykorzystano dane na temat centroidu przeszkode $C(x, y)$ oraz określono maksymalny promień r zasięgu wysięgnika (Rys. 19).



Rys. 19. Wyznaczenie centroidu wykrytej przeszkode [opr. wt.]

Do zdefiniowania wartości maksymalnej promienia r posłużono się danymi określającymi parametry techniczne tego typu obiektów. Etap początkowy przeszukiwania chmury punktów stanowiło określenie wysokości początkowej H_0 chmury punktów. Dla centroidu przeszkody C_i o znanych współrzędnych (x, y) , zdefiniowano płaszczyznę S_i o promieniu r . Realizację algorytmu (iteracja $i = 1$) rozpoczęto od przeszukiwania płaszczyzny S_i dla wysokości H_0 . Odnalezione punkty A chmury punktów należały do zbioru danych B chmury punktów przeszkody tymczasowej. Kolejny etap ($i = 2$) wykonano w odległości $l = H_0 + 0,10$ m. Każda kolejna iteracja wykonywana była dla płaszczyzny S_i o 0,10 m wyżej od poprzedniej. Poszukiwanie wysokości realizowano do momentu odnalezienia ostatniego punktu zawierającego się w zbiorze chmury punktów B [68]:

$$H_{max} \rightarrow A \in B, B \geq 1 \quad (24)$$

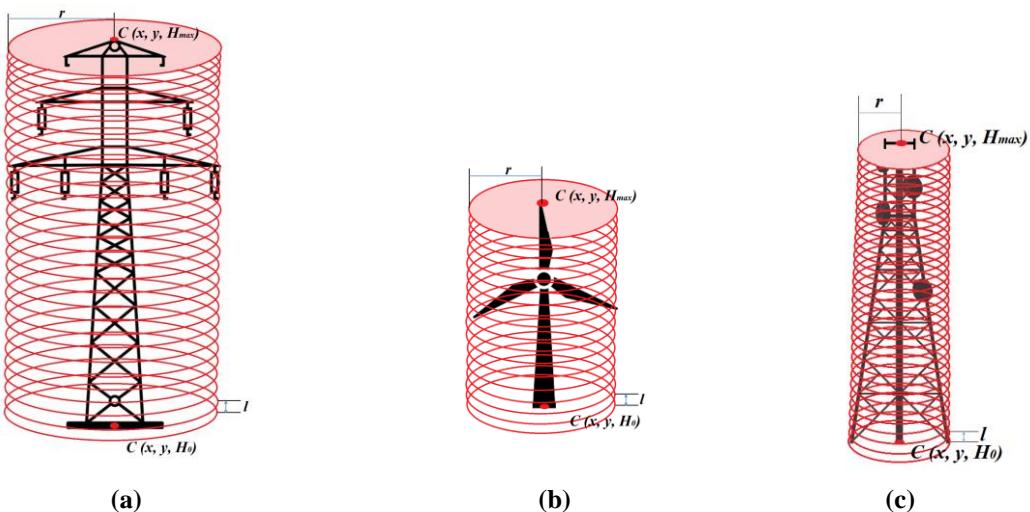
gdzie:

H_{max} – wysokość przeszkody lotniczej;

A – wyszukane punkty chmury punktów;

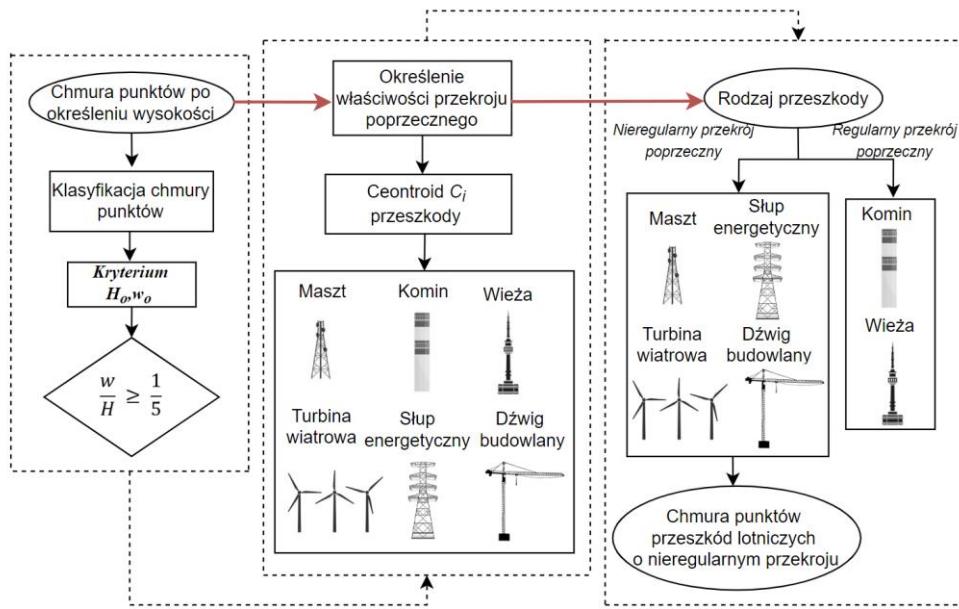
B – zbiór punktów chmury punktów przeszkody lotniczej.

Wyznaczenie wysokości dla pozostałych typów przeszkód (turbiny wiatrowe, słupy energetyczne, maszty) wykonano analogicznie jak w przypadku określenia wysokości dźwigu budowlanego. Wykorzystano współrzędne (x, y) centroidu C przeszkody oraz promień r zasięgu badanej przeszkody (Rys. 20). Do zdefiniowania wartości promienia r posłużono się maksymalnymi parametrami technicznymi danego typu obiektu. W dalszym etapie wykonywano iteracyjne przeszukiwanie chmury punktów w celu określenia wysokości przeszkód H_{max} .



Rys. 20. Wyznaczenie wysokości wykrytej przeszkody: (a) słup energetyczny, (b) turbina wiatrowa, (c) maszt [opr. wl.]

Klasyfikacja chmury punktów miała na celu detekcję przeszkód lotniczych, należących do grupy przeszkód nietypowych. Schemat postępowania klasyfikacyjnego zaprezentowano poniżej (Rys. 21). Jako cechę charakterystyczną definiującą przeszkodę nietypową przyjęto ich wysmukły kształt oraz nieregularny przekrój poprzeczny. Za pierwsze kryterium klasyfikacji przyjęto wysokość obiektów określona na podstawie chmury punktów. Drugie kryterium klasyfikacyjne bazowało na zależności rozmieszczenia punktów chmury punktów względem centroidu C_i badanego obiektu.



Rys. 21. Schemat klasyfikacji chmury punktów [opr. wl.]

Przyjęto, że dla obiektów należących do grupy przeszkód wysmukłych stosunek szerokości w obiektu do jego wysokości H powinien spełniać warunek [69]:

$$\frac{w}{H} \geq \frac{1}{5} \quad (25)$$

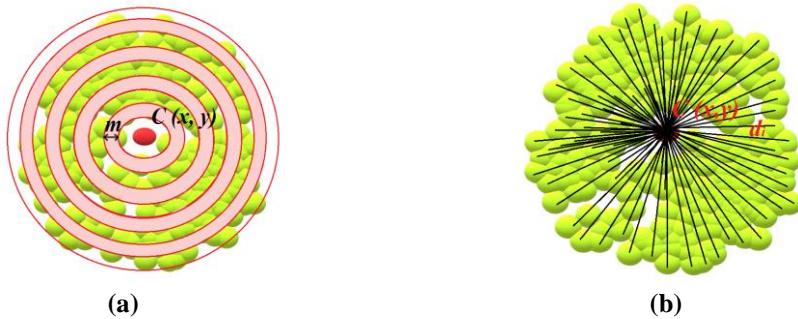
gdzie:

w – szerokość przeszkody lotniczej;

H – wysokość przeszkody lotniczej.

Następnie przyporządkowane do odpowiednich grup przeszkód, chmury punktów poddano klasyfikacji z uwzględnieniem ich przekroju poprzecznego, gdzie zbadano charakterystykę rozmieszczenia punktów chmury punktów względem centroidu C_i . W tym celu wykonano iteracyjne przeszukiwanie chmury punktów w pasach p_i o stałej szerokości m (Rys. 22a).

Określenie położenia punktów chmury punktów w pasach p_i wykonano na podstawie obliczenia odległości d_i punktów chmury od centroidu obiektu C_i (Rys. 22b).



Rys. 22. Analiza rozmieszczenia punktów chmury punktów względem centroidu C_i :

- (a) przeszukiwanie chmury punktów w pasach p_i o stałej szerokości m , (b) określenie położenia punktów chmury punktów w pasach p_i wykonano na podstawie obliczenia odległości d_i punktów chmury od centroidu obiektu C_i [opr. wł.]

Maksymalną liczbę iteracji i przeszukiwania chmury punktów określono na podstawie stosunku maksymalnej odległości d_{max} punktu chmury punktów od centroidu C_i do szerokości m pasa p_i , wg następującego wzoru [68]:

$$i_{max} = \frac{d_{max}}{m} \quad (26)$$

gdzie:

i_{max} – maksymalna liczba iteracji;

d_{max} – maksymalna odległość punktu chmury punktów od centroidu;

m – szerokość pasa przeszukiwania chmury punktów.

2.4.2. Wyniki

Badania przeprowadzono dla dwóch niezależnych zestawów danych. Dla pierwszego, dla którego obszar opracowania stanowiła strefa 2b zbierania danych o przeszkodach wokół lotniska Łask, dane pozyskano za pomocą platformy Trimble UX-5. Kampania pomiarowa składała się z 15 bloków testowych, gdzie każdy blok stanowiło około 600 zdjęć. Drugi obszar badawczy stanowiła strefa 2b zbierania danych o przeszkodach dla lotniska Radom-Sadków. Zbiór danych składał się z 14 bloków, co stanowiło około 600 zdjęć. Dane pozyskano za pomocą systemu VTOL WingtraOne. Platformy BSP wykorzystane w badaniach wyposażone były w jednczęstotliwościowe odbiorniki GPS, rejestrujące dane z częstotliwością 10 Hz. Dane pozyskano z pułapu 250 m nad powierzchnią terenu. Pokrycie poprzeczne i podłużne zdjęć wynosiło 75%. Na obszarze opracowania zaprojektowano i pomierzono sygnalizowane fotopunkty. Punkty te

pomierzono z wykorzystaniem techniki RTK z użyciem obserwacji GNSS. Badania przeprowadzono w dwóch etapach. W pierwszym etapie pozyskano zdjęcia z BSP, następnie przetworzono te dane w specjalistycznym oprogramowaniu fotogrametrycznym. W trakcie opracowania danych wygenerowano gęstą chmurę punktów, którą wykorzystano do określenia wysokości nietypowych przeszkód lotniczych oraz ortofotomapę, którą użyto do detekcji nietypowych przeszkód lotniczych na podstawie algorytmu YOLOv3 oraz do określenia ich lokalizacji. Detekcję nietypowych przeszkód lotniczych rozpoczęto od badań na ortofotomapie. W tym celu wykorzystano sieci neuronowe, które wyodrębniają cechy z obrazów. Dla wykrytych obiektów określono ich współrzędne (x , y) centroidu C_i . Pozyskane w ten sposób dane na temat lokalizacji nietypowych przeszkód lotniczych pozwoliły na odnalezienie tych obiektów w chmurze punktów i były początkiem do dalszych badań na chmurze punktów. W pierwszym etapie do detekcji nietypowych przeszkód lotniczych wykorzystano algorytm YOLOv3, który bazuje na splotowych sieciach neuronowych. Sieci neuronowe wyodrębniają cechy z obrazów poprzez warstwy splotu i wykorzystują warstwy pełnego połączenia do przewidywania prawdopodobieństwa wyjścia i informacji o położeniu ramki ograniczającej. Niestandardowe bazy danych obrazów z obiektemi w kategorii: dźwig budowlany, słup energetyczny, turbina wiatrowa i maszt zostały stworzone na podstawie ortofotomap, będących częścią cyfrowej bazy danych dla terenu Polski utworzonej przez PZGiK. Większość wykorzystanych obrazów zawierała więcej niż jeden obiekt dla trzech kategorii: dźwig budowlany, słup energetyczny i turbina wiatrowa. Natomiast w kategorii maszt większość obrazów zawierała pojedyncze obiekty reprezentujące tę kategorię. Obiekty wszystkich kategorii zostały w pełni umieszczone w obrębie ramek. Przypadki, w których na obrazie widoczna była tylko część obiektu, zostawał on wyłączony z zestawu treningowego lub nie zostawał oznaczony jako przynależny do konkretnej kategorii. Eksperyment badawczy został przeprowadzony na 800 obrazach, które zawierały łącznie 1023 obiekty. Obraz podzielono losowo na trzy zestawy danych: treningowych, co stanowiło 70% obrazów – wykorzystywanych do oszacowania wag sieci neuronowej, walidacyjnych, co stanowiło 20% obrazów – wykorzystywanych do sprawdzania trenowanej sieci oraz testowych, co stanowiło 10% obrazów – wykorzystywanych do sprawdzenia działania sieci po treningu. Zestaw danych treningowych składał się z 560 obrazów zawierających łącznie 716 obiektów, zestaw danych walidacyjnych składał się ze 160 obrazów zawierających łącznie 205 obiektów, natomiast zestaw danych testowych składał się z 80 obrazów zawierających łącznie 102 obiekty.

Wyniki wykrywania nietypowych przeszkód lotniczych na danych z zestawu testowego zobrazowano na Rys. 23a-23d. Próbkę ramki ograniczającej dla kategorii słup energetyczny w kolorze zielonym przedstawiono na Rys. 23a, 23d. Próbkę ramki ograniczającej dla kategorii słup energetyczny w kolorze różowym przedstawiono na Rys. 23b-23c. Próbkę ramki ograniczającej dla kategorii turbina wiatrowa w kolorze piaskowym przedstawiono na Rys. 23b-23c. Próbkę ramki ograniczającej dla klasy maszt w kolorze magenty przedstawiono na Rys. 23d.



Rys. 23. Próbki wykrytych obiektów dla kategorii: (a) dźwig budowlany, (b) turbina wiatrowa i słup energetyczny, (c) turbina wiatrowa i słup energetyczny, (d) dźwig budowlany i maszt [opr. wl.]

Na podstawie ortofotomapy określono współrzędne (x, y) centroidu każdego wykrytego obiektu, dzięki czemu możliwe było określenie ich lokalizacji w chmurze punktów.

Poprawność wykrycia obiektów na obrazie przeprowadzono obliczając wartości współczynników IoU, AP oraz mAP dla czterech kategorii obiektów. Na podstawie wyników zawartych w Tab. 6 stwierdzono, że wartość współczynnika IoU dla kategorii dźwig budowlany wyniosła 69,4%, dla kategorii słup energetyczny wyniosła 78,2%, dla kategorii turbina wiatrowa 74,2%, natomiast dla kategorii maszt 64,9%. Wyniki pokazują, że dokładność położenia i lokalizacji jest lepsza dla obiektów należących do kategorii słup energetyczny i turbina wiatrowa. Jednak współczynnik IoU dla kategorii dźwig budowlany i maszt jest nieznacznie gorszy. Wartość średniej precyzji AP dla kategorii dźwig budowlany wyniosła 74,8%, dla kategorii słup energetyczny wyniosła 67,6%, dla kategorii turbina wiatrowa wyniosła 65,2%, a dla kategorii maszt 75,3%. Wysoka wartość współczynnika AP świadczy o tym, że otrzymano niewiele fałszywych predykcji. Wartość mAP zastosowanego algorytmu YOLOv3 osiągnęła wartość 70,7%. Stosunkowo wysoka wartość mAP świadczy o wszechstronności modelu i możliwości wykorzystania tego algorytmu do detekcji nietypowych przeszkód lotniczych.

Tab. 6. Dokładności wyników testów dla obiektów w czterech kategoriach [opr. wl.]

Kategoria	IoU (%)	AP (%)	mAP (%)
Dźwig budowlany	69,4	74,8	70,7
Słup energetyczny	78,2	67,6	
Trubina wiatrowa	74,6	65,2	
Maszt	64,9	75,3	

Na podstawie otrzymanych wyników (Tab. 6) stwierdzono, że wyższe wartości współczynnika AP osiągane są dla mniejszych wartości IoU, co oznacza, że dopasowanie ramek do wymiarów obiektów nie jest idealne. Za pomocą algorytmu uzyskano gorsze wyniki dla małych obiektów należących do kategorii maszt oraz dla obiektów o podłużnym kształcie na obrazie należących do kategorii dźwig budowlany. Był to spodziewany efektem, gdyż cechą sieci YOLO jest szybkie działanie kosztem uzyskania nieco gorszej detekcji wąskich obiektów.

W kolejnym etapie badań na podstawie autorskiego algorytmu działającego na chmurze punktów określono wysokość wykrytych przeszkód lotniczych i określono dokładności wpasowania chmury punktów. W tym celu posłużyono się danymi referencyjnymi zawartymi w bazie eTOD, jak również w suplementach AIP, w których znajdują się m. in. informacje na temat tymczasowych przeszkód lotniczych. Do określenia dokładności wpasowania chmury punktów wzięto pod uwagę wpasowanie w płaszczyznę poziomą (współrzędne X, Y) oraz wpasowanie w płaszczyznę pionową (współrzędna H).

W tym celu obliczono: parametr $\overline{d_X}$ jako średnią różnicę pomiędzy otrzymaną współrzędną X, a współrzędną referencyjną X_{ref} , parametr $\overline{d_Y}$ jako średnią różnicę pomiędzy otrzymaną współrzędną Y, a współrzędną referencyjną Y_{ref} oraz parametr $\overline{d_Z}$ jako średnią różnicę pomiędzy otrzymaną współrzędną Z, a współrzędną referencyjną Z_{ref} . Analizę dokładności przeprowadzono dla czterech kategorii przeszkód lotniczych: dźwig budowlany, słup energetyczny, turbina wiatrowa i maszt (Tab. 7.).

Tab. 7. Wartości statystyczne charakteryzujące dokładność wpasowania chmury punktów
[opr. wl.]

Kategoria przeszkody lotniczej	Parametr $\overline{d_X}$ [m]	RMSE współrz. X [m]	Parametr $\overline{d_Y}$ [m]	RMSE współrz. Y [m]	Parametr $\overline{d_Z}$ [m]	RMSE współrz. Z [m]
Dźwig budowlany	0,6	0,04	0,7	0,04	0,4	0,02
Słup energetyczny	0,4	0,02	0,3	0,02	0,5	0,03
Turbina wiatrowa	0,3	0,02	0,4	0,02	0,5	0,03
Maszt	0,6	0,04	0,5	0,04	0,6	0,04

Na podstawie wartości statystycznych (Tab. 7), które charakteryzują dokładność wpasowania chmury punktów stwierdzono, że różnica pomiędzy obliczoną wartością współrzędnej X, a wartością referencyjną mieściła się w przedziale 0,3-0,6 m. Różnica ta dla współrzędnej Y mieściła się w przedziale 0,3-0,7 m. Natomiast różnica dla współrzędnej Z mieściła się w przedziale 0,4-0,5 m. Wartość RMSE dla współrzędnych poziomych (X, Y) jak i współrzędnych pionowych ukształtowała się na poziomie 0,02-0,04 m. Uzyskane wyniki pokazują, że opracowana metoda detekcji przeszkód lotniczych o wysmukłym kształcie pozwala na wykrycie tego typu przeszkód lotniczych z maksymalną różnicą pomiędzy otrzymanymi współrzędnymi poziomymi (X, Y), a współrzędnymi referencyjnymi wynoszącą 0,7 m, a dla współrzędnej pionowej (Z) 0,6 m.

2.4.3. Dyskusja i analiza otrzymanych wyników

Na podstawie uzyskanych wyników automatycznej detekcji i klasyfikacji przeszkód lotniczych o charakterystycznym wysmukłym kształcie przeprowadzono analizę dokładności wykrycia przeszkód lotniczych. W ramach analizy uzyskane współrzędne poziome i wysokościowe wykrytych przeszkód lotniczych porównano z danymi zawartymi w bazie eTOD, jak również w suplementach AIP. Opracowana metoda detekcji i klasyfikacji przeszkód lotniczych, prezentująca innowacyjne połączenie dwóch technik pozyskiwania danych: na podstawie analizy obrazu za pomocą algorytmu YOLOv3 i na podstawie analizy chmury punktów, pozwoliła na automatyczne wykrycie przeszkód lotniczych o wysmukłym

kształcie. Na podstawie detekcji obiektów na obrazie stwierdzono, że najwyższą dokładność położenia wykrytych obiektów uzyskano dla przeszkód lotniczych należących do kategorii słup energetyczny i turbina wiatrowa. Wyższą wartość wskaźnika AP, przy niższej dokładności położenia wykrytych obiektów osiągnięto dla przeszkód lotniczych z kategorii maszt i dźwig budowlany. Wyniki te potwierdzają pojawiające się w literaturze wnioski mówiące o tym, że wykorzystanie algorytmu YOLOv3 do wykrycia niewielkich obiektów powoduje uzyskanie mniejszych dokładności [70]. Zauważono, że obiekty z kategorii maszt i dźwig budowlany zlokalizowane były w większości na obszarach o gęstej zabudowie. Nieco niższą wartość współczynnika AP osiągnięto dla kategorii turbiny wiatrowe i słupy energetyczne. Jednak w tym przypadku wartość współczynnika IoU była wyższa, co świadczyło o dokładniejszym wykrywaniu tego typu obiektów. W większości obiekty te zlokalizowane były na terenach otwartych, gdzie brak było zwartej zabudowy. Pomimo, że w ostatnich latach wydajność wykrywania małych obiektów za pomocą metod głębokiego uczenia znacznie się poprawiła, nadal występuje różnica w osiąganych dokładnościach dla małych i dużych obiektów [71]. Dla wykrytych przeszkód lotniczych o wysmukłym kształcie uzyskano maksymalną różnicę pomiędzy otrzymanymi współrzędnymi (X, Y, Z), a współrzędnymi referencyjnymi wynoszącą 0,7 m. Wyniki wykrycia przeszkód lotniczych spełniły wymagania dokładnościowe określone w dokumentach EUROCONTROL i ICAO [5, 7]. Większość pojawiających się w literaturze prac badawczych pokazuje zadowalające wyniki przy wykrywaniu dużych obiektów. Algorytm YOLOv3 jest wciąż ulepszany w celu poprawy wydajności wykrywania małych obiektów na obrazie. Liu i in. [70] w swojej pracy przedstawili propozycję ulepszenie struktury sieci neuronowej poprzez zwiększenie operacji splotu we wczesnej warstwie, w celu wzbogacenia informacji przestrzennych. Istnieją również opracowania, które pokazują efektywne zmniejszenie luki w wykrywaniu małych obiektów, poprzez zwiększenie zbiorów danych, gdzie wykorzystywane są ogromne liczby danych do trenowania modeli [72-73]. Kharchenko i in. [74] w swoich badaniach na temat detekcji obiektów w otoczeniu lotniska pokazali wysoką zdolność wykrywania oraz precyzję lokalizacji obiektów za pomocą algorytmu YOLOv3. Junos i in. [75] w swoich badaniach pokazali wpływ korekcji obrazów z BSP na wyniki detekcji obiektów na podstawie algorytmu YOLOv3.

Reasumując głównym celem w publikacji czwartej było opracowanie metody automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych na podstawie danych pozyskanych z BSP. Badania przeprowadzono w oparciu o nowatorską metodę

detekcji i klasyfikacji nietypowych przeszkodek lotniczych na podstawie danych pozyskanych z niskiego pułapu. Zaprezentowana strategia wykrywania nietypowych przeszkodek lotniczych przez zastosowanie fuzji algorytmu YOLOv3, działającego na obrazie i autorskiego algorytmu klasyfikacji nietypowych przeszkodek lotniczych o wydłużonym kształcie działającego na chmurze punktów pozwoliła na wykrycie przeszkodek lotniczych z dokładnością zapewniającą bezpieczeństwo w przestrzeni powietrznej, czyli zgodną z wymaganiami EUROCONTROL i ICAO [5, 7]. Przeprowadzone badania pozwoliły na stwierdzenie, że **zastosowanie metody detekcji i klasyfikacji nietypowych przeszkodek lotniczych z wykorzystaniem głębszych sieci neuronowych pozwoliło na zwiększenie dokładności identyfikacji oraz poprawność klasyfikacji przeszkodek lotniczych.**

3. WNIOSKI

Spójny cykl czterech publikacji pt. „**Metodyka opracowania danych pozyskanych z niskiego pułapu na potrzeby detekcji i klasyfikacji wybranej grupy przeskód lotniczych**”, który stanowi niniejszą rozprawę doktorską miał na celu przedstawienie autorskiego podejścia do opracowania danych pozyskanych z BSP na potrzeby zbierania danych o przeskodach lotniczych. Cykl publikacji stanowi rozwiązanie następującego problemu badawczego: jakie algorytmy przetwarzania danych pozyskanych z niskiego pułapu należy zastosować, aby wykryć i sklasyfikować nietypowe przeskody lotnicze zgodnie z wymaganiami dokładnościowymi zawartymi w dokumentach EUROCONTROL i ICAO? Ponadto cykl przedstawia algorytm przetwarzania danych na potrzeby zbierania danych o przeskodach lotniczych w strefie 2b zgodnie z określona dokładnością poziomą współrzędnych X, Y wynoszącą 5 m oraz dokładnością pionową Z wynoszącą 3 m. W pierwszej publikacji udowodniono, że uwzględnienie dodatkowych parametrów w procesie wyrównania pozwala na podwyższenie dokładności wyników wyrównania jednoszeregowego bloku zdjęć pozyskanego za pomocą BSP, przy ograniczonej liczbie fotopunktów dla terenów niedostępnych. Pojedynczy blok zdjęć jest przypadkiem szczególnym, w którym zachowanie odpowiedniej geometrii bez pełnego pokrycia osnową fotogrametryczną dla całego obszaru opracowania jest bardzo trudne. Dotychczas pojawiały się próby rozwiązania pojedynczego bloku zdjęć gdzie dla podwyższenia dokładności wyrównania, wykorzystywano pomocnicze bloki pozyskane na wyższej wysokości. Na uwagę zasługuje fakt, że powszechnie stosowane niskobudżetowe bezzałogowe statki powietrzne, wyposażone w jednociąstotliwościowe odbiorniki GPS pozwalają na osiągnięcie dokładności pozycji na poziomie 10 m, co wpływa na obniżenie dokładności uzyskanych produktów fotogrametrycznych. Popularność powszechnie używanych niskobudżetowych BSP, wyposażonych w jednociąstotliwościowe odbiorniki GPS powoduje wzrost zainteresowania metodami podwyższenia dokładności pozycjonowania bezzałogowych statków powietrznych i w efekcie zwiększenia dokładności produktów fotogrametrycznych, co potwierdza aktualność problemu badawczego. W drugiej publikacji zweryfikowano, czy modyfikacja algorytmu metody pozycjonowania pozwoli na zwiększenie dokładności wyznaczenia pozycji bezzałogowego statku powietrznego dla pozyskiwania danych o przeskodach lotniczych bez konieczności pomiaru osnowy fotogrametrycznej. W ramach rozwiązania problemu badawczego do wyznaczenia pozycji BSP zastosowano algorytm metody kodowej SPP z użyciem produktów IGS. Wyniki

pokazały, że dokładność wyznaczenia pozycji bezzałogowego statku powietrznego zwiększyła się znaczco – wzduż osi X o 95%, wzduż osi Y o 40% oraz wzduż osi Z o 80%. Ponadto zastosowane rozwiązańe pozwoliło na uzyskanie większych dokładności wyrównania bloku zdjęć – dla elementów liniowych orientacji zewnętrznej średnio o 58% i elementów kątowych orientacji zewnętrznej średnio o 18%. Otrzymane wyniki potwierdziły skuteczność zaproponowanej metody zwiększenia dokładności pozycjonowania BSP, dzięki czemu możliwe będzie zwiększenie dokładności generowanych w kolejnych etapach produktów fotogrametrycznych. W publikacji trzeciej sprawdzono czy segmentacja chmur punktów zmodyfikowanym algorytmem RANSAC poprzez zastosowanie odpowiedniej filtracji i segmentacji gęstej chmury punktów pozwoli na wykrycie przeskód lotniczych z dokładnością zgodną z przepisami EUROCONTROL i ICAO. W ramach weryfikacji problemu badawczego detekcję przeskód lotniczych przeprowadzono na chmurze punktów, dla której dokonano segmentacji poprzez zastosowanie zmodyfikowanego algorytmu RANSAC oraz autorskiego algorytmu klasyfikacji przeskód lotniczych. Wyniki prowadzonych badań potwierdziły skuteczność zaproponowanej metody do detekcji przeskód lotniczych, a najlepsze rezultaty osiągnięto dla przeskód lotniczych o wydłużonym kształcie i regularnym przekroju. W czwartej publikacji zweryfikowano czy zastosowanie metody detekcji i klasyfikacji nietypowych przeskód lotniczych z wykorzystaniem głębokich sieci neuronowych pozwoli na zwiększenie dokładności identyfikacji i poprawności klasyfikacji przeskód lotniczych. W ramach rozwiązania problemu badawczego zaproponowano nowe podejście do wykrywania przeskód lotniczych, opierające się na fuzji algorytmu YOLOv3 do detekcji na obrazie i autorskiego algorytmu klasyfikacji chmury punktów. Połączenie danych obrazowych i chmury punktów stanowiło podstawę do wykrycia nietypowych przeskód lotniczych i określenia ich wysokości. Otrzymane wyniki potwierdziły zasadność zaproponowanej metody wykrywania przeskód lotniczych o wysmukłym kształcie, pozwalając na osiągnięcie dokładności zgodnych z wymaganiami EUROCONTROL i ICAO.

Teza niniejszej rozprawy brzmi: „**Przetwarzanie danych pozyskanych z niskiego pułpu poprzez zastosowanie algorytmu poprawy pozycjonowania BSP, algorytmu filtracji i segmentacji chmury punktów oraz algorytmu sieci neuronowej pozwoli na detekcję i identyfikację przeskód lotniczych z dokładnością zgodną z wymaganiami EUROCONTROL i ICAO**”. Powyższa teza została udowodniona poprzez opracowanie

i weryfikację metodyki przetwarzania danych pozyskanych z niskiego pułapu na potrzeby detekcji i klasyfikacji wybranej grupy przeszkód lotniczych. W cyklu czterech publikacji zaprezentowano algorytm postępowania mający na celu opracowanie metodyki przetwarzania danych pozyskanych z BSP dla wykrycia i określenia wysokości przeszkód lotniczych o wydłużonym i wysmukłym kształcie.

Otrzymane wyniki pozwoliły na potwierdzenie postawionych hipotez badawczych. Wyniki przedstawione w publikacji pierwszej potwierdziły hipotezę H1: „**Uwzględnienie dodatkowych parametrów w procesie aerotriangulacji pozwala na podwyższenie dokładności wyrównania bloku jednoszeregowego przy ograniczonej liczbie fotopunktów dla terenów niedostępnych, przy zastosowaniu niskobudżetowych bezzałogowych statków powietrznych, wyposażonych w jednociąstotliwościowe odbiorniki GPS**”. Wyniki pokazane w drugiej publikacji potwierdziły hipotezę H2: „**Zastosowanie algorytmu metody pozycjonowania absolutnego SPP z użyciem produktów IGS pozwoli na zwiększenie dokładności wyznaczenia pozycji bezzałogowego statku powietrznego dla pozyskiwania danych o przeszkodach lotniczych**”. Wyniki przedstawione w trzeciej publikacji potwierdziły hipotezę H3: „**Segmentacja chmur punktów zmodyfikowanym algorytmem RANSAC poprzez zastosowanie odpowiedniej filtracji i segmentacji gęstej chmury punktów pozwoli na wykrycie przeszkód lotniczych z dokładnością zgodną z przepisami EUROCONTROL i ICAO**”. Natomiast wyniki pokazane w publikacji czwartej potwierdziły hipotezę H4: „**Zastosowanie metody detekcji i klasyfikacji nietypowych przeszkód lotniczych z wykorzystaniem głębokich sieci neuronowych pozwoli na zwiększenie dokładności identyfikacji oraz poprawności klasyfikacji przeszkód lotniczych**”.

Opracowana metodyka może znaczco usprawnić proces analizy ograniczeń operacyjnych statków powietrznych, projektowanie procedur, czy też tworzenie map lotniczych oraz poprawić bezpieczeństwo w przestrzeni powietrznej, ograniczając ryzyko zderzenia statku powietrznego z przeszkodą do minimum. Zaproponowane rozwiązania i wyniki prac badawczych są „novum” w literaturze przedmiotu badań, co zostało potwierdzone publikacjami w czasopismach wyróżnionych przez Journal Citation Reports (JCR).

Podsumowując za najważniejsze osiągnięcia zaprezentowane w cyklu publikacyjnym uważam:

- opracowanie metody wyrównania jednoszeregowego bloku zdjęć pozyskanych z niskiego pułapu dla terenów niedostępnych,
- opracowanie metody podwyższenia dokładności pozycjonowania bezzałogowych statków powietrznych wyposażonych w odbiorniki jednoczestotliwościowe, a przez to dokładności produktów fotogrametrycznych na potrzeby zbierania danych o przeszkodach lotniczych bez pomiaru fotopunktów,
- opracowanie metody automatycznej detekcji i klasyfikacji nietypowych przeszkód lotniczych na podstawie gęstych chmur punktów oraz obrazów pozyskanych z niskiego pułapu.

LITERATURA

1. Rozporządzenie Ministra Infrastruktury z dnia 12 stycznia 2021 r. w sprawie przeszkód lotniczych, powierzchni ograniczających przeszkody oraz urządzeń o charakterze niebezpiecznym (Dziennik Ustaw/2021/poz. 264).
2. Ustawa z dnia 3 lipca 2002 r. Prawo lotnicze (Dziennik Ustaw/2002/130/poz. 1112).
3. Załącznik 14 do Konwencji o międzynarodowym lotnictwie cywilnym Lotniska, Tom I, *Projektowanie i eksploatacja lotnisk*, Wydanie siódme, lipiec 2016 r.
4. Załącznik 4 do Konwencji o międzynarodowym lotnictwie cywilnym, *Mapy lotnicze*, Wydanie jedenaste, lipiec 2009 r.
5. EUROCONTROL, *Terrain and Obstacle Data Manual*, 3rd ed., Eurocontrol: Brussels, Belgium, 2021.
6. Załącznik 15 do Konwencji o międzynarodowym lotnictwie cywilnym, *Służby informacji lotniczej*, Wydanie szesnaste, lipiec 2018 r.
7. DOC 10066, Procedures for air navigation services, *Aeronautical Information Management*, First edition, 2018.
8. Eling C., Wieland M., Hess C., Klingbeil L., Kuhlmann H., *Development and evaluation of a UAV based mapping system for remote sensing and surveying applications*, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-1/W4, 2015, International Conference on Unmanned Aerial Vehicles in Geomatics, Toronto, Canada, 30 sierpnia-2 września 2015.
9. Wierzbicki D., Kędzierski M., Sekrecka A., *A Method for Dehazing Images Obtained from Low Altitudes during High-Pressure Fronts*, Remote Sensing, 12(1), 25, 2019, DOI:10.3390/rs12010025.
10. Tao W., Lei Y., *UAV aerotriangulation with flight-control data support*, Second International Conference on Mechanic Automation and Control Engineering, Hohhot, China, 15-17 July 2011, 2801-2804, DOI:10.1109/MACE.2011.5987568.
11. Luhmann T., Robson S., *Close Range Photogrammetry: Principles, Methods and Applications*, Cdr ed.; Whittles Publishing: Dunbeath, UK, 2011, ISBN 978-1-84995-057-2.
12. Fryer J., Mitchell H., Chandler J., *Applications of 3D measurement from images*, Whittles Publishing: Dunbeath, UK, 2007, 312, ISBN 978-1-904445-63-0.

13. DeWitt B. A., Wolf P. R., *Elements of Photogrammetry (with Applications in GIS)*, 3rd ed., McGraw-Hill Higher Education: New York, NY, USA, 2000, ISBN 0-07-292454-3.
14. Harwin S., Lucieer A., *Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from Unmanned Aerial Vehicle (UAV) imagery*, Remote Sens. 2012, 4, 1573-1599, DOI:10.3390/rs4061573.
15. Mancini F., Dubbini M., Gattelli M., Stecchi F., Fabbri S., Gabbianelli G., *Using Unmanned Aerial Vehicles (UAV) for High-Resolution Reconstruction of Topography: The Structure from Motion Approach on Coastal Environments*, Remote Sens. 2013, 5, 6880-6898, DOI:10.3390/rs5126880.
16. Tahar K. N., *An evaluation on different number of ground control points in unmanned aerial vehicle photogrammetric block*, Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. 2013, 40, 93-98, DOI:10.5194/isprsarchives-XL-2-W2-93-2013.
17. Shahbazi M., Sohn G., Théau J., Menard P., *Development and evaluation of a UAV-photogrammetry system for precise 3D environmental modeling*, Sensors 2015, 15, 27493-27524, DOI:10.3390/s151127493.
18. Hugenholz C., Brown O., Walker J., Barchyn T., Nesbit P., Kucharczyk M., Myshak S., *Spatial accuracy of UAV-derived orthoimagery and topography: comparing photogrammetric models processed with direct georeferencing and ground control points*, Geomatica 2016, 70, 21-30, DOI:10.5623/cig2016-102.
19. Santerre R., Pan L., Cai C., Zhu, J., *Single Point Positioning Using GPS, GLONASS and BeiDou Satellites*, Positioning 2014, 5(4), 107-114, DOI: 10.4236/pos.2014.54013.
20. Taro S., Takahashi Y., Amano Y., *Precise UAV Position and Attitude Estimation by Multiple GNSS Receivers for 3D Mapping*, Proceedings of the 29th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2016), Portland, Oregon, September 2016, 1455-1464.
21. Ashraf S., Aggarwal P., Damacharla P., Wang H., Javaid AY., Devabhaktuni V., *A low-cost solution for unmanned aerial vehicle navigation in a global positioning system-denied environment*, International Journal of Distributed Sensor Networks 2018, 14(6), 1-17, DOI:10.1177/1550147718781750.
22. Daakir M., Pierrot-Deseilligny M., Bosser P., Pichard F., Thom C., Rabot Y., Martin O., *Lightweight UAV with on-board photogrammetry and single-frequency*

- GPS positioning for metrology applications*, ISPRS J. Photogramm. Remote Sens. 2017, 127, 115-126, DOI:10.1016/j.isprsjprs.2016.12.007.
23. Shahbazi M., Sohn G., Théau J., Menard P., *Development and evaluation of a UAV-photogrammetry system for precise 3D environmental modeling*, Sensors 2015, 15, 27493-27524, DOI:10.3390/s151127493.
 24. Dong L., Shan J., *A comprehensive review of earthquake-induced building damage detection with remote sensing techniques*, ISPRS J. Photogramm. Remote Sens. 2013, 84, 85-99, DOI:10.1016/j.isprsjprs.2013.06.011.
 25. Sun S., Salvaggio C., *Aerial 3D building detection and modeling from airborne LiDAR point clouds*, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2013, 6(3), 1440-1449, 10.1109/JSTARS.2013.2251457.
 26. Rottensteiner F., Sohn G., Gerke M., Wegner J. D., Breitkopf U., Jung J., *Results of the isprs benchmark on urban object detection and 3D building reconstruction*, ISPRS J. Photogramm. Remote Sens. 2014, 93, 256-271, DOI: 10.1016/j.isprsjprs.2013.10.004.
 27. Colomina I., Molina P., *Unmanned aerial systems for photogrammetry and remote sensing: a review*, ISPRS J. Photogramm. Remote Sens. 2014, 92, 79-97, 10.1016/j.isprsjprs.2014.02.013.
 28. Dorniger P., Pfeifer N., *A comprehensive automated 3D approach for building extraction, reconstruction and regularization from air borne laser scanning point cloud*, Sensors 2008, 8(11), 7323-7343, DOI:10.3390/s8117323.
 29. Boykov Y., Funka-Lea G., *Graph cuts and efficient ND image segmentation*, International Journal of Computer Vision 2006, 70(2), 109-131, DOI: 10.1007/s11263-006-7934-5.
 30. Narkhede H., *Review of image segmentation techniques*, International Journal of Science and Modern Engineering 2013,1(8), 54-61.
 31. Jarząbek-Rychard M., Borkowski A., *Porównanie algorytmów RANSAC oraz rosnących płaszczyzn w procesie segmentacji danych z lotniczego skaningu laserowego*, Archiwum Fotogrametrii, Kartografii i Teledetekcji 2010, 21, 119-129, ISSN: 2083-2214.
 32. Fischler M. A. Bolles, R. C., *Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography*, Communications of the ACM 1981, 24(6), 381-395, DOI:10.1145/358669.358692.

33. Girshick R., Donahue J., Darrell T., Malik J., *Rich feature hierarchies for accurate object detection and semantic segmentation*, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA, 24-27 June 2014, 580-587.
34. Girshick R., *Fast R-CNN*, In Proceedings of the IEEE International Conference on Computer Vision, 2015, 1440-1448.
35. Ren S., He K., Girshick R., Sun J., *Faster R-CNN: Towards real-time object detection with region proposal networks*, In Proceedings of Advances in Neural Information Processing Systems 28: Annual Conference on Neural Information Processing Systems 2015, Montreal, QC, Canada, 7-12 December 2015, 91-99.
36. Liu W., Anguelov D., Erhan D., Szegedy C., Reed S., Fu C. Y., Berg A.C., *SSD: Single shot multibox detector*, In Proceedings of the European Conference on Computer Vision (ECCV), Amsterdam, The Netherland, 8-16 October 2016, 21-37.
37. Fu C.Y., Liu W., Ranga A., Tyagi A., Berg A. C., *DSSD: deconvolutional single shot detector*, arXiv preprint arXiv:1701.06659 2017, DOI: 10.48550/arXiv.1701.06659.
38. Redmon J., Divvala S., Girshick R., *You only look once: unified, real-time object detection*, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779-788, Las Vegas, NV, USA, June 2016.
39. Erhan D., Szegedy C., Toshev A., Anguelov D., *Scalable object detection using deep neural networks*, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014, 2147-2154.
40. Esetlili M., Bektas Balcik F., Balik Sanli F., Kalkan K., Ustuner M., Goksel Ç., Gazioğlu C., Kurucu Y., *Comparison of Object and Pixel-Based Classifications for Mapping Crops Using Rapideye Imagery: A Case Study of Menemen Plain, Turkey*, International Journal of Environment and Geoinformatics 2018, 5(2), 231-243, DOI:10.30897/ijegeo.442002.
41. Çelik O., Gazioğlu C., *Coastline Difference Measurement (CDM) Method*, International Journal of Environment and Geoinformatics 2020, 7(1), 1-5, DOI: 10.30897/ijegeo.706792.
42. Granshaw S. I., *Bundle adjustment methods in engineering photogrammetry*, Photogramm. Rec. 1980, 10, 181-207, DOI:10.1111/j.1477-9730.1980.tb00020.x.
43. Brown S. H., *Multiple Linear Regression Analysis: A Matrix Approach with MATLAB*, Alabama Journal of Mathematics Spring/Fall 2009, 34.

44. Yuan Y., *On a subproblem of trust region algorithms for constrained optimization*, Mathematical Programming 1990, 47(1-3), 53-63, DOI:10.1007/BF01580852.
45. Casella V., Chiabrandi F., Franzini M., Manzino A. M., *Accuracy Assessment of A UAV Block by Different Software Packages, Processing Schemes and Validation Strategies*, ISPRS Int. J. Geo-Inf. 2020, 9, 164, DOI:10.3390/ijgi9030164.
46. Rango A., Laliberte A., Herrick J. E., Winters C., Havstad K., Steele C., Browning D., *Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management*, J. Appl. Remote Sens. 2009, 3(1), 033542-033542-15, DOI:10.1117/1.3216822.
47. Lourakis M. I. A., Argyros A. A., *Is Levenberg-Marquardt the most efficient optimization algorithm for implementing bundle adjustment?*, In Proceedings of the IEEE International Conference on Computer Vision, Beijing, China, 17-21 Oct. 2005, 1526-1531.
48. Börlin N., Grussenmeyer P., *Bundle Adjustment with and without Damping*, Photogrammetric Record 2013a, 28(144), 396-415, DOI:10.1111/phor.12037.
49. Börlin N., Grussenmeyer P., Eriksson J., Lindström P., *Pros and cons of constrained and unconstrained formulation of the bundle adjustment problem*, Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. 2004, 35, 589-594.
50. Ge Y., Zhou F., Sun B., Wang S., Shi B., *The Impact of Satellite Time Group Delay and Inter-Frequency Differential Code Bias Corrections on Multi-GNSS Combined Positioning*, Sensors (Basel, Switzerland), 2017, 17(3):602, DOI:10.3390/s17030602.
51. Schaer S., *Mapping and predicting the Earth's ionosphere using Global Positioning System*, PhD thesis, Neunundfünfzigster Band volume 59, ISBN: 3-908440-01-7, Zürich, Switzerland, 1999.
52. Gao Y., *GNSS biases, their effect and calibration*, Paper presented at IGS Workshop, Miami, 2008, length of slides: 24.
53. Le A. Q., Tiberius C., *Single-frequency precise point positioning with optimal filtering*, GPS Solutions 2007, 11(1), 61-69, DOI:10.1007/s10291-006-0033-9.
54. Ueno M., Nimura T., Fujiwara T., Nonaka K., *Evaluation of RTK-OTF positioning system for free running manoeuvrability test of a model ship*, Oceans '97. MTS/IEEE Conference Proceedings, 1997, 2, 1120-1125, DOI: 10.1109/OCEANS.1997.624149.

55. Krasuski K., *Aircraft positioning using SPP method in GPS system*, Aircr. Eng. Aerosp. Technol. 2018, 90(8), 1213-1220, ISSN: 0002-2667.
56. Krasuski, K. *The Research of Accuracy of Aircraft Position Using SPP Code Method*, Ph.D. Thesis, Warsaw University of Technology, Warsaw, Poland, 2019, 1–106.
57. Krasuski K., Ciećko A., Bakuła, M., Wierzbicki, D., *New Strategy for Improving the Accuracy of Aircraft Positioning Based on GPS SPP Solution*, Sensors 2020, 20, 4921, DOI:10.3390/s20174921.
58. Agüera-Vega F., Carvajal-Ramírez F., Martínez-Carricando P., *Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle*, Measurement 2017, 98, 221-227, DOI: 10.1016/j.measurement.2016.12.002.
59. Himanshu S., Schütz A., Pany T., *Preliminary analysis of the RTK positioning using Android GNSS Raw Measurements and Application Feasibility for the Trajectory mapping using UAV's*, In the 31st International Technical Meetingnof the Satellite Division of The Institute of Navigation (ION GNSS+ 2018), 432-444, The Institute of Navigation, Manassas, 24-28 September 2018, Miami, Florida, USA. ISBN 0-936406-10-0.
60. Angrisano A., Del Pizzo S., Gaglione S., Troisi S., Vultaggio M., *Using local redundancy to improve GNSS absolute positioning in harsh scenario*, Acta Imeko 2018, 7(2), 16-23, DOI:10.21014/acta_imeko.v7i2.538.
61. Woronowicz M., *Algebra liniowa z geometrią analityczną*, Skrypt dla studentów pierwszego semestru matematyki stosowanej, Politechnika Białostocka, 2022.
62. Lalak M., Wierzbicki D., *Methodology of detection and classification of selected aviation obstacles based on UAV dense image matching*, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2022, 15, 1869-1883, DOI: 10.1109/JSTARS.2022.3149105.
63. Rogowski, M., Prusiel, J. A., *Budynek wysokościowy*, Przegląd Budowlany, 2019, 90.
64. Shyi-Ching L., Liao LH., Lee Y-C., *Localization algorithm based on improved weighted centroid in wireless sensor networks*, Journal of Networks 2014, 9(1),183-189.
65. Mitsevich L., *3D aerodrome obstacle assessment using stereo remote sensing imagery*, The International Archives of Photogrammetry, Remote Sensing and

- Spatial Information Sciences 2020, Tom XLIII-B2-2020, 1115-1119, DOI:10.5194/isprs-archives-XLIII-B2-2020-1115-2020.
66. Heckbert P. S., *Graphics Gems IV*, Computer Science Department Carnegie Mellon University Pittsburgh, Pennsylvania, 1994, 3-5.
 67. Chaudhuri D., *A simple least squares method for fitting of ellipses and circles depends on border points of a two-tone image and their 3-D extensions*, Pattern Recognition Letters 2010, 31(9), 818-829, DOI:10.1016/j.patrec.2010.01.009.
 68. Lalak M., Wierzbicki D., *Automated detection of atypical aviation obstacles from UAV images using a YOLO algorithm*, Sensors 2022, 22(17), 6611, DOI: 10.3390/s22176611.
 69. *Geodezja inżynieryjna*, Praca zbiorowa, Tom II, 1980.
 70. Liu M., Wang X., Zhou A., Fu X., Ma Y., Piao C., *UAV-YOLO: Small object detection on unmanned aerial vehicle perspective*, Sensors 2020, 20(8), 2238, DOI: 10.3390/s20082238.
 71. Nhat-Duy N., Tien D., Thanh Duc N., Duy-Dinh L., *An Evaluation of Deep Learning Methods for Small Object Detection*, Journal of Electrical and Computer Engineering 2020, 2020(3189691), 18, DOI:10.1155/2020/3189691.
 72. Lin T. Y., Maire M., Belongie S., Hays J., Perona P., Ramanan D., Dollár P., Zitnick C. L., *Microsoft COCO: common objects in context*, In Proceedings of the European Conference on Computer Vision, 740-755, Springer, Zurich, Switzerland, September 2014.
 73. Russakovsky O., Deng J., Su H., Krause J., Satheesh S., Ma S., Huang Z., Karpathy A., Khosla A., Bernstein M., Berg A. C., Fei-Fei L., *Imagenet large scale visual recognition challenge*, International Journal of Computer Vision 2015, 115(3), 211-252.
 74. Kharchenko V., Iurii C., *Detection of airplanes on the ground using YOLO neural network*, In Proceedings of the 17th international conference on mathematical methods in electromagnetic theory (MMET), IEEE, 2018.
 75. Junos M. H., Khairuddin A. S. M., Thannirmalai S., Dahari M., *Automatic detection of oil palm fruits from UAV images using an improved YOLO model*, The Visual Computer 2021, 1-15.

WYKAZ ZAŁĄCZNIKÓW

Załącznik 1 – [Publikacja 1].....81-116

Lalak M., Wierzbicki D., Kędzierski M., *Methodology of processing single-strip blocks of imagery with reduction and optimization number of ground control points in UAV photogrammetry*, Remote Sensing 2020, 12(20), 3336, DOI: 10.3390/rs12203336.

Załącznik 2 – [Publikacja 2]117-139

Lalak M., Krasuski K., Wierzbicki D., *Methodology to improve the accuracy of the determination of the position of UAV equipped with single-frequency receivers for the purposes of gathering data about aviation obstacles*, Scientific Journal of Silesian University of Technology, Series Transport 2023, 119, 83-104, ISSN: 0209-3324, DOI: 10.20858/sjsutst.2023.119.5.

Załącznik 3 – [Publikacja 3]140-155

Lalak M., Wierzbicki D., *Methodology of detection and classification of selected aviation obstacles based on UAV dense image matching*, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2022, 15, 1869-1883, DOI: 10.1109/JSTARS.2022.3149105.

Załącznik 4 – [Publikacja 4]156-178

Lalak M., Wierzbicki D., *Automated detection of atypical aviation obstacles from UAV images using a YOLO algorithm*, Sensors 2022, 22(17), 6611, DOI: 10.3390/s22176611.

Załącznik 1 – [Publikacja 1]

Article

Methodology of Processing Single-Strip Blocks of Imagery with Reduction and Optimization Number of Ground Control Points in UAV Photogrammetry

Marta Lalak ¹, Damian Wierzbicki ^{2,*} and Michał Kędzierski ²

¹ Institute of Navigation, Military University of Aviation, 08-521 Dęblin, Poland; m.lalak@law.mil.pl

² Institute of Geospatial Engineering and Geodesy, Faculty of Civil Engineering and Geodesy, Military University of Technology, 00-908 Warsaw, Poland; michał.kędzierski@wat.edu.pl

* Correspondence: damian.wierzbicki@wat.edu.pl; Tel.: +48-261-83-96-92

Received: 28 August 2020; Accepted: 10 October 2020; Published: 13 October 2020



Abstract: Unmanned aerial vehicle (UAV) systems are often used to collect high-resolution imagery. Data obtained from UAVs are now widely used for both military and civilian purposes. This article discusses the issues related to the use of UAVs for the imaging of restricted areas. Two methods of developing single-strip blocks with the optimal number of ground control points are presented. The proposed methodology is based on a modified linear regression model and an empirically modified Levenberg–Marquardt–Powell algorithm. The effectiveness of the proposed methods of adjusting a single-strip block were verified based on several test sets. For method I, the mean square errors (RMSE) values for the X, Y, Z coordinates of the control points were within the range of 0.03–0.13 m/0.08–0.09 m, and for the second method, 0.03–0.04 m/0.06–0.07 m. For independent control points, the RMSE values were 0.07–0.12 m/0.06–0.07 m for the first method and 0.07–0.12 m/0.07–0.09 m for the second method. The results of the single-strip block adjustment showed that the use of the modified Levenberg–Marquardt–Powell method improved the adjustment accuracy by 13% and 16%, respectively.

Keywords: photogrammetry; unmanned aerial vehicle; bundle block adjustment; single strip; accuracy analysis; additional parameters

1. Introduction

In recent years, the intensity of use of unmanned aerial vehicles (UAVs) in photogrammetric and remote sensing applications has been constantly growing. Miniature unmanned aerial vehicles can be a cheap and effective alternative for acquiring imagery for the purpose of classic aerial photogrammetry. UAVs, which were initially created for the needs of the military, have also found civilian use—for example, to study the natural environment. It is worth noting that UAV imaging also meets needs related to aviation. A good example is the so-called securing of an off-airport landing strip, where the selection of the landing site is made based on preliminary field reconnaissance or based on landing zone maps. It seems reasonable to use UAVs to collect data to facilitate the choice of the location for such a landing strip. This can be justified in many ways, such as low cost of operation, the ability to provide geospatial data with high spatial resolution, the small size of the flying platform, low airspace occupancy (e.g., low flight altitude), ease of preparation for flight and quick recovery of readiness to perform the task. Therefore, UAVs can also be used to obtain data from hard-to-reach areas. Conducting a flight over an area with restricted access is associated with the problem of an incomplete photogrammetric control network, which should be evenly distributed throughout the area of study. It is worth noting that despite the emergence of a more precise positioning system

(e.g., real-time kinematic (RTK)), many low-cost UAVs are still equipped with single-frequency global positioning system (GPS) receivers [1]. In comparison with previously used global navigation satellite systems (GNSS) methods, the RTK positioning method uses a wider frequency band. There is, therefore, a greater likelihood of improper navigation of the UAV using RTK in the vicinity of other radiation sources. This is mainly due to the phenomenon of electromagnetic wave interference from various devices. Therefore, it seems more appropriate to use a UAV positioning method which utilizes a narrower frequency band, i.e., GPS.

1.1. Related Works

Obtaining geospatial data from unmanned aerial systems is becoming more and more popular [2]. UAVs have become a widely used aerial platform in the field of photogrammetry and remote sensing [3]. Currently, a gradual replacement of classical aerial photogrammetry with low-altitude photogrammetry can be observed [4]. UAVs platforms have many advantages, including low costs and ease of use [5]. UAVs were created mainly for the needs of the military: for exercises, observation, reconnaissance, and offensive operations [6]. Increasingly, however, unmanned aerial vehicles are being used for civilian applications, such as for researching the natural environment, among others [7–10]. UAVs may be remotely controlled (e.g., piloted from a ground control station) or can fly autonomously using a pre-programmed flight plan [11]. UAVs can be equipped with optical sensors, thermal sensors, multispectral sensors, and Lidar sensors [12,13]. They can be used for mapping artificial objects and 3D modeling of natural objects [14,15]. Compared to traditional aerial photogrammetry, UAVs can acquire higher spatial resolution images for the production of orthophotos [16], digital surface models [17], and others [18].

Unmanned aerial vehicles can be used for imaging the earth's surface to create air navigation obstacle maps [19–21]. The location of objects (aviation obstacles) affects the course and safety of the flight during its critical stages (take-off, landing). There are cases of a so-called improvised landing where the landing site selection can be made based on terrain reconnaissance. Such an area is called an off-airport take-off and landing area [21,22]. The basic criterion for selecting such a site is the ability to perform a safe landing and take-off in accordance with the conditions and limitations specified in the operation manual of a given type of aircraft [23]. An important parameter is the slope angle of the landing area and the type of coverage. Due to the low cost of operation, small size, low flight altitude, ease of storage and implementation, and the ability to provide geospatial data with a high spatial resolution with a higher data collection rate and relatively short data processing time, it is reasonable to obtain imagery data using UAV platforms [24–27]. Another area that may be used in the future for the so-called accidental landing are highway strips. The use of unmanned aerial vehicles can facilitate the control of the current condition of road sections used as emergency landing strips.

UAV imagery has become a commonly used tool for the observation of restricted areas [28,29]. While the imaging of the inaccessible area seems easy to perform with the use of UAV platforms, setting up and measuring a photogrammetric control network in the study area may be impossible (Figure 1).

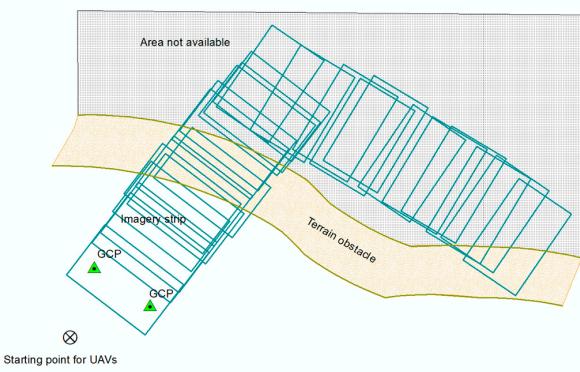


Figure 1. Inaccessible single-strip.

The general consensus in photogrammetry is to ensure an even distribution of control points [30] and check points throughout the study area [31–33]. It is worth noticing the issues related to the processing of data obtained from UAVs and determining how the accuracy of photogrammetric products changes depending on the distribution of ground control points (GCPs), especially with a small number of GCPs [34]. Unfortunately, there is no consensus on what best practice is, and questions remain as to whether GCPs should be mainly on the periphery or in the middle of the area, and what is the best placement rule for them. The number of GCPs to be used in traditional aerial photogrammetry has previously been discussed in the photogrammetric literature. It is well known that an increase in the number of ground control points (GCPs) results in an improvement in the accuracy of the developed data [33]. There is little published work on the impact of the number of GCPs on the accuracy of UAV-derived photogrammetric products, and many conclusions are ambiguous or even contradictory. For example, Mancini et al. [35], Yang et al. [36] and Saporano et al. [37] found that the number of used GCPs can be further reduced without significant loss of accuracy. Tmušić et al. [38] state that the required GCP deployment will also depend on the image content (e.g., vegetation and surface type), terrain characteristics, survey design, and camera characteristics, which influence the potential for systematic error to develop within the image block. The optimal number of GCPs and their spatial distribution is one of the most important issues in indirect georeferencing. In their research, Harwin et al. [34] use different subsets of GCPs, suggesting that the number of GCPs is an important parameter in the resulting accuracy. By contrast, Tahar et al. [39] analyses the accuracy of different configurations using from four to 12 GCPs, with the authors concluding that the error range decreased after using seven or more GCPs. Shahbazi et al. [40] analyze the results using three to 22 GCPs. They recommend providing a large number of well-distributed GCPs to maximize accuracy but also state that with a minimum number of GCPs that are well distributed and with high overlap, similar results can be obtained. In their research, Oniga et al. [41] determined that the RMSE can be reduced down to 50% when switching from four to 20 GCPs, whereas a higher number of GCPs only slightly improves the results. In the study aimed at determining the optimal number of GCPs conducted by Yu et al. [42] the alignment results were analyzed in three study sites with different areas according to the number of GCPs. The results showed that the optimal number of GCPs was 12 for small and medium sites (7 and 39 ha) and 18 for large sites (342 ha) based on the overall accuracy. Agüera-Vega et al. [43] showed in their research that both the horizontal and vertical accuracy improves with an increase in the number of GCPs.

Currently, the integration of the increasingly popular RTK system with the aircraft allows for the reduction of the number of control points, and in some cases, even their complete exclusion. Caution should be exercised when abandoning the field survey. If we do not have the coordinates of even a few check points, we are deprived of the possibility of controlling the obtained results [44]. As it is known, the accuracy of determining the position of an unmanned aerial vehicle for a single-frequency GPS receiver is about 10 m [1]. At the same time, Shahbazi et al. [40] in his research shows the possibility of achieving high accuracy from UAVs equipped with GPS receivers.

The use of the RTK system in the vicinity of certain devices may affect its operation. Airports are equipped with a large amount of flight inspection system equipment (instrument landing system (ILS), primary surveillance radar (PSR), secondary surveillance radar (SSR), VHF omnidirectional range (VOR), tactical air navigation (TACAN), radio communication), the proper operation of which is based on electromagnetic wave propagation in a wide range of frequencies and with different types of modulation. In addition, military airfields and aircraft based there may be equipped with jamming, spoofing, or radiation protection devices. To reduce the likelihood of navigation errors of an unmanned aerial vehicle performing a task near an airfield, it is reasonable to use a positioning method which utilizes a more narrow frequency band, i.e., GPS. The use of “traditional” GNSS technology may have a smaller impact on the operation of the airport devices themselves compared to RTK technology (e.g., transmitting antenna—rover), which directly translates into the safety of air operations. UAVs with a GPS module can also perform better during a conflict. The arguments for this are higher system reliability and, as previously mentioned, fewer frequencies. Moreover, UAVs with GPS do not require the presence of an operator (reference station) directly in the study area. An example of use may be checking the suitability of a highway strip or other takeoff and landing site in inaccessible terrain or during a conflict.

In photogrammetric triangulation approaches, bundle adjustment (BA) is a commonly used process to simultaneously refine the X , Y , Z coordinates of the scene points, the exterior orientation points (EOPs) of the involved images, and/or the interior orientation parameters (IOPs) of the utilized cameras [45,46]. The classic photogrammetric bundle adjustment is based on the collinearity equations [47]. It can be formulated as a nonlinear least-squares problem, which aims at minimizing the total back-projection error between the observed image point coordinates and predicated feature locations [48]. Recently, bundle adjustment has been further expanded to deal with a wide variety of situations, such as the utilization of different features (e.g., line [49,50], curves [51], etc.), the reconstruction of dynamic scene objects [52], and the employment of non-quadratic error models [53]. Readers wishing to know more details regarding modern bundle adjustment techniques [54,55], should refer to the review conducted by Triggs et al. [53]. The most popular programs processing the low-ceiling photogrammetric data are Agisoft Photoscan, Infoph UASMaster, Pix4D, and EnsoMosaic [45].

In literature, there are studies on the processing of a single block of images. One can especially find many detailed descriptions of adjusting blocks of imagery using the independent model method [56,57]. A methodology of processing a single block of imagery collected by a UAV had been described by Forlani et al. [58], where an auxiliary block obtained from the flight at a higher altitude is used to adjust a single strip block. Another approach to developing a single-strip block from a UAV is presented by Jiang et al. [59], where, to determine the accuracy of the adjustment of a single-strip block, images were additionally taken as part of a two-strip block.

1.2. Research Purpose

In this research work, the hypothesis is: taking into account additional parameters in the aerotriangulation process makes it possible to increase the accuracy of the adjustment of a single-strip block with a limited number of control points for inaccessible areas, using sensors installed onboard low-cost unmanned aerial vehicles using single-frequency GPS receivers.

The research aimed to develop a methodology of adjusting single-strip blocks of low altitude imagery depicting highway landing strips, taking into account limited access to the entire study area. Based on the research hypothesis, as part of the research, a methodology was proposed based on a modified linear regression model and a modified Levenberg–Marquardt–Powell algorithm (empirically modified ranges for the region size Δ_k depending on the size ρ_k were taken into account). The effectiveness of the proposed methods of adjusting a single-strip block was verified based on several test sets.

The paper is structured as follows: in Section 2, the test data are introduced. In Section 3, the research method is explained. Section 4 presents the results of the conducted experiments. In Section 5, the results are discussed. Finally, Section 6 provides a brief summary of this work.

2. Materials

2.1. Study Area

The research was carried out on two test blocks carried out as two separate missions. The first block—set I Łagiewniki—covered the area along a road section, a highway landing strip, located in southwestern Poland, in the town of Łagiewniki ($50^{\circ}47'27''\text{N}$; $16^{\circ}50'40''\text{E}$) (Figure 2). The imaged area covered an area of approximately 0.34 km^2 .

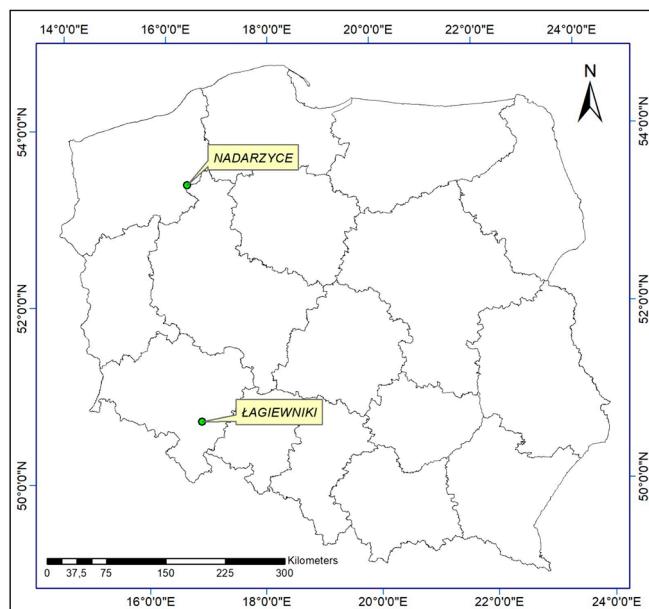


Figure 2. The location of study areas.

The second test block—set II Nadarzyce—covered an area of the Central Aviation Training Range in Nadarzyce ($53^{\circ}27'18''\text{N}$; $16^{\circ}29'24''\text{E}$) in northwestern Poland (Figure 2).

2.2. Description of Data Sets

Set I—Łagiewniki: The source data for aerotriangulation was obtained using the Trimble UX-5 airframe (Figure 3a), equipped with a Sony a7R camera. The aerial platform was equipped with a single-frequency GPS receiver, recording data at a frequency of 10 Hz.



Figure 3. (a) Trimble UX-5—before flight; (b) example of location GCP.

The flight was carried out in the test area in July 2017. The imaging conditions were good, i.e., the sky was partially covered by cumulus clouds and the average wind speed was about 2 m/s. The camera settings were defined in manual mode, while the focus of the lens was set to infinity. The selected test area was the vicinity of the village of Łagiewniki, covering the area along the highway landing strip. The entire test block consisted of 811 images in 34 rows, obtained from an altitude of 250 m above the ground. The flight was conducted in the east-west direction, assuming that the transverse and longitudinal coverage was 75%. In the area of the study, 22 signaled control points were designed and measured (Figure 3b). All points were measured using the RTK technique in the GNSS system. The field coordinates of the control points were determined with the mean error $m_{x,y,z} = \pm 0.03$ m.

Set II—Nadarzyce: The source data for aerotriangulation was obtained using the VTOL WingtraOne system (Figure 4a), equipped with a Sony RX1R II camera. The aerial platform was equipped with a single-frequency GPS receiver, recording data at a frequency of 10 Hz. As part of the research analysis, the GNSS data recorded by an AsteRx-m2 UAS receiver placed on the Tailsitter unmanned platform was used. The Tailsitter platform is a type of VTOL aircraft.

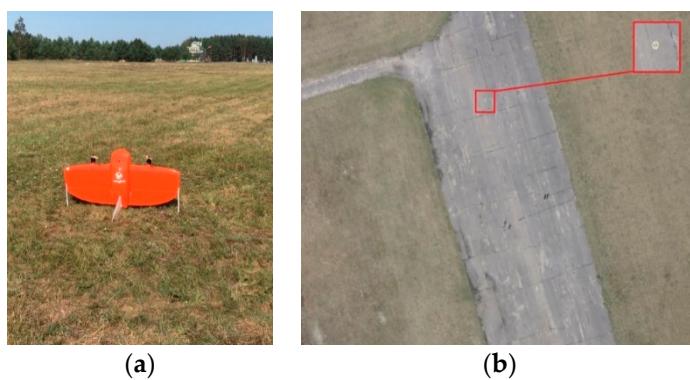


Figure 4. (a) VTOL WingtraOne—before flight; (b) example of location GCP.

The flight was carried out in the test area in August 2019. The imaging conditions were good. The selected test area was an airport located at the 21st Central Aviation Training Grounds. The entire test block consisted of 97 images in three rows, obtained from an altitude of 250 m above the ground. The flight was conducted in the east-west direction, assuming that the transverse and longitudinal coverage was 75%. In the test area, nine signaled control points were measured (Figure 4b) using the RTK technique in the GNSS system. The accuracy of determining the field coordinates of the control points was 0.03 m. In addition, in order to perform further verification of the results, a re-raid of the Wingtra platform was carried out with precise recording of the platform's flight trajectory in the post-processing kinematic (PPK) mode.

2.3. Data Characteristics

For set I—Łagiewniki, the test block consisted of 34 strips (Table 1), which consisted of 811 images. The images were referenced to PUWG 2000PL zone V (Cartesian 2D coordinate system marked with the symbol “2000”, based on the ellipsoid GRS80 according to the Gauss–Krüger mapping theory [60].

Table 1. Characteristics of the test block in Łagiewniki.

Number of Strips	34
Camera/lens focal length [mm]	Sony a7R/36.34
Average longitudinal/transverse coverage [%]	75/75
Flight altitude [m]	250
Number of control points	4
Number of independent check points	18
a priori standard deviation of the control points and check points X, Y, Z [m]	0.03, 0.03, 0.03
Theoretical pixel size [m]	0.04

For set II—Nadarzyce, test block I consisted of three strips made up of 97 images. The images were referenced to PUWG 2000PL zone VI. Block characteristics are presented in the table below (Table 2).

Table 2. Characteristics of the test block in Nadarzyce.

Number of Rows	3
Camera/lens focal length [mm]	Sony RX1R II/35.0
Average longitudinal/transverse coverage [%]	75/75
Flight altitude [m]	250
Number of control points	4
Number of independent check points	5
a priori standard deviation of the control points and check points X, Y, Z [m]	0.03, 0.03, 0.03
Theoretical pixel size [m]	0.04

3. Methods

This chapter presents and describes the mathematical models which can be used for the adjustment of a single-strip block of UAV images. The block diagram of the adjustment process is shown in the figure below (Figure 5). It shows two methods of adjusting a test block. The common point of both methods is the first step, i.e., the adjustment of the entire block of images using Inpho UASMaster software. The second step is to develop a single-strip block of images using two methods, taking additional parameters into account.

Method I was based on the densification of the photogrammetric network with tie points generated during the adjustment of the entire block (step I). From among the tie points, a certain number of them had been selected based on the following criteria:

1. One point on at least three images
2. Points with the lowest mean square error (RMSE = minimum)
3. Points evenly distributed within the area of development (linear regression method [61]).

Method II is the adjustment of the single-strip block of images using nonlinear optimization in MATLAB. In this case, the empirically modified Levenberg–Marquardt–Powell (LMP) method was used. A ready, generally available toolbox was used—the damped bundled adjustment toolbox (DBAT) [62], to which the input data file was implemented. The toolbox includes tools for developing various nonlinear optimization strategies [63,64]. For the bundle adjustment process, the DBAT toolbox with self-calibration was selected. In this toolbox, the fixed and weighted prior observations, control points and camera stations, and check points are all supported. The parameters to be estimated by the bundle are selectable at the parameter level, for individual camera parameters. Furthermore, the parameters can be block-invariant (the same for a whole block), image-variant (individual for each image), or anything in between. Multiple damping schemes may be used to avoid divergence due to poor initial values of the modified Levenberg–Marquardt–Powell [63].

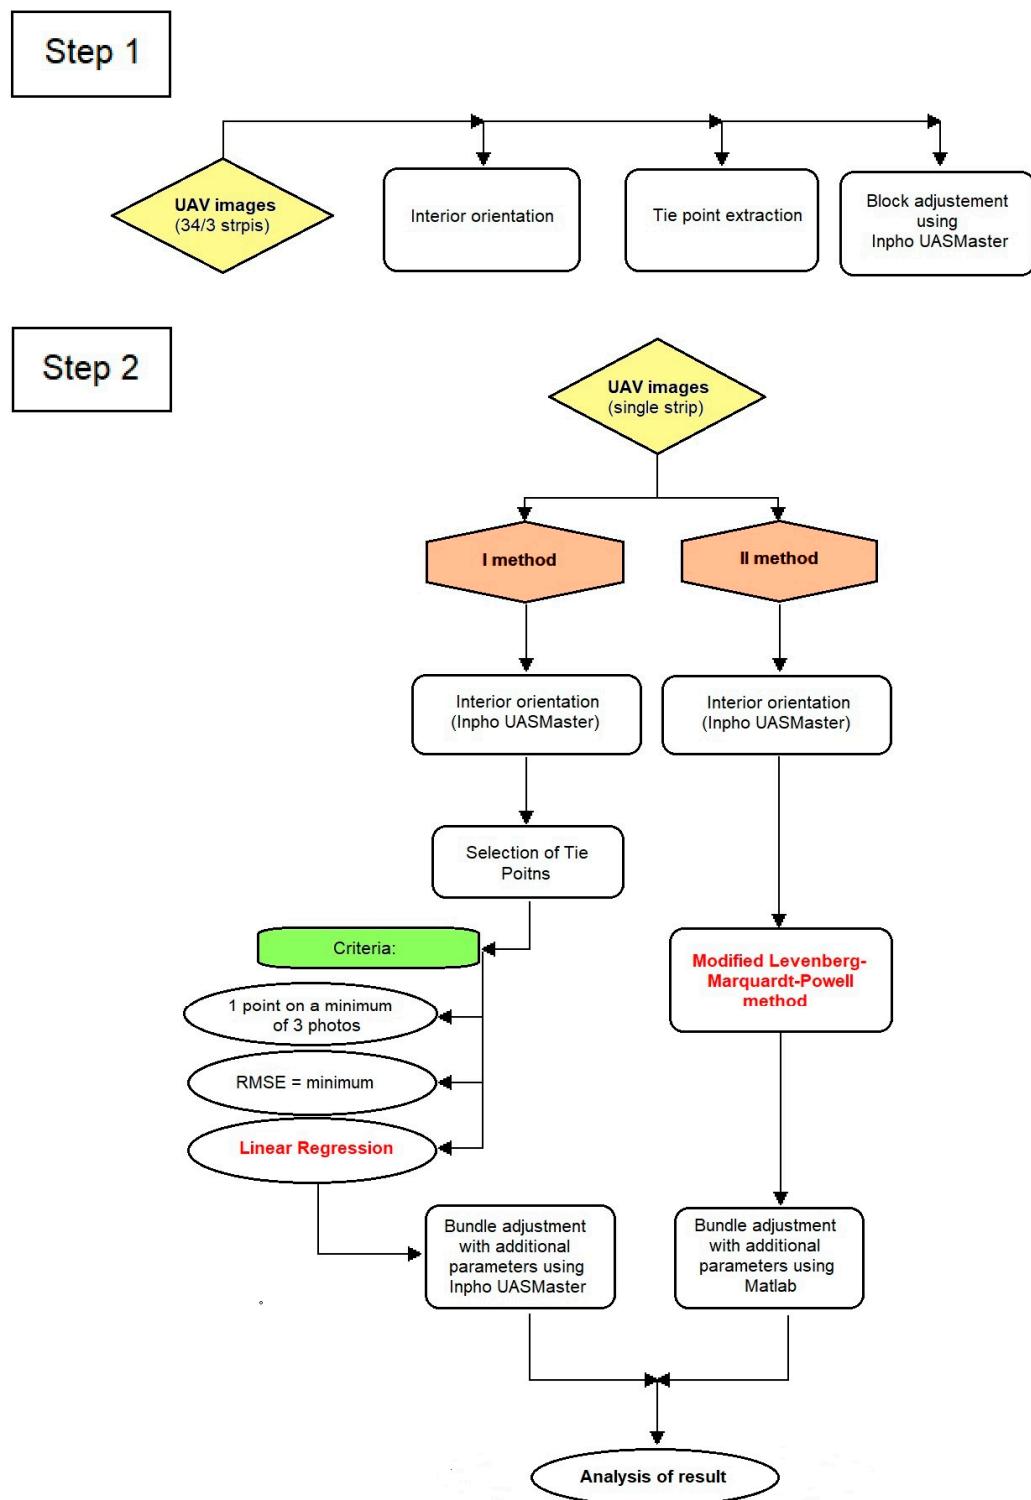


Figure 5. The bundle block adjustment process.

3.1. Modified Linear Regression with Additional Parameters

Using the linear relationship between the data, a classic linear regression model was used to ensure an even distribution of tie points in the study area.

Due to the restricted access to the area, only a small number of control points were measured in the study area. Hence, for the purpose of this research, tie points generated through digital

aerotriangulation of the entire block were used. The adjustment was performed in Inpho UASMaster software. These points were randomly distributed throughout the test area. To ensure an even distribution of the tie points in the study area, a linear regression method was used, based on a linear relationship in which the curve was fitted to the data, i.e., the coordinates of the tie points.

The linear regression model [61,65–67] used is defined by the following formula:

$$y_i = ax_i + b; i = 1, 2, \dots, n, \quad (1)$$

where a and b are the parameters of the line that had to be adapted to our data using the least-squares method [68–71]. Using the least-squares method, the best fit line can be found by minimizing the sum of the squares of the vertical distance from a data point to a point on the line [72].

The point selection criterion: one point on at least three images, points with the smallest errors, and points evenly distributed throughout the area of study.

To select the tie points, the least-squares method was used, thanks to which the line $y = a_1x + b_1$ (Figure 11a).

The parameters of the line defined by the equation $y_i = ax_i + b$ were determined using the formulas:

$$a = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} \quad (2)$$

$$b = \frac{\sum_{i=1}^n y_i \sum_{i=1}^n x_i^2 - \sum_{i=1}^n x_i \sum_{i=1}^n x_i y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} = \frac{1}{n} \left(\sum_{i=1}^n y_i - a \sum_{i=1}^n x_i \right), \quad (3)$$

where a and b are the determined linear coefficients; n is the number of tie points; and x_i and y_i are the coordinates of the tie point.

3.2. Modified Bundle Adjustment with Additional Parameters

This section describes the block adjustment with additional parameters methodology. Studies presented by Börlin et al. [63] and Lourakis et al. [73] served as the basis for writing this subsection.

3.2.1. Problem-Specific Damping

In the algorithm shown below (Figure 6), a trial point t_k is calculated and tested at each iteration. If t_k does not improve on the current point, it is rejected and another point is tried according to an algorithm-specific scheme. The quality of t_k is judged by the reduction of the objective function value. However, it is possible to add a problem-specific veto condition to disqualify “illegal” trial points. For the BA problem, an illegal trial point t_k may, for instance, violate the chirality constraint (each object point should be in front of each camera in which the object point was measured). The veto condition would be added to steps 4, 5, and 6 of algorithms 4, 5, and 6, respectively (Figure 6). Thus, in the case of the veto condition, the trial point will be accepted only when the value of the objective function is reduced and the trial point satisfies the veto condition. Importantly, for the veto addition to work, the initial values must satisfy the veto condition [63].

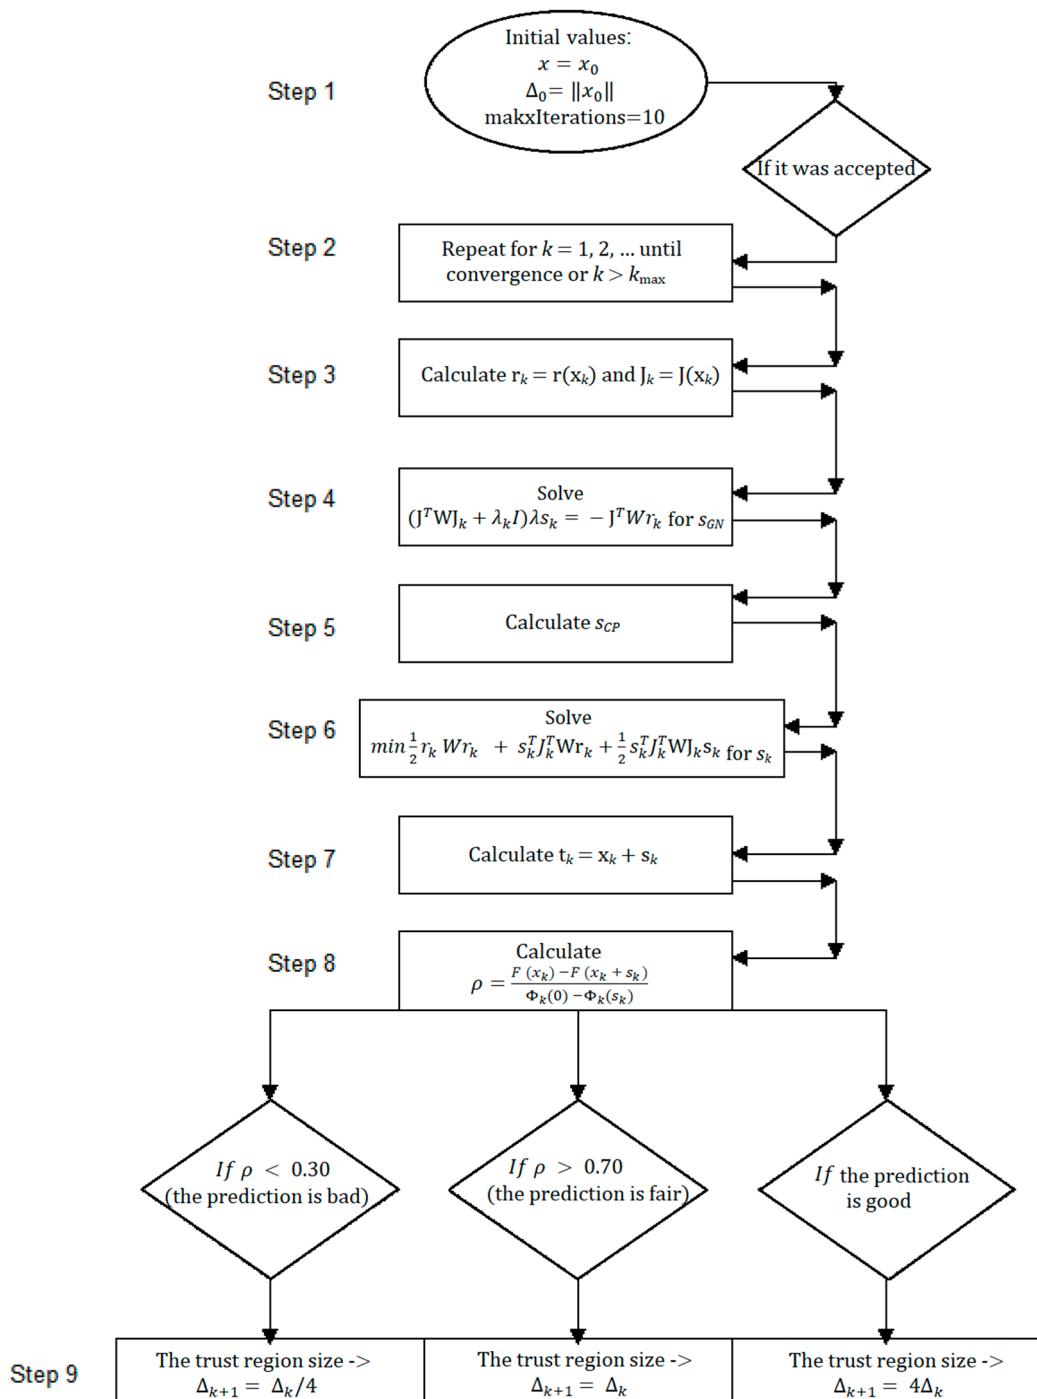


Figure 6. Modified Levenberg–Marquardt–Powell algorithm. Δ_0 is the initial trust region radius. Routine update radius controls the trust region radius based on the value of the gain ratio ρ of actual over predicted reduction: Δ is increased $\rho > 0.70$, kept constant if $0.30 \leq \rho \leq 0.70$, and decreased if $\rho < 0.30$.

In this method, a combination of the camera model and the least-squares adjustment (LSA) algorithm is called a BA algorithm. The algorithm assumes fixed, known IO parameters and does not perform any outlier detection during the least-squares iterations. The choice of $\Delta_0 = \|x_0\|$ for the Levenberg–Marquardt–Powell method is based on the assumption that the initial values are correct to within one order of magnitude [63].

3.2.2. Non-Linear Optimization

In order to increase the accuracy of adjustment, non-linear optimization based on a function called the objective function was used.

The GN method may be modified to converge under a large set of circumstances [74]. The basic modification is to require that every value is “better” than the previous one. The logical choice is to at least require that the objective function must decrease so that

$$F(x_{k+1}) < F(x_k), \quad (4)$$

Algorithms satisfying the descent condition (4) are called descent methods.

The modifications to make GN a descent method are of two types, line search and trust-region [74]. The line search strategy uses the same linear model in

$$r(x_k + s) \approx r_k + J_k s, \quad (5)$$

that was used to calculate s_k to decide when a new point is good enough. The trust-region approach works with the quadratic approximation in

$$\min \frac{1}{2} \|r_k + J_k s\|_w^2 = \min \frac{1}{2} (r_k + J_k s_k)^T W (r_k + J_k s_k), \quad (6)$$

of the objective function for the same purpose. Both methods may be seen as attempts to avoid taking “too long” steps, since when the Jacobian $F(x_k)$ is ill-conditioned, the norm of the update can become arbitrarily large. The line search strategy is now considered; the trust-region is discussed in a later section on the Levenberg–Marquardt–Powell method.

3.2.3. The Levenberg–Marquardt–Powell Method (Trust-Region)

It is possible to interpret the LM method [75–81] geometrically as a trust-region method (Figure 7) [74]. In this interpretation, the method relies on the same quadratic model (6) as the GN method

$$\Phi_k(s_k) = \frac{1}{2} \|r_k + J_k s_k\|_w^2 = \frac{1}{2} r_k^T W r_k + s_k^T J_k^T W r_k + \frac{1}{2} s_k^T J_k^T W J_k s_k, \quad (7)$$

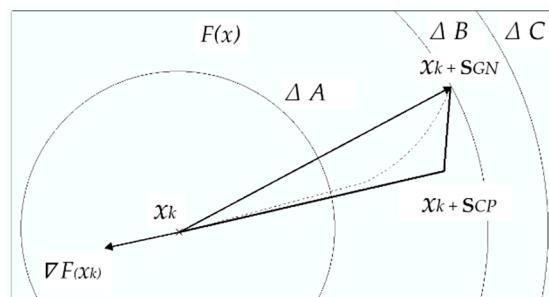


Figure 7. The dogleg method finds the intersection between the dogleg path $x_k \rightarrow x_k + s_{CP} \rightarrow x_k + s_{GN}$ (thick line) and the circle $\|s_k\| = \Delta_k$ or the current value Δ_k . If $\|s_k\| \leq \Delta_k$, the solution is s_{GN} . Based on [63,77].

The quadratic model is trusted only within a region of trust $\|s_k\| \leq \Delta_k$ around the current approximation x_k . Thus, at each iteration, we consider the constrained sub-problem

$$\begin{aligned} \min \frac{1}{2} r_k^T W r_k + s_k^T J_k^T W r_k + \frac{1}{2} s_k^T J_k^T W J_k s_k, \\ \text{subject to } \|s_k\| \leq \Delta_k \end{aligned} \quad (8)$$

Mathematically, the solution of Problem (8) is given by

$$(J^T W J_k + \lambda_k I) \lambda s_k = -J^T W r_k, \quad (9)$$

for some value of the Lagrange multiplier $\lambda_k \geq 0$. Indeed, Equation (9) may be seen as a way to solve the Problem (8).

3.2.4. Modified Powell Dogleg Method

Similarly to the LM algorithm, the Powell dogleg algorithm [82] for unconstrained minimization tries combinations of the Gauss–Newton and steepest descent directions [73]. In the case of DL, however, this is explicitly controlled via the use of a trust region. Trust region methods have been studied during the last few decades and have given rise to numerical algorithms that are reliable and robust, possessing strong convergence properties and being applicable even to ill-conditioned problems [83,84].

The method of Powell may be used to solve the problem (7) without any knowledge of the λ_k value. The method is called dogleg due to the shape of the piecewise linear path used to approximate the $s_{LM}(\lambda)$ curve. The dogleg path goes from the current point, via the Cauchy point s_{CP} , to the GN search direction s_{GN} . The Cauchy point is defined as

$$s_{CP} = \frac{g_k^T g_k}{g_k^T J_k^T W J_k g_k} (-g_k), \quad (10)$$

where $g_k = \nabla F(x_k) = J_k^T W r_k$ is the minimizer of the quadratic model $\Phi_k(s_k)$ in the direction of the negative gradient. Given the current value of Δ_k , the dogleg point is found as the intersection of the dogleg path with the circle $\|s_k\| = \Delta_k$. If $\|s_k\| < \Delta_k$, the dogleg point is chosen as s_{GN} . During the iterations, the trust region size Δ_k is adaptively modified based on how well the quadratic model predicts the reduction of the objective function. The gain ratio ρ between the actual and predicted reductions is defined as

$$\rho = \frac{F(x_k) - F(x_k + s_k)}{\Phi_k(0) - \Phi_k(s_k)}, \quad (11)$$

If ρ is high enough, the step is accepted and the region size Δ is increased. If ρ is too low, the step is discarded and the region size Δ is decreased.

4. Experiments and Results

In this section, we present research experiments and the corresponding results obtained in the aerotriangulation process. The aerotriangulation process of the low altitude image block was performed in the Inpho UASMaster software. Tie points were generated automatically using Dense Image Matching algorithms [85]. After the adjustment, manual correction of the measured points in the images was made by the operator and points with the number of ties less than three were eliminated in order to increase the reliability of the network.

4.1. Set I—Łagiewniki

In the first step of the research, four main work areas were specified (Figure 8). Each of them consisted of a different test block: test block I–IV, each of which was then identified as separate study areas (Figure 9).



Figure 8. Arrangement of areas of study.

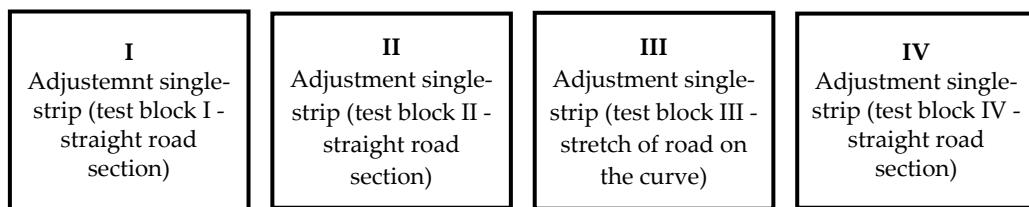


Figure 9. Stages of research.

The basis for the entire processing was the initial part of the algorithm, i.e., the adjustment of the entire block, which consisted of 34 strips of imagery. The images were taken along the road section (approx. 2 km long). The four main work areas mentioned earlier are test block I, test block II, test block III, test block IV, (Figure 8), all within the area of development of the entire block. Each of these workspaces is a special case image block—a single strip block. Test block I, II, and IV consisted of images taken over straight sections of road about 300–450 m long. Test block III is a study area covering the section of the road on the curve (length about 350 m).

4.1.1. Step I

Test block 0

The bundle adjustment in Inpho UASMaster process starts with defining the internal orientation elements based on the results of the Sony a7R camera calibration. Four control points and 18 independent check points were identified in the study area. The tie points were generated automatically using a digital image correlation strategy based on the least-squares method. The results of the aerotriangulation are presented in Table 3.

Table 3. Summary of blocks adjustment.

Description	Test Block 0	Test Block I	Test Block II	Test Block III	Test Block IV
		Variant I/Variant II	Variant I/Variant II	Variant I/Variant II	after 2 Stages
Weather Conditions					Scattered Cloud
Number of images	811	12	25	13	12
$\sigma_0 [\mu\text{m}]/[\text{pix}]$	7.5/1.5	7.0/1.4 6.3/1.3	7.3/1.5 6.9/1.4	7.9/1.6 7.5/1.5	5.5/1.1
Number of GCPs	4	26/13	43/17	46/17	12
Number of check points	18	6	4	4	5
Number of tie points	51,092	1509/1545	2483/2604	2422/2450	1694
Average a priori error for GCPs and check points	X Y Z	0.03 0.03 0.03	0.03 0.03 0.03	0.03 0.03 0.03	0.03 0.03 0.03
Standard deviation X, Y, Z [m]	X Y Z	0.07 0.09 0.08	0.12/0.09 0.14/0.12 0.05/0.04	0.12/0.12 0.13/0.11 0.05/0.05	0.19/0.14 0.16/0.14 0.09/0.05
GCPs X, Y, Z [m] RMS	X Y Z	0.02 0.10 0.15	0.04/0.04 0.04/0.03 0.19/0.17	0.04/0.03 0.05/0.05 0.18/0.17	0.04 0.03 0.13
Check points X, Y, Z [m] RMS	X Y Z	0.06 0.04 0.15	0.05/0.02 0.03/0.01 0.22/0.09	0.05/0.03 0.08/0.05 0.16/0.09	0.04/0.02 0.08/0.02 0.14/0.10
$MX_0 [\text{m}]$		0.11	0.13/0.12	0.12/0.09	0.09/0.09
$MY_0 [\text{m}]$		0.13	0.11/0.09	0.10/0.08	0.11/0.08
$MZ_0 [\text{m}]$		0.13	0.08/0.09	0.08/0.08	0.12/0.10
$M\omega [\text{°}]$		0.034	0.054/0.043	0.047/0.042	0.056/0.054
$M\varphi [\text{°}]$		0.026	0.046/0.036	0.040/0.040	0.066/0.046
$M\kappa [\text{°}]$		0.006	0.011/0.009	0.009/0.009	0.014/0.008

As a result of adjusting the entire block, the average error of a typical observation was $7.5 \mu\text{m}$ (1.5 pixels). The mean square errors (calculated from the equalization corrections) for the X, Y, and Z coordinates of the control points were within the range of 0.02–0.15 m. As a result of the adjustment of the large block, good results were obtained in determining the coordinates of the centres of projection X_0, Y_0, Z_0 . The values of standard deviations ranged from 0.07–0.10 m. However, the accuracy of determining the angular elements of the external orientation ω, φ, κ was between 0.006° and 0.034° . On the basis of the analysis of the adjusting results of the entire block, it was noticed that four control points in the study area gave satisfactory accuracy results. The mean square errors of the horizontal coordinates fluctuates on the level of a few cm. The height coordinates are affected by errors of several cm. The decrease in accuracy for the Z coordinates is due to the fact that some of the tie points were on the canopy of trees and shrubs.

4.1.2. Step II—I Method

Test block I

The first fundamental area of the study was the adjustment of a single-strip block, which consisted of 12 images. This area was included in the area of the entire block (test block 0). The adjustment was performed in two variants. The first variant is to adjust one strip by measuring 26 control points and six check points (Figure 10a). The control points were the points of the measured photogrammetric network, while the control points were selected from among the tie points generated during the adjustment of the entire block. The selection of control points in the first variant was made based on two criteria: one tie point on a minimum of three images and points with the lowest mean square errors. After automatic selection of the tie points, a visual selection was performed. Points located in characteristic places, clearly identifiable in the images, were selected for further study. The second

variant (Figure 10b), is to adjust the same block as in the first variant, using the same six check points. 13 control points were selected based on an additional linear regression criterion (Figure 11b). The use of the linear relationship ensured the uniformity of the distribution of GCPs in the area of study, with particular emphasis on the edges. The process of adjusting a single-strip block is shown in the diagram below (Figure 12). The results of the adjustment are presented in Table 3.

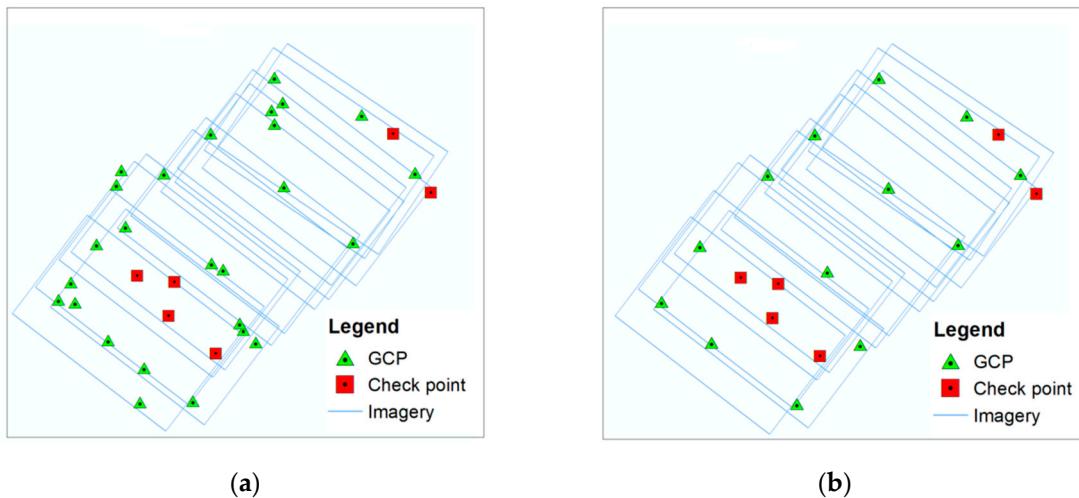


Figure 10. The location of GCPs and check points: (a) variant I: 26 GCPs and six check points; (b) variant II: 13 GCPs and six check points.

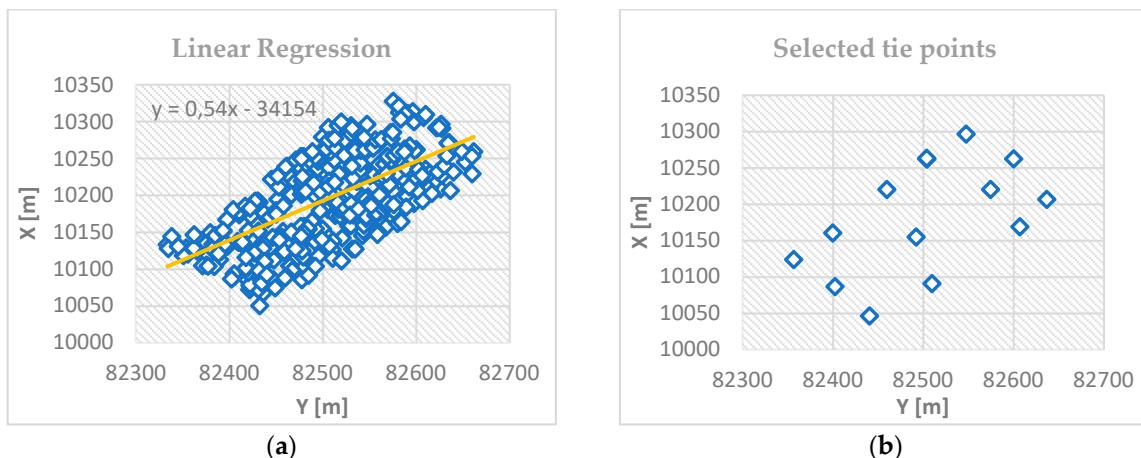


Figure 11. (a) Linear regression for tie points; (b) selected tie points.

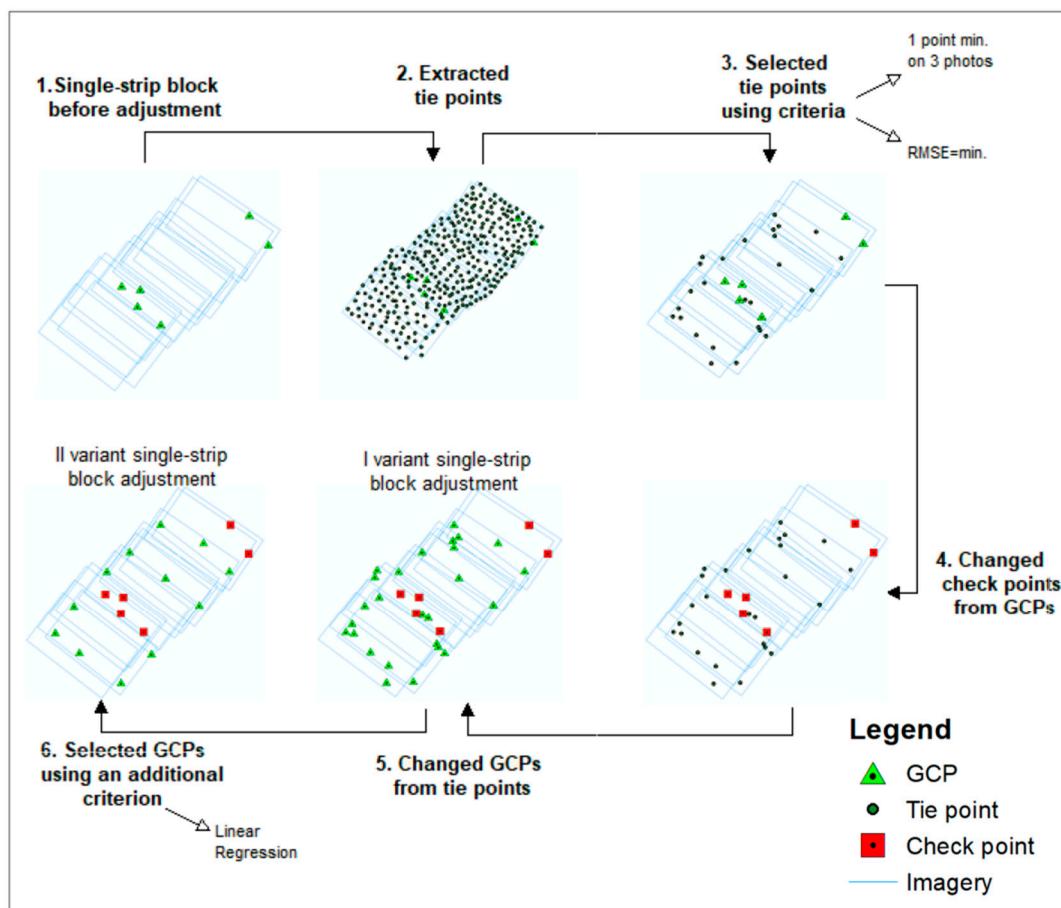


Figure 12. Single-strip block adjustment process including the change of tie points into GCPs.

As a result of the block adjustment in two variants, the mean error of a typical observation was $7.0 \mu\text{m}$ (1.4 pixels) for the first variant and $6.3 \mu\text{m}$ (1.3 pixels) for the second variant. The mean square errors for the X , Y , Z coordinates of the control points were within the range of $0.04\text{--}0.19 \text{ m}$ for the first variant and $0.03\text{--}0.17 \text{ m}$ for the second variant. For independent check points, the mean square errors were $0.03\text{--}0.22 \text{ m}$ for the first variant and $0.01\text{--}0.09 \text{ m}$ for the second variant. The values of standard deviations were within the range of $0.08\text{--}0.13 \text{ m}$ for the first variant and $0.09\text{--}0.12 \text{ m}$ for the second variant. However, the accuracy of determining the angular elements of the exterior orientation ω , φ , κ was from 0.011° to 0.054° for the first variant and $0.009^\circ\text{--}0.043^\circ$ for the second variant. Variant II provides better adjustment accuracy of a single-strip block. The mean square errors both at control points and independent check points are smaller by a few mm for variant II. Better accuracy was ensured by the optimal number of control points. 13 GCPs were necessary to obtain the correct geometry of a single-strip block of images. It was found that a large number of GCPs did not improve the adjustment results. Only reduction and even distribution of control points guarantee improved results. The results of the block adjustment in variant II improved the accuracy by an average of 28%.

Test block II

The second area of the study was a single-strip block consisting of 25 images. The block adjustment was also conducted in two variants. The first variant is the adjustment of one strip when measuring 43 control points and four check points (Figure 13a). Check points are points that are part of the photogrammetric control network, measured in the study area. Control points were selected based on tie points generated when adjusting the entire block. The criterion for selecting points from among the

tie points: one point on at least three images, points with the smallest mean square errors (a method similar to test block I—variant I). The second variant is the adjustment of the same block, by measuring 17 control points and four check points (Figure 13b). The check points used are the same checkpoints as in the first variant. The control points were selected from the tie points based on an additional linear regression parameter. The results of the adjustment are presented in Table 3.

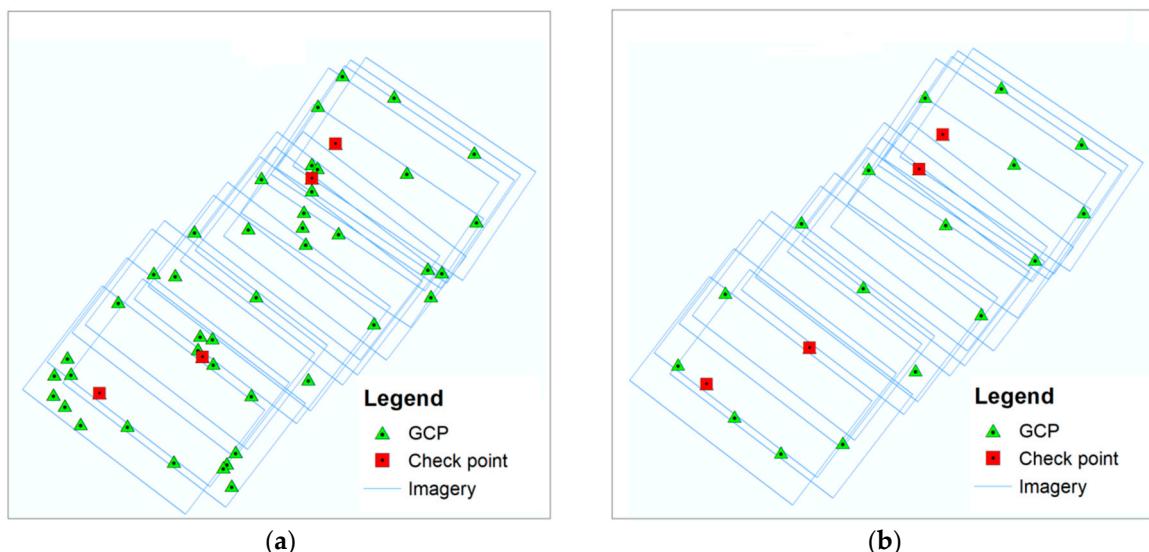


Figure 13. The location of GCPs and check points: (a) variant I: 43 GCPs and four check points; (b) variant II: 17 GCPs and four check points.

As a result of the block adjustment in two variants, the mean error of a typical observation was $7.3 \mu\text{m}$ (1.5 pixels) for the first variant and $6.9 \mu\text{m}$ (1.4 pixels) for the second variant. The mean square errors for the X, Y, Z coordinates of the control points were within the range of 0.04–0.18 m for the first variant and 0.03–0.17 m for the second variant. For independent check points, the mean square errors were 0.05–0.16 m for the first variant and 0.03–0.09 m for the second variant. The values of standard deviations were within the range of 0.08–0.12 m for the first variant and 0.08–0.09 m for the second variant. However, the accuracy of determining the angular elements of the exterior orientation ω , φ , κ was from 0.009° to 0.047° for the first variant and 0.009° – 0.042° for the second variant. The results of the Test block II adjustment in two variants correspond to the results of the Test block I adjustment. It was noticed that variant II increased the adjusting accuracy by an average of 23%. Thus, it is confirmed that striving for an even distribution of GCPs in the developed areas is justified. Based on the analysis of the results of the research experiment, it can be noticed that the RMS values for the horizontal coordinates was only a few cm. The mean square errors Z, on the other hand, reach several cm. The obtained accuracy values result from the large leveling of the terrain in the test area.

Test block III

The next stage was the adjustment of a single-strip block (road curve), which consisted of 21 images. This area was within the area of the entire block. The adjustment was performed in two variants. The first is the adjustment of the single-strip by measuring 46 control points and four check points (Figure 14a). The selection of control points and check points was carried out based on the previously measured photogrammetric network and on the basis of the tie points generated during the adjustment of the entire block.

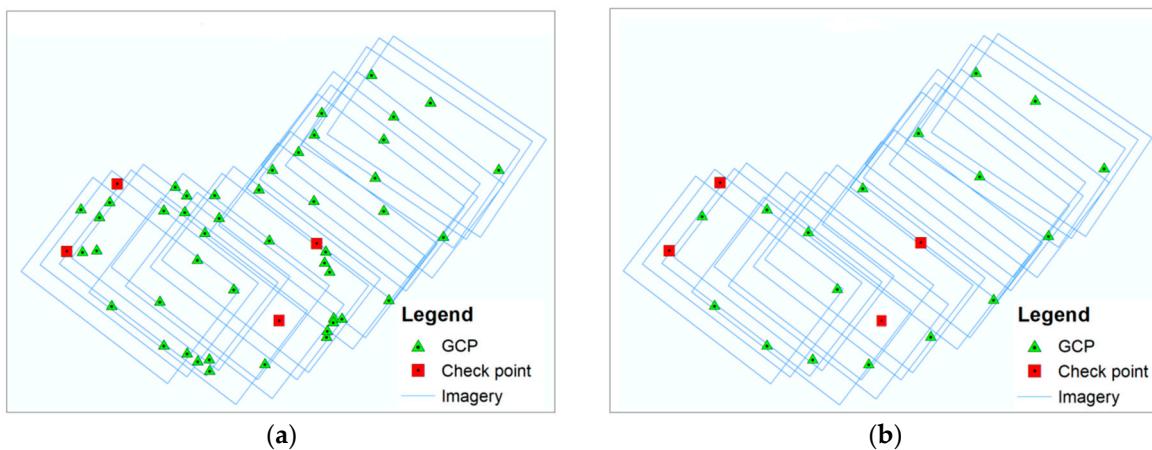


Figure 14. The location of ground control points and check points: (a) variant I: 46 GCPs and 4 check points; (b) variant II: 17 GCPs and 4 check points.

The criterion for selecting points from among the tie points: one point on at least three images, points with the smallest mean square errors.

The second variant is to adjust the single strip by measuring five control points and 31 check points (Figure 14b). The selection of control points and check points was carried out based on the previously measured photogrammetric network and on the basis of the tie points generated during the adjustment of the entire block. In order to filter the binding points, a method similar to that of test block I—variant II, was used. From the tie points, control points and check points were selected and the single-strip block was adjusted.

As a result of the block adjustment in two variants, the mean error of a typical observation was $7.9 \mu\text{m}$ (1.6 pixels) for the first variant and $7.5 \mu\text{m}$ (1.5 pixels) for the second variant. The mean square errors for the X , Y , Z coordinates of the control points were within the range of $0.04\text{--}0.22 \text{ m}$ for the first variant and $0.03\text{--}0.19 \text{ m}$ for the second variant. For independent check points, the mean square errors were $0.04\text{--}0.14 \text{ m}$ for the first variant and $0.02\text{--}0.10 \text{ m}$ for the second variant. The values of standard deviations were within the range of $0.09\text{--}0.12 \text{ m}$ for the first variant and $0.08\text{--}0.11 \text{ m}$ for the second variant. However, the accuracy of determining the angular elements of the exterior orientation ω , φ , κ was from 0.014° to 0.066° for the first variant and $0.008^\circ\text{--}0.054^\circ$ for the second variant. Variant I is block adjustment with 46 GCPs. The distribution of the control points was completely random, which translated into the results of the equalization. Variant II showed that ensuring the optimal number of GCPs turned out to be as important as ensuring their proper distribution in the test area. As a result of GCPs optimization satisfactory equalization results were obtained, where the mean square errors were a few cm for the horizontal coordinates and a dozen or so for the elevation coordinate. The accuracy of determining the linear elements of EO and the accuracy of determining the angles elements of EO turned out to be sufficient to ensure the correct geometry of the block. The results of the block adjustment in variant II improved the accuracy by an average of 27%.

An analysis of the results of the adjustment of blocks: test block I, test block II, test block III with filtered tie points showed that the second variant of the adjustment, which uses linear regression as an additional parameter in the selection of tie points, significantly improves the accuracy of the adjustment. For test block I, the accuracy increased on average by 28%, for test block II by 23% and for test block III by 27%. For further study, the tie point selection method was used according to the following three criteria:

- One point on minimum three images
- RMSE = minimum
- Linear regression

Test block IV

The fourth study area was focused on the adjustment of a block for an area with restricted access, where it is impossible to establish a photogrammetric network for the entire studied area. The selected test area is a single-strip block consisting of 13 images. The adjustment took place in two closely related stages. The first stage is the adjustment of the block with five control points on the edge of the study. In the second stage, the control points from the first stage were turned into check points, and the control points were selected from among the tie points from the development of the entire block (selection according to three criteria: one point on and minimum three images, RMSE = minimum, linear regression). To sum up, the second step is the adjustment of the test block with 16 control points and five check points (Figure 15). The results of the adjustment are presented in (Table 3).

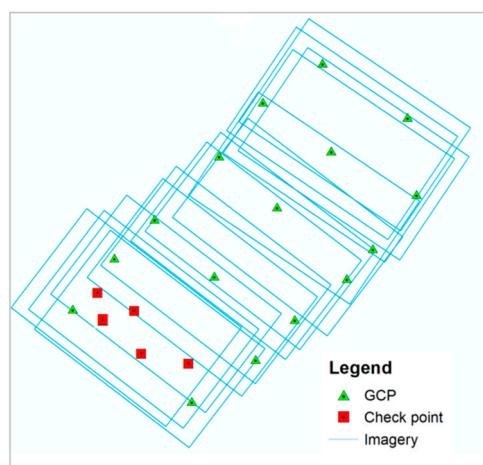


Figure 15. The location of ground control points and check points.

The sequence of processes in the adjustment of a single-strip block in areas with restricted access is presented in the diagram below (Figure 16).

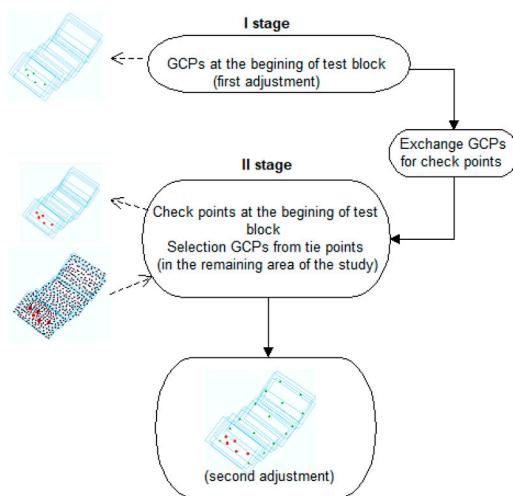


Figure 16. The stages of GCPs selection.

As a result of the two-step block adjustment, the following results were obtained: the mean error of the typical observation for stage I/stage II was $6.4 \mu\text{m}/5.5 \mu\text{m}$, respectively. The mean square errors for the X, Y, Z coordinates of the control points were in the range $0.20\text{--}0.85 \text{ m}/0.03\text{--}0.13 \text{ m}$. For independent check points, the mean square errors were $0.14\text{--}0.16 \text{ m}/0.07\text{--}0.09 \text{ m}$. The values of standard deviations were within the range of $0.11\text{--}0.15 \text{ m}/0.08\text{--}0.11 \text{ m}$. In contrast, the accuracy of

determining the angular elements of the exterior orientation ω, φ, κ was $0.094\text{--}0.336^\circ/0.021\text{--}0.085^\circ$. On the basis of the obtained results, it was noticed that the X, Y coordinates were affected by errors of a few cm. The highest values of the mean square errors for GCPs and check points occur for the Z coordinate. The mentioned dependence was noticed in the research experiment for test block 0, test block I, test block II, and test block III. One of the reasons for this regularity is the high leveling of the terrain in the studied area. The block alignment at 12 GCPs allowed to obtain accuracy on the level from a few to several cm for both the X, Y, Z coordinates. The summary of the adjustment results for the areas of study: test block 0, test block I, test block II, test block III, and test block IV is presented in the table below (Table 3).

4.1.3. Step II—Method II

This section presents the experimental use of the modified Levenberg–Marquardt–Powell algorithm for single-strip block adjustment. For this process, the same study area was selected as in test block IV (consisting of 13 images). A working project was set up, in which the initial parameters of the adjustment were defined. Next, two control points and three check points were manually measured on the images. Control points and check points located on the edge of the block were points of the photogrammetric network. The bundle adjustment was done in MATLAB. The self-calibrating DBAT toolbox was selected for this adjustment. The camera parameters, control points, and check points were input directly into the program. The same camera parameters were selected for the entire block. After auto-calibration, the bundle with damping using modified Levenberg–Marquardt–Powell was selected. The initial values for bundle adjustment:

- Start with initial values x_0 of the parameters and $k_0 = 0$ (a maximum number of iterations = 10)
- Select an initial value of Δ_0 , such as $\Delta_0 = \|x_0\|$

The threshold values for ρ were selected on the basis of the adjustment results for several variants ($0.10 < \rho < 0.90$, $0.20 < \rho < 0.80$, $0.25 < \rho < 0.75$, $0.30 < \rho < 0.70$, $0.35 < \rho < 0.65$). The range which gave the best adjustment accuracy was selected.

The modified range for the gain ratio:

- If $\rho < 0.30$ (the prediction is bad)—the trust region size $\rightarrow \Delta + 1 = \Delta k/4$
- If $\rho > 0.70$ (the prediction is fair)—the trust region size $\rightarrow \Delta k + 1 = \Delta k$
- If the prediction is good the trust region size $\rightarrow \Delta k + 1 = \Delta 4k$.

The results of the adjustment are presented in Table 4. To analyze the accuracy of the adjustment, the table summarizes the results of the adjustment using method I and II.

Table 4. Compare of bundle block adjustment—method II, method I.

Description	Method II—Test Block IV	Method I—Test Block IV	
		after II Stages	
Weather conditions		scattered cloud	
Number of images	12	12	
$\sigma_0 [\mu\text{m}]/[\text{pix}]$	4.2/0.9	5.5/1.1	
Number of GCPs	2	12	
Number of check points	3	5	
Number of tie points	1515	1694	
Average a priori error for GCPs and check points $X, Y, Z [\text{m}]$	X Y Z	0.03 0.03 0.03	0.03 0.03 0.03
Standard deviation $X, Y, Z [\text{m}]$	X Y Z	0.21 0.18 0.20	0.27 0.32 0.36

Table 4. Cont.

Description	Method II—Test Block IV	Method I—Test Block IV	
		after II Stages	
GCPs <i>X, Y, Z [m] RMS</i>	X	0.03	0.04
	Y	0.03	0.03
	Z	0.04	0.13
Check points <i>X, Y, Z [m] RMS</i>	X	0.07	0.07
	Y	0.08	0.09
	Z	0.12	0.12
MX₀ [m]		0.09	0.08
MY₀ [m]		0.08	0.09
MZ₀ [m]		0.11	0.11
Mω [°]		0.076	0.083
Mφ [°]		0.073	0.085
Mκ [°]		0.018	0.021

As a result of the test block IV adjustment using method II, the mean error of a typical observation σ_0 was at a level of $4.2 \mu\text{m}$. The mean square error value for the X, Y, Z coordinates of the control points reached the value of 0.03–0.04 m. For independent check points, the mean square errors were 0.07–0.12 m. The values of standard deviations were within 0.18–0.21 m. Whereas the angular elements of the exterior orientation ω, φ, κ obtain values in the range from 0.018° – 0.076° . The second adjustment method allowed to obtain the mean square error value for the X, Y, Z coordinates of the control points and the independent check points at the level of several cm. The accuracy of the determination of the linear elements of EO was from a few to several cm. The values of standard deviations for the angle elements of EO also allowed to obtain a good alignment accuracy.

For the adjustment using method II, the mean square errors decreased slightly. The results presented in the table below (Table 5) represent the relative percentage change in accuracy in relation to the results of block adjustment conducted using method I. When considering the increase of the adjustment accuracy, the assessment of the error value σ_0 , the determination of terrain coordinates for control points and independent check points, as well as elements of exterior orientation, were taken into account. Based on the results of the adjustment, a slight increase in accuracy in the second method was noticed—an average increase in accuracy by 16%.

Table 5. Summary of the percentage accuracy of adjustment results—test block IV (method II).

Name of Test Area	σ_0	Increase in Accuracy [%]							
		GCPs			Check Points			Linear Elements of EO	Angles Elements of EO
		RMS X	RMS Y	RMS Z	RMS X	RMS Y	RMS Z	MX ₀ , MY ₀ , MZ ₀	Mω, Mφ, Mκ
test block IV	24	25	0	69	0	14	0	3	12

4.1.4. A Statistical Significance Test of Results—Data Set I

In order to confirm the reliability of the obtained results of the block adjustment using two methods, a statistical analysis of the results was performed. For this purpose, confidence intervals with a probability of 95% [86] were determined for the obtained mean square errors of the X, Y, Z coordinates of the control points and check points. The confidence interval was determined for the

mean of the population with a normal distribution $N(m, \sigma)$. The confidence interval for the m parameter of this distribution was calculated from the formula:

$$P\left(\bar{X} - t_{\alpha, n-1} \frac{S(x)}{\sqrt{n-1}} < m < \bar{X} + t_{\alpha, n-1} \left(\frac{S(x)}{\sqrt{n-1}} \right)\right) = 1 - \alpha \quad (12)$$

where: n is the size of the random sample, \bar{X} is the mean of the random sample, S is the standard deviation of the sample, t_α is the Student's t -distribution with $n - 1$ degrees of freedom.

For the first method, based on the modified linear regression method, the GCPs X RMSE confidence interval was calculated with the number of trials $n = 12$. It was calculated that the confidence interval was within the limits: $0.04 < m < 0.07$. For the Y coordinate, with the same number of trials, the confidence interval was $0.03 < m < 0.06$. For the Z coordinate, the confidence interval is $0.09 < m < 0.13$. Confidence intervals were also calculated for the X, Y, Z RMSE check points with the number of trials $n = 8$. It was calculated that the confidence interval for RMSE X was within the limits: $0.04 < m < 0.08$. For the Y coordinate, with the same number of trials, the confidence interval was $0.02 < m < 0.12$. For the Z coordinate, the confidence interval is $0.09 < m < 0.15$. The common rule in photogrammetry confirms that the mean square errors for the Z coordinate are greater than for the horizontal X, Y coordinates. Additionally, the RMSE values for the control points are lower than for the check points.

For the second method, based on the modified Levenberg–Marquardt–Powell algorithm, the RMSE confidence interval was calculated for the X coordinates of the control points with the number of trials $n = 2$. It was calculated that the confidence interval was within the limits $-0.10 < m < 0.15$. For the Y coordinate, with the same number of trials, the confidence interval was $-0.09 < m < 0.16$. For the Z coordinate, the confidence interval is $-0.21 < m < 0.29$. Confidence intervals were also calculated for the check points X, Y, Z RMSE with the number of trials $n = 3$. It was calculated that the confidence interval for RMSE X was within the limits: $0.04 < m < 0.10$. For the Y coordinate, with the same number of trials, the confidence interval was $0.02 < m < 0.14$. For the Z coordinate, the confidence interval is $0.11 < m < 0.15$. Similarly to the first method, the second method also confirms the common rule that the mean square errors for the Z coordinate are greater than for the horizontal X, Y coordinates. The confidence intervals for the RMSE values of the control points are greater than for the check points. This is due to the fact that there are fewer trials for the control points.

4.2. Set II—Nadarzyce

Processing of the second data set was divided into two main areas: test block I and test block II (Figure 17). The basis for the study was the first area, i.e., the entire block (Figure 18).

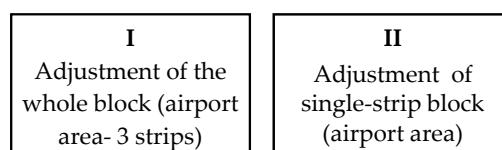


Figure 17. Stages of research.



Figure 18. The location of the study area.

The first area was the entire test block, which consisted of three strips of imagery, with evenly distributed control points. The second working area is a single-strip block with an incomplete photogrammetric network, located on the edge of the study.

4.2.1. Step I

Test Block I

The first study area was processed using UASMaster software. The bundle adjustment process began by defining the interior orientation elements based on the results of the Sony RX1R II camera calibration. Four control points and five independent check points were identified in the study area. The tie points were generated automatically using a digital image correlation strategy based on the least-squares method. The results of the aerotriangulation are summarized in Table 6.

Table 6. Summary of blocks adjustment.

Description	Test Block I		Test Block II
			After Stage II
Weather conditions			scattered clouds
Number of images	97		22
$\sigma_0 [\mu\text{m}]/[\text{pix}]$	3.6/0.8		3.8/0.9
Number of GCPs	4		16
Number of check points	5		5
Number of tie points	2231		1199
Average a priori error for GCPs and check points	X Y Z	0.03 0.03 0.03	0.03 0.03 0.03
Standard deviation	X Y Z	0.09 0.08 0.26	0.62 0.07 0.10
GCPs	X Y Z	0.15 0.10 0.15	0.08 0.08 0.09
X, Y, Z [m] RMS			
Check points	X Y Z	0.17 0.19 0.16	0.08 0.09 0.10
X, Y, Z [m] RMS			

Table 6. Cont.

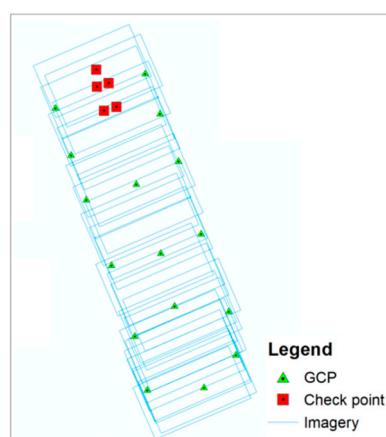
Description	Test Block I	Test Block II	
		After Stage II	
MX_0 [m]	0.09	0.10	
MY_0 [m]	0.08	0.10	
MZ_0 [m]	0.11	0.13	
$M\omega$ [$^{\circ}$]	0.076	0.051	
$M\varphi$ [$^{\circ}$]	0.073	0.043	
$M\kappa$ [$^{\circ}$]	0.018	0.026	

As a result of adjusting the entire block, the mean error of a typical observation was $3.6 \mu\text{m}$ (0.8 pixels). The mean square errors (calculated from the equalization corrections) for the X, Y, and Z coordinates of the control points were within the range of 0.10–0.15 m. For the independent check points, the mean square errors were 0.17–0.19 m. The values of standard deviations were within the range of 0.11–0.13 m. Whereas the accuracy of determining the angular elements of the exterior orientation ω, φ, κ was from 0.018° to 0.051° . Adjustment of a block consisting of three strips performed at four control points allowed to obtain mean square errors for the X, Y, Z of the control points and the independent check points at the level of several centimeters. No significant deterioration of the accuracy for the horizontal coordinates and the Z coordinate was noticed. The studied area covered the airport area, where the ground leveling was a few cm maximum. The values of standard deviations of the coordinates of the linear elements of EO are several cm. The accuracy of the angle elements of EO proves good block geometry. The highest value of the standard deviation of angle elements of EO was obtained for the kappa angle.

4.2.2. Step II—Method I

Test Block II

The processing of the second study area was carried out in two stages. The first stage included the adjustment of the block using five control points on the edge of the study. Stage II is the adjustment of the test block with 16 control points and five check points. At this stage, the control points were selected from the tie points generated during the test block I adjustment. The criterion from the first method of adjusting the image block was used: one point on a minimum three images, RMSE = minimum, linear regression. The sequence of processes in the adjustment of a single-strip block with a small number of points of the photogrammetric network is shown in the diagram (Figure 16). The final distribution of the control points and check points is presented below (Figure 19).

**Figure 19.** The location of GCPs and check points.

As a result of the two-stage block adjustment, the following results were obtained: the mean error of a typical observation for stage I/stage II was $3.9 \mu\text{m}/3.8 \mu\text{m}$, respectively. The mean square errors for the X, Y, Z coordinates of the control points were at in the range of $0.56\text{--}0.92 \text{ m}/0.08\text{--}0.09 \text{ m}$. For the independent check points, the mean square errors were $0.11\text{--}0.18 \text{ m}/0.08\text{--}0.10 \text{ m}$. The values of standard deviations ranged from $0.11\text{--}0.14 \text{ m}/0.10\text{--}0.13 \text{ m}$. However, the accuracy of determining the angular elements of the exterior orientation ω, φ, κ was $0.061\text{--}0.144^\circ/0.026\text{--}0.051^\circ$. The analysis of the results of the adjustment of a single-strip block confirms the need to select the appropriate number of GCPs (16) and, above all, to ensure their proper distribution, with particular emphasis on the edge of the block. A summary of the adjustment results for the study areas: test block I and test block II is presented in the table below (Table 6).

4.2.3. Step II—Method II

This section presents the experimental use of the modified Levenberg–Marquardt–Powell algorithm for single-strip block adjustment. The same study area was selected for this research as in test block II (consisting of 22 images). A working project was set up, in which the initial parameters of the adjustment were defined. Next, two control points and three check points were manually measured on the images. Control points and check points located on the edge of the block were points of the photogrammetric network. The bundle adjustment was done in MATLAB. The self-calibrating DBAT toolbox was selected for this adjustment. The camera parameters, control points, and check points were input directly into the program. The same camera parameters were selected for the entire block. After auto-calibration, the bundle with damping using modified Levenberg–Marquardt–Powell was selected. The initial values for bundle adjustment:

- Start with initial values x_0 of the parameters and $k_0 = 0$ (a maximum number of iterations = 10)
- Select an initial value of Δ_0 , such as $\Delta_0 = \|x_0\|$

The threshold values for ρ were selected on the basis of the equalization results for several variants ($0.10 < \rho < 0.90$, $0.20 < \rho < 0.80$, $0.25 < \rho < 0.75$, $0.30 < \rho < 0.70$, $0.35 < \rho < 0.65$). The range which gave the best adjustment accuracy was selected.

The modified range for the gain ratio:

- If $\rho < 0.30$ (the prediction is bad)—the trust region size $\rightarrow \Delta_{k+1} = \Delta_k/4$
- If $\rho > 0.70$ (the prediction is fair)—the trust region size $\rightarrow \Delta_{k+1} = \Delta_k$

If the prediction is good the trust region size $\rightarrow \Delta_{k+1} = \Delta_4 k$.

The results of the adjustment are presented in Table 7. To analyze the accuracy of the adjustment, the table presents the results of the adjustment methods I and II.

Table 7. Comparison of bundle block adjustment—method II, method I.

Description	MethodII—Test Block II	Method I—Test Block II	
			after Stage II
Weather conditions		scattered clouds	
Number of images	22	22	
σ_0 [μm]/[pix]	3.0/0.6	3.8/0.9	
Number of GCPs	2	16	
Number of check points	4	5	
Number of tie points	2218	1199	
Average a priori error for GCPs and check points	X Y Z	0.03 0.03 0.03	0.03 0.03 0.03
Standard deviation	X Y Z	0.12 0.14 0.13	0.03 0.03 0.03
GCPs	X Y Z	0.06 0.07 0.07	0.62 0.07 0.10
X, Y, Z [m] RMS	X Y Z	0.07 0.08 0.09	0.08 0.08 0.09
Check points	X Y Z	0.07 0.08 0.09	0.08 0.08 0.09
X, Y, Z [m] RMS			
MX₀ [m]		0.09	0.10
MY₀ [m]		0.09	0.10
MZ₀ [m]		0.12	0.13
Mω [°]		0.044	0.051
Mφ [°]		0.038	0.043
Mκ [°]		0.024	0.026

As a result of performing the adjustment of test block II using method II, the mean error of a typical observation σ_0 was at a level of $3.2 \mu\text{m}$. The mean square error value for the X, Y, Z coordinates of the control points reached the value of 0.06–0.07 m. For independent check points, the mean square errors were 0.07–0.09 m. The values of standard deviations were within 0.09–0.12 m. Whereas the angular elements of the exterior orientation ω , φ , κ obtain values in the range from 0.024° – 0.044° . The second adjustment method allowed to obtain the mean square error value for the X, Y, Z coordinates of the control points and the independent check points at the level of several cm. No significant deterioration of the accuracy for the Z coordinate was noticed. The accuracy of the linear elements of EO was determined at the level from a few to several cm. The LMP method provided low values of standard deviation for angles elements of EO.

For the adjustment in which method II was used, the mean square errors decreased slightly. The results presented in the table below (Table 8) represent the relative percentage change in accuracy in relation to the results of the block adjustment using method I. When considering the increase of the adjustment accuracy, the assessment of the error value σ_0 , the determination of terrain coordinates for control points and independent check points, as well as elements of exterior orientation, were taken into account. Based on the results of the adjustment, a slight increase in accuracy in the second method was noticed—an average increase in accuracy by 13%.

Table 8. Summary of the percentage accuracy of adjustment results—test block II (method II).

Name of Test Area	σ_0	Increase in Accuracy [%]							
		GCPs			Check Points			Linear Elements of EO	Angles Elements of EO
		RMS X	RMS Y	RMS Z	RMS X	RMS Y	RMS Z	MX_0, MY_0, MZ_0	$M\omega, M\varphi, M\kappa$
Test block II	21	25	12	22	12	20	11	9	11

4.2.4. A Statistical Significance Test of Results—Data Set II

The statistical analysis of the equalization results was also performed for the second data set. Confidence intervals of 95% [86] were determined for the obtained mean square errors of the X, Y, Z coordinates of the control points and check points. The confidence interval was determined for the mean of the population with a normal distribution $N(m, \sigma)$ based on formula (14).

For the first method, based on the modified linear regression method, the GCPs X RMSE confidence interval was calculated with the number of trials $n = 12$ (the number of trials is the same as the number of control points). It was calculated that the confidence interval was within the limits: $0.05 < m < 0.11$. This means that the RMSE mean value is within the calculated range with a probability of 95%. For the Y coordinate, with the same number of trials, the confidence interval was $0.05 < m < 0.11$. For the Z coordinate, the confidence interval is $0.06 < m < 0.13$. Confidence intervals were also calculated for the X, Y, Z RMSE check points with the number of trials $n = 8$. It was calculated that the confidence interval for RMSE X was within the limits: $0.04 < m < 0.12$. For the Y coordinate, with the same number of trials, the confidence interval was $0.05 < m < 0.14$. For the Z coordinate, the confidence interval is $0.05 < m < 0.14$. The common rule in photogrammetry confirms that the mean square errors for the Z coordinate are greater than for the horizontal X, Y coordinates. Additionally, the RMSE values for the control points are lower than for the check points.

For the second method based on the modified Levenberg–Marquardt–Powell algorithm, the confidence interval of GCPs X RMSE was determined with the number of trials $n = 2$. It was calculated that the confidence interval was within the limits: $-0.07 < m < 0.19$. For the Y coordinate, with the same number of trials, the confidence interval was $-0.06 < m < 0.20$. For the Z coordinate, the confidence interval is $-0.18 < m < 0.32$. Confidence intervals were also calculated for the X, Y, Z RMSE check points with the number of trials $n = 3$. It was calculated that the confidence interval for RMSE X was within the limits: $0.04 < m < 0.10$. For the Y coordinate, with the same number of trials, the confidence interval was $0.02 < m < 0.10$. For the Z coordinate, the confidence interval is $0.01 < m < 0.13$. In method II, one can also observe the regularity that the mean square errors for the Z coordinate are greater than for the horizontal X, Y coordinates. The greater confidence interval for the RMSE value of the control points is due to a smaller number of trials than in the case of the control point analysis.

4.2.5. Comparison of the Results of BBA using LMP Algorithm and with Precision Positioning Trajectory of UAV

The results of the BBA of a single-strip block from the Set II—Nadarzyce research area, were compared with the results of a research experiment using precision positioning technology using post-processing kinematic (PPK). The exact coordinates of the UAV platform linear elements of EO were determined. The results are shown in the table below (Table 9).

Table 9. Comparison of bundle block adjustment—LMP, PPK.

Description	LMP—Test Block II	PPK—Test Block II
Weather conditions	scattered clouds	
Number of images	22	22
σ_0 [μm]/[pix]	3.0/0.6	2.0/0.4
Number of GCPs	2	2
Number of check points	4	4
Number of tie points	2218	8346
Average a priori error for GCPs and check points X, Y, Z [m]	X Y Z	0.03 0.03 0.03
Standard deviation X, Y, Z [m]	X Y Z	0.12 0.14 0.13
GCPs X, Y, Z [m] RMS	X Y Z	0.06 0.07 0.07
Check points X, Y, Z [m] RMS	X Y Z	0.07 0.08 0.09
MX_0 [m]		0.09
MY_0 [m]		0.09
MZ_0 [m]		0.12
$M\omega$ [$^\circ$]		0.044
$M\varphi$ [$^\circ$]		0.038
$M\kappa$ [$^\circ$]		0.024

An additional research experiment gave the following results: the mean error of a typical observation was $2.0 \mu\text{m}$, respectively. The mean square errors for the X, Y, Z coordinates of the control points were at in the range of $0.04\text{--}0.05$ m. For the independent check points, the mean square errors were $0.04\text{--}0.05$ m. The values of standard deviations ranged from $0.03\text{--}0.05$ m. However, the accuracy of determining the angular elements of the exterior orientation ω, φ, κ was $0.008\text{--}0.010^\circ$. Based on the analysis of the results, it was found that the accuracy of the single-strip BBA using precision positioning technology increased by 40%. A significant increase in accuracy has been observed for the linear elements of EO (60%) and angles elements of EO φ, ω, κ (70%).

5. Discussion

This article presents the methodology for processing a single-strip block of images of highway landing strips obtained from low altitudes. The study area was a restricted area, so the photogrammetric network covered only a small part of it. This article presents two methods of processing a single-strip block. The first method met the iron rule of ensuring an even distribution of GCPs and check points in the study area [31–33]. Because a special case of block adjustment was considered—the one-strip block, attention was also paid to ensuring that the block edges had both control points and check points [39,86]. The proposed first method of adjustment, based on the selection of tie points according to selected criteria, significantly improved the accuracy of aerotriangulation for the data set I. The mean error value of a typical observation σ_0 decreased by $0.90 \mu\text{m}$. RMSE for the control points decreased by 0.17 m on average, and by 0.13 m for check points. However, the accuracy of determining the angular elements of the exterior orientation ω, φ, κ increased by an average of 0.176° . For the second data set, the use of the first method also increased the accuracy of the block adjustment. The value of σ_0 decreased by $0.10 \mu\text{m}$. The RMSE for control points decreased on average by 0.06 m, for control

points by 0.02 m. On the other hand, the accuracy of determining the angular elements of the external orientation ω, φ, κ increased by an average of 0.080°. Similar results were obtained in the research of Casella et al. [86], where the authors present bundle adjustment in three different configurations of GCPs and check points, using five different types of software. The use of additional adjustment parameters improves the adjustment results. Similar conclusions are presented in the article by Rango et al. [87].

Within the photogrammetric community, ref. [88] compared the undamped GM method with the LM method on the spatial resection problem. On the BA problem, Börlin et al. [89] suggested the GNA algorithm and compared it to the GM method on a problem with two cameras. The conclusion was that the GNA method reduced the number of convergence failures compared to GM at an insignificant extra computational cost. Later, ref. [73] applied the LM and LMP (called DL) algorithms on the BA problem and concluded that LMP was faster than LM.

The second method of single-strip block adjustment using the modified Levenberg–Marquardt–Powell algorithm allowed for a slight increase in the adjustment accuracy. For data set I—Łagiewniki, the mean error of a typical observation σ_0 decreased by 1.30 μm . The RMSE for control points and check points was not improved. However, the accuracy of determining the angular elements of the exterior orientation ω, φ, κ increased by an average of 0.007°. For the second data set, the value of σ_0 decreased by 0.80 μm . The RMSE for the control points decreased by 0.02 m on average, and by 0.01 m for check points. However, the accuracy of determining the angular elements of the exterior orientation ω, φ, κ increased by 0.005°.

The legitimacy of using the LMP algorithm for bundle adjustment has already been confirmed [63,73].

The obtained test results prove the universality of the presented approach for the adjustment of a single-strip block with a limited number of control points in areas with restricted access. The presented research shows the validity of using both the modified linear regression method and the empirically modified Levenberg–Marquardt–Powell method for block compensation. The linear regression method ensures an even distribution of control points in the study area, with particular emphasis on the outer edges of the images. The limitation of this method may be the lengthy and complex filtering process of the tie points. The modified LMP method does not ensure an even distribution of the GCPs.

The approach proposed by the authors may be a new direction in the orientation of low altitude imagery from low-cost UAVs. The presented approach based on the modified Levenberg–Marquardt–Powell algorithm made it possible to increase the accuracy of the adjustment regardless of the input data (two different UAV systems were used), which proves the universality of the proposed methodology. Ongoing research also revealed some imperfections in the orientation of single-strip blocks, suggesting the need to develop a new approach to facilitate a more reliable assessment. Compared to the traditional bundle adjustment method, the BA with Levenberg–Marquardt–Powell process allows for a noticeable increase in the accuracy of determining the coordinates of projection centers with low accuracy GNSS and with a limited number of GCPs.

The developed method of adjustment of single-strip block does not reduce the accuracy in relation to the latest methods with precise registration of flight trajectory. This method is recommended for the orientation of images obtained by low-cost UAVs because the single-frequency GNSS receivers installed onboard them will not allow for more accurate registration of the linear elements of exterior orientation. Low-cost UAVs are also particularly sensitive to wind, and in this case, the negative impact of the rotation angles will be significant. The conducted research also showed that the proposed method can use the advantages of the on-board GNSS/IMU receiver with the additional condition of using an optimized method of selecting tie points at the adjustment stage. This results in an improved processing method that reduces the values of the final processing errors.

A limitation of the presented method is that it may not improve the accuracy of adjustment on blocks consisting of images with irregular geometry (e.g., high tilt angles for the images—above 6°) or blocks with asymmetric coverage between images—below 70%. In addition, for blocks with images

of an irregular shape or atypical distribution of GCPs, the use of the developed methodology may even cause a decrease in accuracy

6. Conclusions

The article presents the results of experiments and analyses concerning the adjustment of a single-strip block. The main objective of the research was to develop a methodology of adjusting single-strip blocks of low altitude imagery of highway landing strips, taking into account the limited access to the entire study area. The research was based on two methods. The first one, presenting a proprietary approach to the use of tie points in the adjustment process, was based on a modified linear regression method. The second method was based on a linear optimization method—the modified Levenberg–Marquardt–Powell algorithm. Based on the conducted analyses, it was found that the use of both methods to adjust a single-strip block improve adjustment results. It was noticed that the RMSE error values for the X, Y coordinates were smaller than for the Z coordinates, which confirms the common rule in photogrammetry. It was also noticed that an even distribution of GCPs significantly improves the accuracy of the adjustment (on average by 50%). Locating the GCPs on the edge of the block improves the accuracy for the angular elements of the exterior orientation ω , φ , κ (on average by 25%). Based on the comparative analysis of the first and second methods, it was found that the second method improved the accuracy of the adjustment by 16% for the flight carried out in Łagiewniki and by 13% for the mission carried out in Nadarzyce.

In the future, research is planned on the methodology of developing landing approach maps based on data obtained from UAVs.

Author Contributions: Conceptualization, D.W.; methodology, M.L. and D.W.; software, M.L.; validation, M.L.; formal analysis, M.L.; investigation, M.L. and D.W.; resources, M.L.; data creation, M.L. and D.W.; writing—original draft preparation, M.L.; writing—review and editing, D.W. and M.K.; visualization, M.L.; supervision, D.W. and M.K.; project administration, D.W.; funding acquisition, M.L. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Acknowledgments: This paper was supported by the Military University of Aviation in the year of 2020.

Conflicts of Interest: The authors declare no conflict of interest.

Database: <https://drive.google.com/drive/folders/1NZ2i3UIYLRuOjKTAgRfsRsQ1BLIpZHrW?usp=sharing>.

References

1. Daakir, M.; Pierrot-Deseilligny, M.; Bosser, P.; Pichard, F.; Thom, C.; Rabot, Y.; Martin, O. Lightweight UAV with on-board photogrammetry and single-frequency GPS positioning for metrology applications. *ISPRS J. Photogramm. Remote Sens.* **2017**, *127*, 115–126. [[CrossRef](#)]
2. Eling, C.; Wieland, M.; Hess, C.; Klingbeil, L.; Kuhlmann, H. Development and evaluation of a UAV based mapping system for remote sensing and surveying applications, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XL-1/W4. In Proceedings of the 2015 International Conference on Unmanned Aerial Vehicles in Geomatics, Toronto, ON, Canada, 30 August–2 September 2015.
3. Colomina, I.; Molina, P. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS J. Photogramm. Remote Sens.* **2014**, *92*, 79–97. [[CrossRef](#)]
4. Kędzierski, M.; Wierzbicki, D. Methodology of improvement of radiometric quality of images acquired from low altitudes. *Measurement* **2016**, *92*, 70–78. [[CrossRef](#)]
5. Nex, F.; Remondino, F. UAV for 3D mapping applications: A review. *Appl. Geomat.* **2014**, *6*, 1–15. [[CrossRef](#)]
6. Vacca, A.; Onishi, H. Drones: Military weapons, surveillance or mapping tools for environmental monitoring? The need for legal framework is required. *Transp. Res. Procedia* **2017**, *25*, 51–62. [[CrossRef](#)]

7. Gonçalves, J.A.; Henriques, R. UAV photogrammetry for topographic monitoring of coast areas. *ISPRS J. Photogramm. Remote Sens.* **2015**, *104*, 101–111. [[CrossRef](#)]
8. Lin, Y.; Jiang, M.; Yao, Y.; Zhang, L.; Lin, J. Use of UAV oblique imaging for the detection of individual trees in residential environments. *Urban For. Urban Green.* **2015**, *14*, 404–412. [[CrossRef](#)]
9. Jiang, S.; Jiang, W. Efficient structure from motion for oblique UAV images based on maximal spanning tree expansion. *ISPRS J. Photogramm. Remote Sens.* **2017**, *132*, 140–161. [[CrossRef](#)]
10. Groos, A.R.; Bertschinger, T.J.; Kummer, C.M.; Erlwein, S.; Munz, L.; Philipp, A. The Potential of Low-Cost UAVs and Open-Source Photogrammetry Software for High-Resolution Monitoring of Alpine Glaciers: A Case Study from the Kanderfirn (Swiss Alps). *Geosciences* **2019**, *9*, 356. [[CrossRef](#)]
11. Eisenbeiss, H. A mini Unmanned Aerial Vehicle (UAV): System overview and image acquisition. *Int. Arch. Photogramm. Remote Sens.* **2004**, *36*, 1–7.
12. Berni, J.; Zarco-Tejada, P.; Suárez, L.; Fereres, E. Thermal and narrowband multispectral remote sensing for vegetation monitoring from an unmanned aerial vehicle. *IEEE Trans. Geosci. Remote Sens.* **2009**, *47*, 722–738. [[CrossRef](#)]
13. Lin, Y.; Hyppä, J.; Jaakkola, A. Mini-UAV-Borne LIDAR for Fine-Scale Mapping Geoscience and Remote Sensing Letters. *IEEE Trans. Geosci. Remote Sens.* **2011**, *8*, 426–430. [[CrossRef](#)]
14. Lerma, J.; Navarro, S.; Cabrelles, M.; Villaverde, V. Terrestrial laser scanning and close range photogrammetry for 3D archaeological documentation: The Upper Palaeolithic cave of Parpall as a case study. *J. Archaeol. Sci.* **2010**, *37*, 499–507. [[CrossRef](#)]
15. Reich, M.; Wiggenhagen, M.; Muhle, D. Filling the holes—Potential of UAV-based photogrammetric façade modeling. In Proceedings of the Tagungsband des 15, 3D-NordOst Workshops der GFaI, Berlin, Germany, 6–7 December 2012.
16. Mesas-Carrascosa, F.; Rumbao, I.; Berrocal, J.; Porras, A. Positional Quality Assessment of Orthophotos Obtained from Sensors Onboard Multi-Rotor UAV Platforms. *Sensors* **2014**, *14*, 22394–22407. [[CrossRef](#)]
17. Remondino, F.; Barazzetti, L.; Nex, F.; Scaioni, M.; Sarazzi, D. Uav photogrammetry for mapping and 3d modeling-current status and future perspectives. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2011**, *38*, C22. [[CrossRef](#)]
18. Ahmad, A. Digital Mapping Using Low Altitude UAV. *Pertanika J. Sci. Technol.* **2011**, *19*, 51–58.
19. Rozporządzenia Ministra Infrastruktury z dnia 25 czerwca 2003 w sprawie warunków, jakie powinny spełniać obiekty budowlane oraz naturalne w otoczeniu lotniska. *Dziennik Ustaw*, 8 August 2003. (In Polish)
20. ICAO. *Aeronautical Charts, Annex 4 to the Convention on International Civil Aviation, International Civil Aviation Organization*, 9th ed.; ICAO: Montreal, QC, Canada, 2009; pp. 47–50.
21. ICAO. *Annex 14 to the Convention on International Civil Aviation Aerodromes—Aerodrome Desing and Operations*, 7th ed.; ICAO: Montreal, QC, Canada, 2016; Available online: <https://cockpitdata.com/Software/ICAO%20Annex%202014%20Volume%20201%20207th%20Edition%202016> (accessed on 12 October 2020).
22. Rozporządzenie Ministra Infrastruktury z Dnia 20 lipca 2004 r. w Sprawie Wymagań dla Lotnisk. *Dziennik Ustaw*; 17 August 2004. Available online: <http://isap.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20041701791> (accessed on 12 October 2020). (In Polish)
23. Decyzja Nr 348/Ministra Obrony Narodowej z dnia 28 grudnia 2016 r. w Sprawie Wprowadzenia do użytku w Lotnictwie Sił Zbrojnych Rzeczypospolitej Polskiej “Instrukcji Zarządzania Ruchem Lotniczym w Siłach Zbrojnych Rzeczypospolitej Polskiej” (IZRL-2017). *Dziennik Urzędowy Ministra Obrony Narodowej*. 30 December 2016. 25. Available online: <https://www.infor.pl/akt-prawny/U23.2016.081.0000220,decyzja-nr-348mon-ministra-obrony-narodowej-w-sprawie-wprowadzenia-do-uzytku-w-lotnictwie-sil-zbrojnych-rzeczypospolitej-polskiej-instrukcji-zarzadzania-ruchem-lotniczym-w-silach-zbrojnych-rzeczypospo.html> (accessed on 12 October 2020). (In Polish).
24. He, F.; Habib, A.; Al-Rawabdeh, A. Planar constraints for an improved uav-image-based dense point cloud generation. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2015**, *40*, 269. [[CrossRef](#)]
25. Lari, Z.; Al-Rawabdeh, A.; He, F.; Habib, A.; El-Sheimya, N. Region-based 3D surface reconstruction using images acquired by low-cost unmanned aerial systems. *ISPRS-Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2015**, *40*, 167–173. [[CrossRef](#)]
26. He, F.; Habib, A. Automated Relative Orientation of UAV-Based Imagery in the Presence of Prior Information for the Flight Trajectory. *Photogramm. Eng. Remote Sens.* **2016**, *82*, 879–891. [[CrossRef](#)]

27. Gomez, C.; Purdie, H. UAV-based photogrammetry and geocomputing for hazards and disaster risk monitoring—A review. *GeoenvIRON. Disast.* **2016**, *3*, 23. [[CrossRef](#)]
28. Tsouros, D.C.; Bibi, S.; Sarigiannidis, P.G. A Review on UAV-Based Applications for Precision Agriculture. *Information* **2019**, *10*, 349. [[CrossRef](#)]
29. Tao, W.; Lei, Y. UAV aerotriangulation with flight-control data support. In Proceedings of the 2011 Second International Conference on Mechanic Automation and Control Engineering, Hohhot, China, 15–17 July 2011; pp. 2801–2804.
30. Przybilla, H.J.; Bäumker, M.; Luhmann, T.; Hastedt, H.; Eilers, M. Interaction between direct georeferencing, control point configuration and camera self-calibration for rtk-based uav photogrammetry. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2020**, *43*, 485–492. [[CrossRef](#)]
31. Luhmann, T.; Robson, S. *Close Range Photogrammetry: Principles, Methods and Applications*, Cdr ed.; Whittles Publishing: Dunbeath, UK, 2011.
32. Fryer, J.; Mitchell, H.; Chandler, J. *Applications of 3D Measurement from Images*; Whittles Publishing: Dunbeath, UK, 2007; p. 312.
33. DeWitt, B.A.; Wolf, P.R. *Elements of Photogrammetry (with Applications in GIS)*, 3rd ed.; McGraw-Hill Higher Education: New York, NY, USA, 2000.
34. Harwin, S.; Lucieer, A. Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from Unmanned Aerial Vehicle (UAV) imagery. *Remote Sens.* **2012**, *4*, 1573–1599. [[CrossRef](#)]
35. Mancini, F.; Dubbini, M.; Gattelli, M.; Stecchi, F.; Fabbri, S.; Gabbianelli, G. Using Unmanned Aerial Vehicles (UAV) for High-Resolution Reconstruction of Topography: The Structure from Motion Approach on Coastal Environments. *Remote Sens.* **2013**, *5*, 6880–6898. [[CrossRef](#)]
36. Yang, H.; Li, H.; Gong, Z.; Dai, W.; Lu, S. Relations between the Number of GCPs and Accuracy of UAV Photogrammetry in the Foreshore of the Sandy Beach. *J. Coast. Res.* **2020**, *95*, 1372–1376. [[CrossRef](#)]
37. Saponaro, M.; Tarantino, E.; Reina, A.; Furfarò, G.; Fratino, U. Assessing the Impact of the Number of GCPs on the Accuracy of Photogrammetric Mapping from UAV Imagery. *Baltic Surv.* **2019**, *10*, 43–51.
38. Tmušić, G.; Manfreda, S.; Aasen, H.; James, M.R.; Gonçalves, G.; Ben Dor, E.; Brook, A.; Polinova, M.; Arranz, J.J.; Mészáros, J.; et al. Current Practices in UAS-based Environmental Monitoring. *Remote Sens.* **2020**, *12*, 1001. [[CrossRef](#)]
39. Tahar, K.N. An evaluation on different number of ground control points in unmanned aerial vehicle photogrammetric block. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2013**, *40*, 93–98. [[CrossRef](#)]
40. Shahbazi, M.; Sohn, G.; Théau, J.; Menard, P. Development and evaluation of a UAV-photogrammetry system for precise 3D environmental modeling. *Sensors* **2015**, *15*, 27493–27524. [[CrossRef](#)]
41. Oniga, V.-E.; Breaban, A.-I.; Pfeifer, N.; Chirila, C. Determining the Suitable Number of Ground Control Points for UAS Images Georeferencing by Varying Number and Spatial Distribution. *Remote Sens.* **2020**, *12*, 876. [[CrossRef](#)]
42. Yu, J.J.; Kim, D.W.; Lee, E.J.; Son, S.W. Determining the Optimal Number of Ground Control Points for Varying Study Sites through Accuracy Evaluation of Unmanned Aerial System-Based 3D Point Clouds and Digital Surface Models. *Drones* **2020**, *4*, 49. [[CrossRef](#)]
43. Agüera-Vega, F.; Carvajal-Ramírez, F.; Martínez-Carricendo, P. Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle. *Measurement* **2017**, *98*, 221–227. [[CrossRef](#)]
44. Hugenholz, C.; Brown, O.; Walker, J.; Barchyn, T.; Nesbit, P.; Kucharczyk, M.; Myshak, S. Spatial accuracy of UAV-derived orthoimagery and topography: Comparing photogrammetric models processed with direct geo-referencing and ground control points. *Geomatica* **2016**, *70*, 21–30. [[CrossRef](#)]
45. He, F.; Zhou, T.; Xiong, W.; Hasheminnasab, S.M.; Habib, A. Automated aerial triangulation for UAV-based mapping. *Remote Sens.* **2018**, *10*, 1952. [[CrossRef](#)]
46. Förstner, W.; Wrobel, B.P. *Photogrammetric Computer Vision*; Springer: Berlin, Germany, 2016.
47. Urban, S.; Wursthorn, S.; Leitloff, J.; Hinz, S. MultiCol Bundle Adjustment: A Generic Method for Pose Estimation, Simultaneous Self-Calibration and Reconstruction for Arbitrary Multi-Camera Systems. *Int. J. Comput. Vis.* **2017**, *121*, 234–252. [[CrossRef](#)]
48. Granshaw, S.I. Bundle adjustment methods in engineering photogrammetry. *Photogramm. Rec.* **1980**, *10*, 181–207. [[CrossRef](#)]
49. Habib, A.; Morgan, M.F. Automatic calibration of low-cost digital cameras. *Opt. Eng.* **2003**, *42*, 948–956.

50. Bartoli, A.; Sturm, P. Structure-from-motion using lines: Representation, triangulation, and bundle adjustment. *Comput. Vis. Image Understand.* **2005**, *100*, 416–441. [[CrossRef](#)]
51. Lee, W.H.; Yu, K. Bundle block adjustment with 3D natural cubic splines. *Sensors* **2009**, *9*, 9629–9665. [[CrossRef](#)]
52. Vo, M.; Narasimhan, S.G.; Sheikh, Y. Spatiotemporal bundle adjustment for dynamic 3d reconstruction. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016; pp. 1710–1718.
53. Triggs, B.; McLauchlan, P.F.; Hartley, R.I.; Fitzgibbon, A.W. Bundle adjustment—A modern synthesis. In *International Workshop on Vision Algorithms*; Springer: Berlin, Germany, 1999; pp. 298–372.
54. Lourakis, M.I.; Argyros, A.A. SBA: A software package for generic sparse bundle adjustment. *ACM Trans. Math. Softw. (TOMS)* **2009**, *36*, 2. [[CrossRef](#)]
55. Wu, C.; Agarwal, S.; Curless, B.; Seitz, S.M. Multicore bundle adjustment. In Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2011), Providence, RI, USA, 20–25 June 2011; pp. 3057–3064.
56. Borgogno Mondino, E.; Chiabrando, R. Multi-temporal block adjustment for aerial image time series: The Belvedere glacier case study. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2008**, *XXXVII Pt B2*, 89–94.
57. Kraus, K. Photogrammetry—Geometry from Images and Laser Scans. *J. Chem. Inf. Modeling* **2007**, *53*, 1–30. [[CrossRef](#)]
58. Forlani, G.; Diotri, F.; di Cellia, U.M.; Roncella, R. Indirect UAV strip georeferencing by on-board GNSS data under poor satellite coverage. *Remote Sens.* **2019**, *11*. [[CrossRef](#)]
59. Jiang, S.; Jiang, W. Uav-based oblique photogrammetry for 3D reconstruction of transmission line: Practices and applications. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.—ISPRS Arch.* **2019**, *42*, 401–406. [[CrossRef](#)]
60. Pędziuch, P.; Kuźma, M. Application of methods for area calculation of geodesic polygons on Polish administrative units. *Geod. Cartogr.* **2013**, *61*, 105–115. [[CrossRef](#)]
61. Brown, S.H. Multiple Linear Regression Analysis: A Matrix Approach with MATLAB. *Ala. J. Math. Spring/Fall* **2009**, *34*, 1–3.
62. Börlin, N.; Murtiyoso, A.; Grussenmeyer, P. Implementing functional modularity for processing of general photogrammetric data with the damped bundle adjustment toolbox (DBAT). *Int. Arch. Photogramm. Remote Sens. Patial Inf. Sci.—ISPRS Arch.* **2019**, *42*, 69–75. [[CrossRef](#)]
63. Börlin, N.; Grussenmeyer, P. Bundle Adjustment with and without Damping. *Photogramm. Rec.* **2013**, *28*, 396–415. [[CrossRef](#)]
64. Börlin, N.; Grussenmeyer, P. Experiments with Metadata-derived Initial Values and Linesearch Bundle Adjustment in Architectural Photogrammetry. *ISPRS Ann. Photogramm. Remote Sens. Spat. Inf. Sci.* **2013**, *2*, 43–48. [[CrossRef](#)]
65. Montgomery, D.C.; Peck, E.A.; Vining, G.G. *Introduction to Linear Regression Analysis*, 3rd ed.; Wiley: New York, NY, USA, 2001; pp. 131–154.
66. Gillan, J.K.; McClaran, M.P.; Swetnam, T.L.; Heilman, P. Estimating forage utilization with drone-based pho-grammetric point clouds. *Rangel. Ecol. Manag.* **2019**, *72*, 575–585. [[CrossRef](#)]
67. Stal, C.; Briese, C.; De Maeyer, P.; Dorninger, P.; Nuttens, T.; Pfeifer, N.; De Wulf, A. Classification of airborne laser scanning point clouds based on binomial logistic regression analysis. *Int. J. Remote Sens.* **2014**, *35*, 3219–3236. [[CrossRef](#)]
68. Conte, P.; Girelli, V.A.; Mandanici, E. Structure from Motion for aerial thermal imagery at city scale: Pre-processing, camera calibration, accuracy assessment. *ISPRS J. Photogramm. Remote Sens.* **2018**, *146*, 320–333. [[CrossRef](#)]
69. Yang, N.; Cheng, Q.; Xiao, X.; Zhang, L.; Jiang, X. Point cloud optimization method of low-altitude remote sensing image based on vertical patch-based least square matching. *J. Appl. Remote Sens.* **2016**, *10*, 035003. [[CrossRef](#)]
70. Li, M. High-precision relative orientation using feature-based matching techniques. *ISPRS J. Photogramm. Remote Sens.* **1990**, *44*, 311–324. [[CrossRef](#)]

71. Debella-Gilo, M.; Kääb, A. Measurement of Surface Displacement and Deformation of Mass Movements Using Least Squares Matching of Repeat High Resolution Satellite and Aerial Images. *Remote Sens.* **2012**, *4*, 43–67. [CrossRef]
72. Gordon, S.; Gordon, F. Deriving the regression equations without calculus. *Math. Comput. Educ.* **2004**, *38*, 64–68.
73. Lourakis, M.I.A.; Argyros, A.A. Is Levenberg-Marquardt the most efficient optimization algorithm for implementing bundle adjustment? In Proceedings of the IEEE International Conference on Computer Vision, Beijing, China, 17–21 October 2005; pp. 1526–1531.
74. Nocedal, J.; Wright, S.J. *Numerical Optimization*, 2nd ed.; Springer: Berlin, Germany, 2006; pp. 254–262. Available online: https://books.google.pl/books?hl=pl&lr=&id=VbHYoSyelFcC&oi=fnd&pg=PR17&dq=69.+Nocedal,+J.%3B+Wright,+S.+J.,+2006.+Numerical+Optimization.+Second+Edition.+Springer,+Berlin,+Germany.+664+pages.&ots=31Uczqx1SN&sig=9RPngMHdC9KKilJKdtAZYKOVRsU&redir_esc=y#v=onepage&q&f=false (accessed on 23 July 2020).
75. Levenberg, K. A method for the solution of certain non-linear problems in least squares. *Quart. Appl. Math.* **1944**, *2*, 164–168. [CrossRef]
76. Marquardt, D. An algorithm for the least-squares estimation of nonlinear parameters. *J. Soc. Ind. Appl. Math.* **1963**, *11*, 431–441. [CrossRef]
77. Madsen, K.; Nielsen, H.; Tingleff, O. *Methods for Non-Linear Least Squares Problems*, 2nd ed.; Informatics and Mathematical Modelling; Technical University of Denmark: Lyngby, Denmark, 2004.
78. Nocedal, J.; Wright, S. *Numerical Optimization*, 2nd ed.; Springer: New York, NY, USA, 1999; pp. 66–98. Available online: https://books.google.pl/books?hl=pl&lr=&id=VbHYoSyelFcC&oi=fnd&pg=PR17&ots=31UczpD1UJ&sig=fgLs3BySzuaSOznlBR9kGZ3ay6s&redir_esc=y#v=onepage&q&f=false (accessed on 23 July 2020).
79. Draper, N.R.; Smith, J.R.H. *Applied Regression Analysis*, 3rd ed.; John Wiley: New York, NY, USA, 1981; pp. 135–147. Available online: https://books.google.pl/books?hl=pl&lr=&id=d6NsDwAAQBAJ&oi=fnd&pg=PR13&dq=74.%09Draper,+N.+R.%3B+Smith,+JR.,+H.,+Applied+Regression+Analysis,+2nd+ed.+John+Wiley&ots=Bxv8m9mZNL&sig=InDgGqoCUoInhL1Xa408yEch2tE&redir_esc=y#v=onepage&q&f=false (accessed on 23 July 2020).
80. Press, W.H.; Teukolsky, S.A.; Vetterling, W.T.; Flannery, B.P. *Numerical Recepies in Fortan* 77, 2nd ed.; Cambridge University Press: Cambridge, UK, 1992; pp. 678–683. Available online: https://books.google.pl/books?hl=pl&lr=&id=gn_4mpdN9WkC&oi=fnd&pg=PR13&ots=UfxaZiQkyl&sig=TWrVj-uWIKF5GHDQzRzT_RQydpc&redir_esc=y#v=onepage&q&f=false (accessed on 23 July 2020).
81. Hartley, R.I.; Zisserman, A. *Multiple View Geometry in Computer Vision*; Cambridge University Press: Cambridge, UK, 2000; pp. 600–608. Available online: https://books.google.pl/books?hl=pl&lr=&id=sj3R3Pfa98QC&oi=fnd&pg=PR11&dq=Multiple+View+Geometry+in+Computer+Vision&ots=aSx0nx583J&sig=VB0WEJYi2V4e79bwi7Fo5-xO6oA&redir_esc=y#v=onepage&q=Multiple%20View%20Geometry%20in%20Computer%20Vision&f=false (accessed on 23 July 2020).
82. Powell, M.J.D. A hybrid method for nonlinear equations. In *Numerical Methods for Nonlinear Algebraic Equations*; Rabinowitz, P., Ed.; Gordon and Breach Science: London, UK, 1970; pp. 87–144.
83. Gould, N.I.M.; Orban, D.; Sartenaer, A.; Toint, P.L. Sensitivity of trust-region algorithms to their parameters. *4OR* **2005**, *3*, 227–241. [CrossRef]
84. Yuan, Y. On a subproblem of trust region algorithms for constrained optimization. *Math. Program.* **1990**, *47*, 53–63. [CrossRef]
85. Saile, J. *High Performance Photogrammetric Production, Photogrammetric Week'11*; Wichmann/VDE Verlag: Belin/Offenbach, Germany, 2011; pp. 21–27. Available online: <https://phowo.ifp.uni-stuttgart.de/publications/phowo11/030Saile.pdf> (accessed on 23 July 2020).
86. Casella, V.; Chiabrando, F.; Franzini, M.; Manzino, A.M. Accuracy Assessment of A UAV Block by Different Software Packages, Processing Schemes and Validation Strategies. *ISPRS Int. J. Geo-Inf.* **2020**, *9*, 164. [CrossRef]
87. Rango, A.; Laliberte, A.; Herrick, J.E.; Winters, C.; Havstad, K.; Steele, C.; Browning, D. Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. *J. Appl. Remote Sens.* **2009**, *3*, 033542.

88. Jianchar, Y.; Chern, C.T. Comparison of Newton-Gauss with Levenberg-Marquardt algorithm for space resection. In Proceedings of the 22nd Asian Conference on Remote Sensing, Singapore, 5–9 November 2001; pp. 256–261.
89. Börlin, N.; Grussenmeyer, P.; Eriksson, J.; Lindström, P. Pros and cons of constrained and unconstrained formulation of the bundle adjustment problem. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2004**, *35*, 589–594.



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Załącznik 2 – [Publikacja 2]



Volume 119

2023

p-ISSN: 0209-3324

e-ISSN: 2450-1549

DOI: <https://doi.org/10.20858/sjsutst.2023.119.5>

Journal homepage: <http://sjsutst.polsl.pl>



Article citation information:

Lalak, M., Krasuski, K., Wierzbicki, D. Methodology to improve the accuracy of determining the position of UAVs equipped with single-frequency receivers for the purposes of gathering data on aviation obstacles. *Scientific Journal of Silesian University of Technology. Series Transport*. 2023, **119**, 83-104. ISSN: 0209-3324.

DOI: <https://doi.org/10.20858/sjsutst.2023.119.5>.

Marta LALAK¹, Kamil KRASUSKI², Damian WIERZBICKI³

**METHODOLOGY TO IMPROVE THE ACCURACY OF
DETERMINING THE POSITION OF UAVS EQUIPPED WITH SINGLE-
FREQUENCY RECEIVERS FOR THE PURPOSES OF GATHERING
DATA ON AVIATION OBSTACLES**

Summary. Low-altitude photogrammetric studies are often applied in detection of aviation obstacles. The low altitude of the Unmanned Aerial Vehicle (UAV) flight guarantees high spatial resolution (X, Y) of the obtained data. At the same time, due to high temporal resolution, UAVs have become an appropriate tool for gathering data about such obstacles. In order to ensure the required accuracy of orientation of the photogrammetric block, Ground Control Points (GCPs) are measured. The recently introduced UAV positioning solutions that are based on Post-Processing Kinematic (PPK) and Real Time Kinematic (RTK) are known to effectively reduce, or, according to other sources, even completely eliminate the necessity to conduct GCP measurements. However, the RTK method involves multiple limitations that result from the need to ensure continuous communication between the reference station and the rover receiver. The main challenge lies in

¹ Institute of Navigation, Polish Air Force University, Dywizjonu 303 35 Street, 08-521 Dęblin, Poland. Email: m.lalak@law.mil.pl. ORCID: <https://orcid.org/0000-0001-5485-4720>

² Institute of Navigation, Polish Air Force University, Dywizjonu 303 35 Street, 08-521 Dęblin, Poland. Email: k.krasuski@law.mil.pl. ORCID: <https://orcid.org/0000-0001-9821-4450>

³ Department of Imagery Intelligence, Faculty of Civil Engineering and Geodesy, Military University of Technology, Kaliskiego 2 Street, 00-908 Warsaw, Poland. Email: damian.wierzbicki@wat.edu.pl. ORCID: <https://orcid.org/0000-0001-6192-3894>

achieving accurate orientation of the block without the need to conduct time-consuming ground measurements that are connected to signalling and measuring the GCPs. Such solution is required if the SPP code method is applied to designation the position of the UAV. The paper presents a research experiment aimed at improving the accuracy of the determination of the coordinates of UAV for the SPP method, in real time. The algorithm of the SPP method was improved with the use of IGS products.

Keywords: IGS, GPS, UAV, photogrammetry, aviation obstacle, accuracy analysis, SBAS

1. INTRODUCTION

In recent years, we have been witnessing a dynamic growth in the use of low altitude photogrammetric studies in remote sensing [13, 40], in Geographic Information Systems (GIS) [2, 9] or aviation [10]. The potential of these miniature aerial vehicles that has also been noticed by the aviation sector is used, among others, in ensuring safety in the airspace [14]. The main area of focus in the fields of photogrammetry, remote sensing and geographic information is currently the monitoring of aviation obstacles, including the detection of such obstacles in the vicinity of airports.

The 21st century has become a symbol of the development of various branches of the industry. This leads to the dramatic growth of investment areas. As a result, we are witnessing rapidly emerging new objects (various types of structures, etc.) not only in large agglomerations, but also in less urbanised areas and in the neighbourhood of airports. From the point of view of aviation safety, such objects situated near the airport may constitute a potential threat for the operations of aerial vessels, and thus become aviation obstacles. Their presence requires developing flight procedures based on the height of the aviation obstacle. Accurate and reliable data about such obstacles, in particular about their location or dimensions, such as height, are essential for planning safe take-off and landing paths for aircrafts. Existing guidelines for aviation obstacle data collection methods strictly define the accuracy of data collection. Despite the regulation of this issue, methods are still evolving to achieve the highest possible degree of automation [14]. The detection of small obstacles and those of elongated shapes is becoming a major challenge [14]. If such an object is captured, it is necessary for the scale of the image to be larger than in traditional exploratory flights. This is possible with a lower flight altitude by using a UAV. The techniques employed for the detection of aviation obstacles used so far were based on Airborne Laser Scanning (ALS). However, in such cases, one cannot exclude the possibility of omitting an obstacle [14], and the object detection was controlled using ordinary geodetic measurements. As a result, the process was time-consuming and strenuous, not to mention ineffective, especially in representing large-surface areas. In order to maintain the safety of air operations, it is necessary that the data about obstacles should be updated regularly, whenever necessary. Unfortunately, ALS data does not guarantee high temporal resolution of obtaining data. The latest guidelines [14] for obtaining obstacle data recommend using data obtained from lower altitudes of flight, which may be achieved by using UAVs. They allow obtaining imagery in a scale which is significantly larger than that obtained from traditional photogrammetric flights. In addition, the UAV altitude will allow for much higher spatial accuracy (X, Y, Z) of aviation obstacle data. The accuracy of obtaining data from UAV is influenced by several factors. Among them, one may distinguish the method and accuracy of positioning of the Unmanned Aerial Vehicle [36] and the accuracy of adjustment

of the photogrammetric block [30, 15, 4]. Until recently, the processing of data obtained from a photogrammetric flight required conducting a measurement of the control points (GCP) to perform an absolute orientation of the model. This resulted in an extended duration of the process of measurement as well as data processing. Currently, the development of the UAV technology, among others, in photogrammetric applications, resulted in the possibility to use numerical algorithms that improve the positioning of the platform in real time, while the necessary navigation analyses may be conducted in post-processing mode. As a consequence, this may lead to the complete elimination of the need to conduct measurements of ground control points (GCP). For more than ten years, the main device used to detect the position of the UAV has been the GNSS (Global Navigation Satellite System) satellite receiver with the functions of tracking, monitoring, and recording the observations and navigation data. GNSS receivers provide the 3 main navigation parameters of a UAV: position, velocity, and time [23]. From the point of view of photogrammetric applications, the navigation data of the UAV enable the determination of elements of exterior orientation, first of all linear ones, i.e. the centres of the projection of each photograph [15]. In this case, it is necessary to know the eccentric of the position shift of the GNSS receiver antenna and of the camera at the moment of exposure. While the value of the eccentric is provided by the manufacturer on the name plate of the unmanned platform, the position of the antenna of the GNSS receiver mounted on the platform still has to be determined. In low-cost on-board GNSS receivers, the coordinates of the UAV is designated in near-real time with the use of the SPP (Single Point Positioning) method [29]. This method is based on the application of single-frequency receivers mounted on the UAV platform [37]. Even though this method is the most commonly used, it is characterised by low positioning accuracy, reaching even up to 10 m [5, 11]. Another currently used solution is an RTK system integrated with the aerial vessel, which can allow the number of GCPs to be reduced or eliminated altogether. However, the RTK method involves multiple limitations that result from the need to ensure continuous communication between the base station and the mobile receiver. It should be noted that a UAV equipped with GPS does not require the data from GNSS reference station, which might significantly improve the efficiency of the process of collecting data on aviation obstacles. Previous studies [33] revealed the possibility to obtain a high accuracy by UAVs equipped with GPS receivers.

The authors of this study took an attempt to improve the determination of the accuracy of the positioning of UAVs for the SPP method. With this aim, IGS products were used to improve the algorithm of the SPP method.

1.1. Related works

In recent years, many studies have been conducted on the application of the single point positioning method to determine the position of aerial vehicles [22]. Publications discussing the accuracy of the SPP method in positioning Unmanned Aerial Vehicles [37] and the attempts to improve this accuracy are also becoming more common. The need to enhance the accuracy of positioning UAVs resulted in the development of numerical algorithms that improve the positioning of UAVs in terms of code observations for the SPP method [39] and thus, the adjustment of the determination of the linear elements of exterior orientation.

In the study by Santerre et al. [29], the Chinese satellite system BeiDou was used and compared to the American GPS system and the Russian GLONASS systems. In fact, the BeiDou system consists of 14 satellites that provide complete coverage of the whole Asia and Pacific area. Positioning with use of the SPP method was conducted in Changsha in the Hunan Province of China, in order to demonstrate the benefits of the use of the combined pseudo-

distance solutions from these 3 satellite navigation systems, in particular in covered locations. The results demonstrated an improvement in accuracy by 20% for the horizontal coordinates and by 50% for the vertical coordinates. The combination of the GPS/GLONASS/BeiDou solutions resulted in an accuracy of approx. 5 m.

Other methods of enhancing the accuracy of the single point positioning method were presented in the study by Angrisano et al. [3]. The tests were conducted with the use of UAVs in the area of an urban agglomeration, with tall structures such as skyscraper buildings. The navigation algorithm for positioning the UAV was based on the weighted average model. The conducted experiments resulted in an accuracy of approx. 10 m, which was achieved in a difficult, urban area.

Furthermore, Forlani et al. [15] presented the results of a research experiment that consisted in assessing the improvement of the orientation accuracy of a photogrammetric block with use of various numbers of GCP. Apart from that, the authors compared alternative positioning methods (including the SPP method) in order to determine the position of the UAV platform. The photogrammetric flight was performed with the Dji Phantom 4 RTK platform on the test military training ground in the Italian Alps. The conducted research demonstrated that determining the coordinates of a UAV platform with the use of the SPP code method allows obtaining a spatial accuracy of several meters when independent ground control points are used in the whole test area.

Kai-Wei Chiang et al. [7] developed a fast and inexpensive system for gathering spatial information in near-real time. The authors pointed out that fast collection of information had become a new trend in remote sensing applications. During the studies, a platform for obtaining spatial information based on UAV, without the need to measure ground control points, was developed. The UAV-based platform shown has a Direct Georeferencing (DG) module [6], which includes an integrated Inertial Navigation System (INS)/ Global Positioning System (GPS). The initially results of the analysis of positioning accuracy in the DG mode revealed that the accuracy of horizontal positioning was approx. 5 m at the flight altitude of 300 m above ground. The positioning accuracy for the vertical component was lower than 10 m.

The research conducted by Himanshu Sharma et al. [34] demonstrated a significant increase in positioning accuracy over the standard SPP solution, after the application of the Kalman filter. H.R. Hosseinpoor et al. [20] developed an algorithm that enables to estimate the geolocation of the target based on the video images captured by a UAV with RTK GPS module. These results were compared to the positioning accuracy obtained with use of the GPS solution for the SPP code method instead of RTK. The research results revealed that the accuracy improved by several tens of centimetres without the necessity to perform measurements of ground control points.

In order to facilitate certain types of applications, e.g., environmental detection or monitoring disasters, it is essential to develop an effective system for acquiring spatial information in near-real time. Speed and ease in gathering spatial information has become the most important goal in land mapping technology. Meng-Lun Tsai et al. [7] presented a platform that was developed to obtain spatial information based on UAV. Additionally, the results of the assessment of data collection accuracy were provided. The presented platform based on UAV is equipped with a DG module, including an integrated INS/GPS system, a digital camera, as well as other general UAV modules in which all the necessary calibration procedures were implemented. During the research project, test flights were conducted in order to verify the positioning accuracy in the direct georeferencing mode, without using ground control points. The preliminary results of the positioning accuracy in direct geo-referencing mode without the use of GCP demonstrated that the accuracy of horizontal positioning was lower than 20 meters,

while the vertical positioning accuracy (z) was lower than 50 m at the flight altitude of 600 meters above ground. The authors pointed out that the obtained accuracy results may be useful in monitoring disasters, where it is vital to obtain spatial information fast, in near-real time.

The literature review revealed a recurring problem of low positioning accuracy of unmanned aerial vehicles when the SPP code method was used. In the conducted research, the authors of the present study took an attempt to enhance the accuracy of positioning the UAV for the purposes of collecting data about aviation obstacles. In order to achieve it, the algorithm of the SPP code method was modified by adding IGS products to determine the position of the UAV.

1.2. Research purpose

In this paper, a research question was posed: whether the modification of the algorithm of the absolute positioning method SPP by adding IGS products will enable to enhance the accuracy of the positioning of UAVs for the purposes of collecting data about aviation obstacles? IGS products are understood as precise ephemerides in the EPH format, precise clocks in the CLK format, the IONEX ionosphere map format, the DCB instrumental error format, and the format of the antenna phase center of the satellite/receiver ANTEX.

The main objective of the research was to develop a methodology to enhance the accuracy of the positioning of UAVs that are equipped with single-frequency receivers and the accuracy of photogrammetric products for the purposes of collecting data about aviation obstacles without measuring the ground control points.

The paper consists of: section 2 where the research method is described; section 3 presents the experimental materials and results; section 4 is a description of the results obtained and section 5 provides a summary.

2. METHODS

This chapter provides a description and presentation of the observation equation for the SPP positioning method with use of GPS navigation data and the observation equation in the modified algorithm of the SPP positioning method with IGS products, i.e.: the precise ephemerides EPH, precise clocks CLK, the IONEX format, DCB format, and ANTEX format. The block diagram of the process of improving the accuracy of determining the position of the UAV for the purposes of collecting data about obstacles is presented in the illustration below (Fig. 1). It presents two methods of determining the position of the UAV: with the SPP method and with the SPP + IGS method. For these two methods, the photogrammetric block of images was adjusted without measuring the ground control points. Then, based on the obtained results, the accuracy of positioning of the UAV and the adjustment of the block of images were analysed.

In this study, two research methods were used to designation the position of the UAV. These were: the classic navigation algorithm for the code-based SPP method using the GPS navigation data and the modified algorithm of the SPP method with the added products of the IGS geodesic service. The fundamental observation equation for the SPP method using GPS navigation data takes the form presented below [18, 31]:

$$l = d + c(dtr - dts) + Ion + Trop + Rel + TGD + Mp \quad (1)$$

where:

l – code observations;

d – geometric distance between the satellite and the receiver;

$$d = \sqrt{(X - X_{GPS})^2 + (Y - Y_{GPS})^2 + (Z - Z_{GPS})^2};$$

(X, Y, Z) – unknown coordinates of the UAV;

$(X_{GPS}, Y_{GPS}, Z_{GPS})$ – coordinates of the GPS satellites;

c – light speed;

dtr – unknown bias of the receiver clock;

dts – correction of the receiver clock;

Ion – ionospheric correction;

$Trop$ – tropospheric delay;

Rel – relativistic effect;

TGD – group delay in GPS system;

Mp – multipath effect.

The positioning algorithm in equation (1) is a classical solution of the position in the SPP method. The position of the UAV in the geocentric frame XYZ are determined from equation (1) in form of parameters (X, Y, Z) .

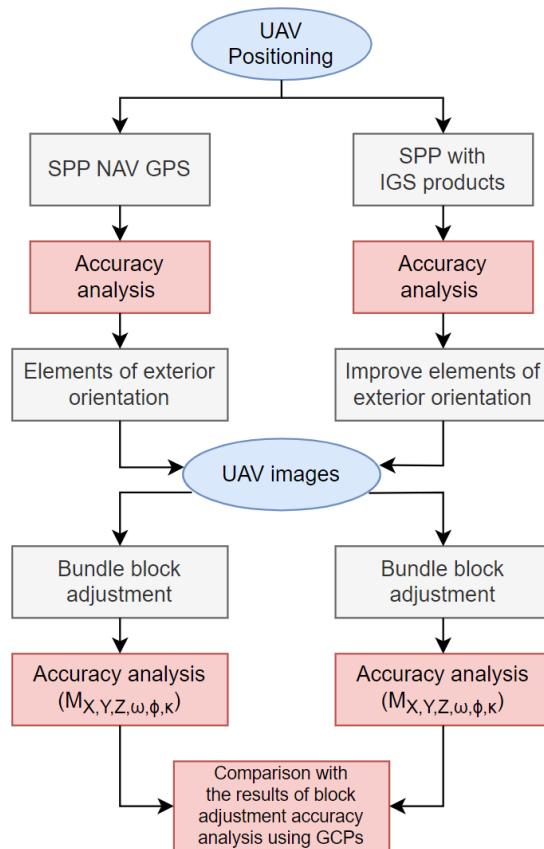


Fig. 1. The scheme of improving the accuracy of UAV position

On the other hand, the basic observation equation in the modified algorithm of the SPP method with use of the IGS products takes the following form [17, 24]:

$$l = d' + c(dtr - dts') + Ion' + Trop + Rel + SDCB'_{P1} + RDCB'_{P1} + Mp \quad (2)$$

where:

l – code observations;

d – geometric distance between the satellite and the receiver, include the phase center offset from ANTEX format;

$$d' = \sqrt{(X - X'_{GPS})^2 + (Y - Y'_{GPS})^2 + (Z - Z'_{GPS})^2};$$

(X, Y, Z) – unknown coordinates of the UAV;

$(X'_{GPS}, Y'_{GPS}, Z'_{GPS})$ – coordinates of GPS satellites, the coordinates are determined with the use of Lagrange's polynomial from the precise ephemeris EPH obtained from the IGS geodesic services;

c – light speed;

dtr – unknown bias of the receiver clock;

dts' – bias of the receiver clock, determined based on the CLK format from the IGS geodesic services;

Ion' – ionosphere delay, which is interpolated from the GRID in the IONEX format obtained from the IGS geodesic services;

$Trop$ – tropospheric delay, calculated based on the determinist model of tropospheric delay;

Rel – relativistic effect;

$SDCB'_{PI}$ – hardware delay for the $SDCB_{PI}$ satellite, based on the DCB product from the IGS geodesic services;

$RDCB'_{PI}$ – hardware delay for the $SDCB_{PI}$ receiver, determined in the linear combination Geometry-Free or based on the DCB product from the IGS geodesic services;

Mp – multipath effect.

The algorithm in equation (2) is a modified solution of positioning in the code-based SPP method, where IGS products were applied, i.e.: the EPH format, CLK format, IONEX format, DCB format, and the ANTEX format. Similarly, as with equation (1), algorithm (2) enables the designation of the coordinates of the UAV. When comparing the observation equations (1) and (2), attention should be paid to different models of systematic errors. Thus, if the position of the GPS satellite on the orbit is determined from equation (1), Kepler's model of the orbit is applied, while equation (2) uses the Lagrange polynomial model. Apart from that, the coordinates of GPS satellites that are determined from the Lagrange polynomial take into account the correction of the phase centre offset of the satellite antenna based on the ANTEX format. The accuracy of positioning from the Kepler model of the orbit is 1 m, while with the Lagrange polynomial it is 0.10 m. Additionally, the error of the satellite clock in the Kepler orbit model is determined with use of a 2nd degree polynomial, and the accuracy of this solution is 5 ns (approx. 0.15 m). In addition, in equation (2), the error of the GPS satellite clock is determined from the CLK format, and its accuracy is higher than 3 ns (approx. 0.1 m [21]). As for the model of the ionosphere, the Klobuchar model applied in equation (1) reduces ionospheric delay by approx. 50-60%, while the ionosphere model from the IONEX format reduces it by approx. 80-90% respectively. As far as hardware delay is concerned, the TGD parameter is used in equation (1), while equation (2) is based on DCB instrumental errors [18]. The comparison of equations (1) and (2) reveals that the application of different types of systematic errors will influence the final designation of the coordinates of the UAV in the stochastic process, as well as the accuracy of positioning of the UAV. The results of the research are presented in Section 3.

3. MATERIALS AND EXPERIMENTAL RESULTS

3.1. Study area

The research experiment was performed near the Radom-Sadków airport (Fig. 2). The Radom-Sadków airport is located near the city centre of Radom. The area surrounding the airport is covered by aviation obstacle data collection zones. In the nearest vicinity of the airport, zone 2a – in the runway strip and zone 2b that is directly connected to zone 2a and covers the take-off sector (Fig. 2).

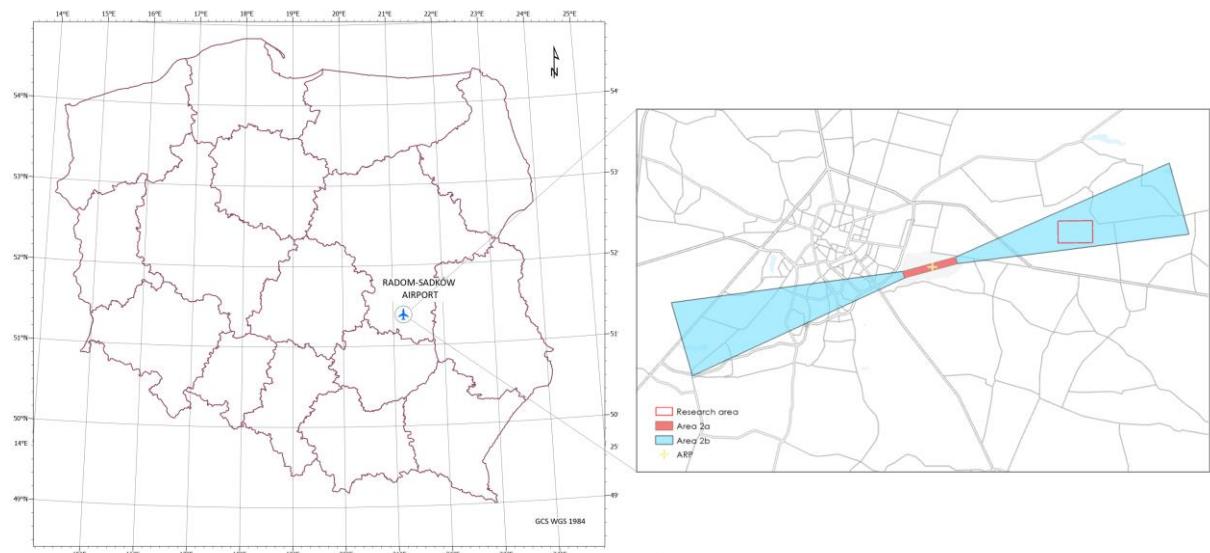


Fig. 2. Location of the research area

The zones of collecting data about aviation obstacles are planes in which data about aviation obstacles are collected. Such data are necessary in the widely understood process of ensuring safety in airspace, from designing flight operations procedures to developing aeronautical charts.

In the research area near the Radom-Sadków airport, data were acquired using the VTOL WingtraOne system. The platform was equipped with a single-frequency GPS receiver, recording data at 10 Hz. The flight was conducted over two test areas in June 2021. Atmospheric conditions during the raids were good. The test block consisted of 35 series, which constituted 850 images (Fig. 2), acquired from a height of 250 m above the ground surface. The flight was conducted in an east-west direction, with transverse and longitudinal coverage of 75%. The main parameters of the test block in the conducted experiment are presented in the table below (Tab. 1).

Tab. 1
Parameters of the test block

Set of coordinates	PUWG 2000/7
Image saving format	JPEG
Number of series	35
Sensor	Sony RX1R II camera

Lens focal length [mm]	35 mm
Average longitudinal/ transverse coverage [%]	75/75
Flight altitude [m]	250
Theoretic pixel size [m]	0.04

For the purposes of conducting the study and verifying the correctness of the applied mathematical algorithms (1) and (2), navigation calculations were performed in the RTKLIB v. 2.4.3 software [28], and then in the language environment Scilab v.6.1.1. [32]. The RTKLIB was used to designation the position of the UAV based on the mathematical equations (1) and (2). For equation (1), the calculations in RTKLIB software were configured as follows [27]:

- source of observation data: format RINEX 2.11,
- source of navigation data: RINEX navigation 2.11,
- observations used: code-based observations L1-C/A from the AsteRx-m2 UAS receiver,
- calculation interval: 1 second,
- set of coordinates: WGS-84, geocentric coordinates XYZ,
- positioning method: SPP,
- source of ephemeral data: GPS navigation message,
- source of data about satellite clock error: GPS navigation message,
- ionosphere model: Klobuchar model from the GPS navigation message,
- elevation mask: 5°,
- troposphere model: Saastamoinen model,
- hardware delay: TGD parameter,
- navigation system: GPS system,
- reference time: GPS Time.

Moreover, for equation (2), the configuration of the computations in the RTKLIB programme was set as follows [27]:

- source of observation data: format RINEX 2.11,
- source of navigation data: RINEX navigation 2.11,
- observations used: code-based observations L1-C/A from the AsteRx-m2 UAS receiver,
- calculation interval: 1 second,
- set of coordinates: WGS-84, geocentric coordinates XYZ,
- positioning method: SPP,
- source of ephemeral data: EPH format and ANTEX format,
- source of data about satellite clock error: CLK format,
- ionosphere model: IONEX format,
- elevation mask: 5°,
- troposphere model: Saastamoinen model,
- hardware delay: DCB format,
- navigation system: GPS system,
- reference time: GPS Time.

The RTKLIB software was also used to determine the reference position of the UAV flight with use of the RTK-OTF positioning method. The following scheme of configuration of the input parameters for the determination of the reference position of flight was applied [27]:

- positioning type: MOVING BASE,
- source of GNSS navigation data: GPS board message,
- source of GNSS observation data from the on-board receiver: kinematic GPS observations in the RINEX 2.12 format from the AsteRx-m2 UAS receiver,
- source of GNSS observation data from reference station: static GPS observations in RINEX 2.12 format,
- method of determining the coordinates of the GPS satellite: based on the parameters of Kepler's orbit,
- elevation mask: 5°,
- ionosphere model: Klobuchar model from the GPS navigation message,
- troposphere model: Saastamoinen model,
- model of orbit and clocks: board ephemeris,
- calculation interval of the measurement epoch: 1 second,
- set of coordinates: WGS-84,
- final format of coordinates: geocentric coordinates XYZ,
- navigation system: GPS,
- reference time: GPS Time.

After the navigation calculations were performed in the RTKLIB software, the authors developed a script in the Scilab programming language to determine the accuracy of the positioning of UAV for the SPP method using equation (1) and for the SPP method with IGS products from equation (2).

3.2. Experimental results

The research experiment consisted in a flight of an unmanned aerial vehicle. Then, based on the obtained data, the accuracy of UAV positioning and the accuracy of the adjustment of the block of images from the UAV were analysed.

3.2.1. Analysis of UAV positioning accuracy

In the framework of the conducted research, the UAV positioning accuracies were determined for equations (1) and (2). Firstly, position errors were determined, i.e., the coordinates of the UAV calculated from equations (1) and (2) were compared to the reference position of the flight from RTK-OTF solution [38]. To achieve it, position errors were calculated as follows:

$$dX = \begin{cases} X_{SPP} - X_{RTK} \\ X_{IGS} - X_{RTK} \end{cases} \quad (3)$$

$$dY = \begin{cases} Y_{SPP} - Y_{RTK} \\ Y_{IGS} - Y_{RTK} \end{cases} \quad (4)$$

$$dZ = \begin{cases} Z_{SPP} - Z_{RTK} \\ Z_{IGS} - Z_{RTK} \end{cases} \quad (5)$$

Where:

(dX, dY, dZ) – position errors,
 $(X_{SPP}, Y_{SPP}, Z_{SPP})$ – coordinates of the UAV from equation (1),
 $(X_{IGS}, Y_{IGS}, Z_{IGS})$ – coordinates of the UAV from equation (2),
 $(X_{RTK}, Y_{RTK}, Z_{RTK})$ – reference coordinates of the UAV flight from the RTK-OTF solution.

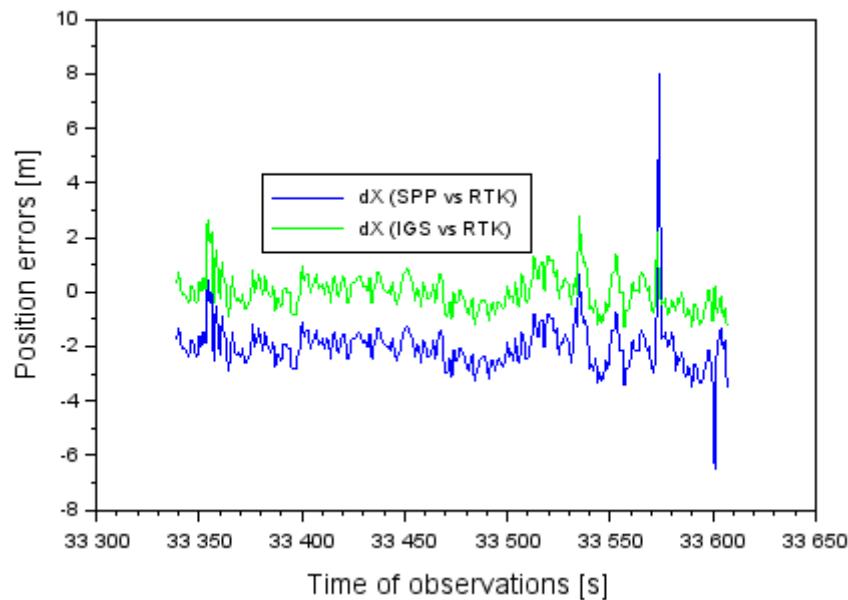


Fig. 3. The position errors for X coordinate

Figure 3 presents the results of position errors for X coordinate for a representative flight of the UAV in Radom. The values of position errors along the X axis for the comparison of the coordinates from equation (1) and the RTK-OTF technique is between -6.5 m to +8.1 m, with the average value of -2.1 m. On the other hand, position errors for equation (2) for the comparison of the coordinates from equation (2) and the RTK-OTF technique ranged from -1.3 m to +2.8 m, with the average value of -0.1 m. The comparison allows us to state that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the position of the UAV along the X axis by approx. 95% in comparison to the classical SPP solution for equation (1).

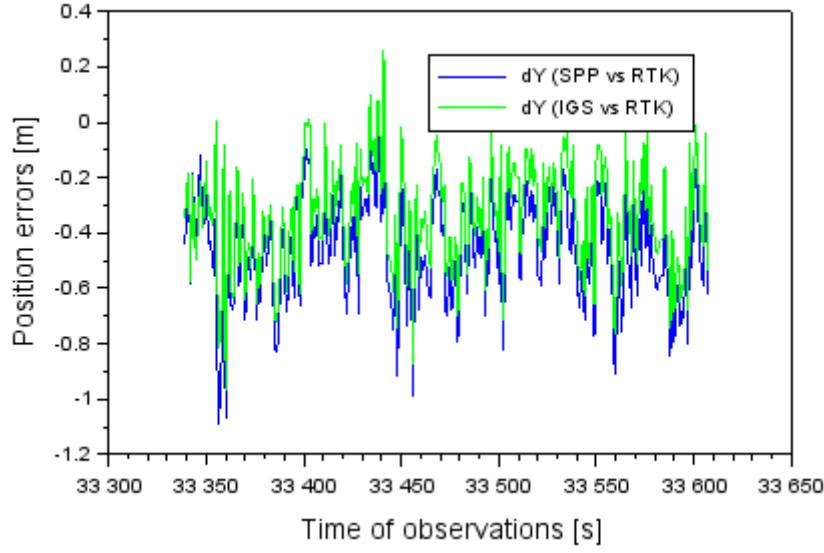


Fig. 4. The position errors for Y coordinate

Figure 4 presents the results of position errors for Y coordinate based on equation (4). The values of position errors along the Y axis for the comparison of the coordinates from equation (1) and the RTK-OTF technique range from -1.1 m to +0.2 m, with the average value of -0.5 m. On the other hand, position errors for equation (2) for the comparison of the coordinates from equation (2) and the RTK-OTF technique ranged from -1.0 m to +0.3 m, with the average value of -0.3 m. The comparison allows us to state that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the position of the UAV along the Y axis by 40% in comparison to the classical SPP solution for equation (1).

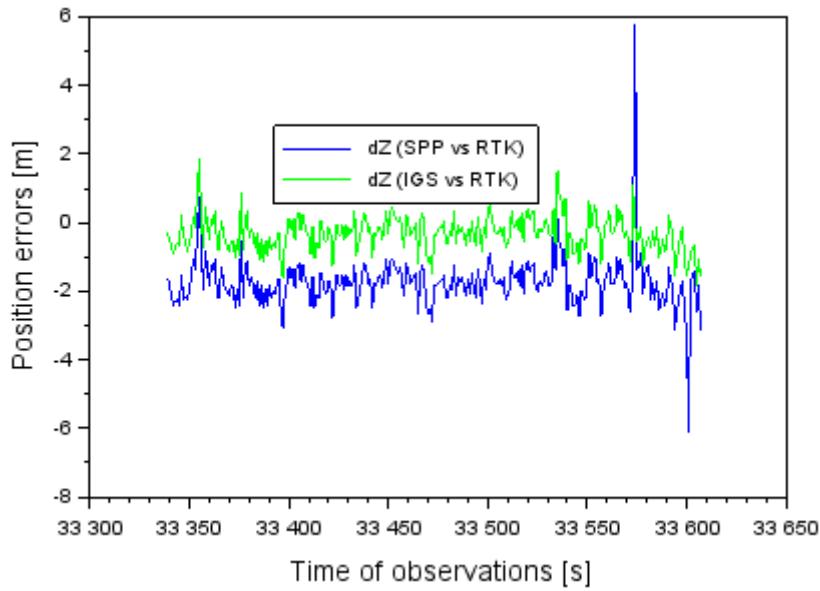


Fig. 5. The position errors for Z coordinate

Figure 5 presents the results of position errors for Z coordinate based on equation (5). The values of position errors along the Z axis for the comparison of the coordinates from equation (1) and the RTK-OTF technique is between -6.1 m to +5.8 m, with the average value of -1.7 m. On the other hand, position errors for equation (2) for the comparison of the coordinates from equation (2) and the RTK-OTF technique ranged from -1.8 m to +1.8 m, with the average value of -0.3 m. The comparison allows us to state that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the position of the UAV along the Z axis by over 80% in comparison to the classical SPP solution for equation (1).

As far as collecting data about aviation obstacles by UAVs is concerned, a particularly important element is the designation of the resultant accuracy of the platform in 3D space. Then it is necessary to use it as the basis for calculating the accuracy of UAV position in 3D space, as presented below:

$$dS = \sqrt{\frac{dX_{SPP}^2 + dY_{SPP}^2 + dZ_{SPP}^2}{dX_{RTK}^2 + dY_{RTK}^2 + dZ_{RTK}^2}} \quad (6)$$

where:

dS – the resultant accuracy of the designation of the position of the UAV.

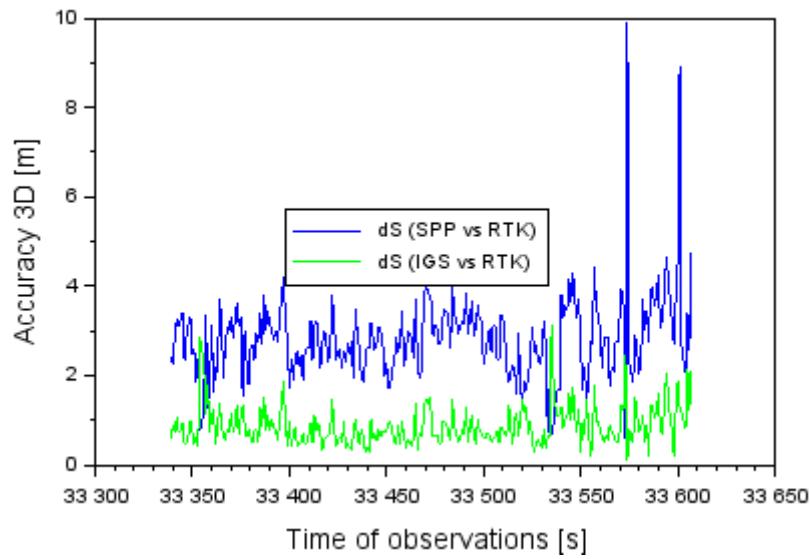


Fig. 6. The resultant accuracy of UAV in 3D space

Figure 6 shows the results of the determination of parameter dS for the position of UAV. Here, for the comparison of the coordinates from equation (1) and the RTK-OTF technique, the values of the dS factor range from 0.6 m to 9.9 m, with the average value of 2.8 m. On the other hand, for the comparison of the coordinates from equation (1) and the RTK-OTF technique, the values of the dS factor are between 0.1 m to 3.2 m, with the average value of 0.9 m. The comparison of the obtained results of the dS parameter allows us to claim that the application of the IGS products in the SPP method enabled to reduce the dS parameter by approx. 67% in comparison to the classic SPP navigation solution.

3.2.2. Block adjustment accuracy analysis

The image data obtained during the flight were processed in the UASMaster software. The block of images obtained at a low altitude was adjusted based on the adjustment algorithm using the independent bundle method. Then, the exterior orientation of the images was defined and approximate elements of exterior orientation were introduced for each image. The linking points were generated automatically using a digital image correlation strategy based on the least squares method. The block was adjusted without measuring the control points, for two variants of the UAV positioning method. The first variant was based on UAV positioning with use of the single point positioning method, while the second one was based on UAV positioning with use of the code-based SPP method modified to include the EPH format, CLK format, IONEX format, DCB format, and the ANTEX format. For the purposes of accuracy analysis, the results obtained from the block adjustment were then compared to the results of block adjustment using GCPs. To do so, additionally, measurements of 14 signalled ground control points were conducted in the test area with use of the RTK method in the GPS system. The accuracy of determination of the coordinates of ground control points (X , Y , Z) was 0.03 m.

After the block adjustment in the first variant of UAV positioning, the errors were calculated for the linear and angular elements of exterior orientation. The accuracy of determining the coordinates of the centres of projections X_0 , Y_0 , Z_0 amounted to 3.16 m to 7.22 m. The angular elements of exterior orientation ω , φ , κ were determined with an accuracy of 0.211° to 0.256°. For the second variant of UAV positioning, the accuracy of the liner elements X_0 , Y_0 , Z_0 ranged from 1.98 m to 3.22 m, while the accuracy of the angular elements ω , φ , κ ranged from 0.172° to 0.215°. As a result of block adjustment with use of ground control points, the following accuracy values were obtained: for linear elements X_0 , Y_0 , Z_0 from 0.13 m to 0.17 m, and for angular elements ω , φ , κ from 0.061° to 0.078°. The results of block adjustment for specific variants are presented in the table below (Tab. 2).

Tab. 2
Summary of blocks adjustment

Description	Variant 1: without GCPs (SPP positioning)	Variant 2: without GCPs (SPP positioning + IGS)	With GCPs
MX_0 [m]	3.16	2.31	0.14
MY_0 [m]	4.08	3.22	0.13
MZ_0 [m]	7.22	1.98	0.17
$M\omega$ [°]	0.243	0.215	0.061
$M\varphi$ [°]	0.211	0.172	0.068
$M\kappa$ [°]	0.256	0.194	0.078

Based on the obtained results, it was found that the application of the classical SPP method extended to include IGS products led to an improved accuracy of the adjustment of a block of photographs. The accuracy of the determination of the linear elements of exterior orientation increased, on average, by 58%, while the accuracy of the angular elements increased, on average, by 18%. The proposed modification of the absolute positioning algorithm SPP by adding IGS products allowed us to obtain the accuracy results of block adjustment that were very similar to those obtained when the block was adjusted based on the measured ground control points.

4. DISCUSSION

Due to the fact that there are two important aspects of the conducted accuracy analysis, this section has been divided into two subsections. In the first part, the accuracy results of the proposed method of positioning UAV are analysed. Part two discusses the results from the adjustment of a block of images after applying the suggested positioning method.

4.1. UAV positioning

This part of the discussion addresses three topics: 1) the reproducibility of the proposed research method, 2) the comparison of the obtained test results with the SPP solution with EGNOS corrections, and 3) the comparison of the obtained results to the knowledge state analysis.

As far as the reproducibility of the proposed research method is concerned, the results of the accuracy of positioning of UAV from another test flight, from the period from 11:22:15 (40935 s) to 12:06:03 (43563 s) according to GPS Time (GPST) were presented. This flight also took place in Radom, on the same measurement day. Figures 7-9 present the results of the accuracy of the UAV position determination along the XYZ axes of coordinates. Figure 7 shows that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the coordinates of the UAV along the X axis by 96% in comparison to the classical SPP navigation solution. Furthermore, Figure 8 shows that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the position of the UAV along the Y axis by 31% in comparison to the classical SPP navigation solution. Finally, Figure 9 confirms that the application of the IGS products in the SPP method resulted in improving the accuracy of determining the position of the UAV along the Z axis by 86% in comparison to the classical SPP navigation solution. The obtained experimental results demonstrated that it is justified to include IGS products in the code-based SPP method. Moreover, the comparison of the test results presented in Fig. 3-5 and Fig. 7-9 reveals the repeatability of the calculation process in form of the reduction in position errors when IGS products were used in the navigation solution for the positioning of the UAV.

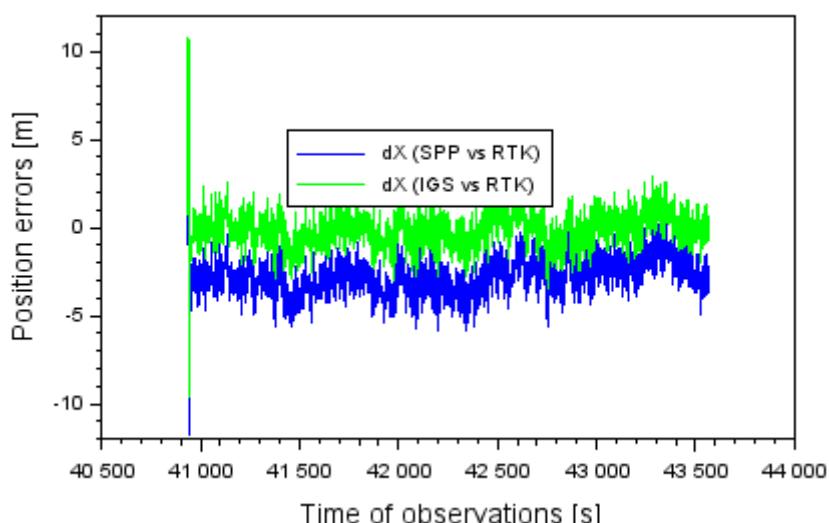


Fig. 7. The position errors for X coordinate in the 2nd test flight

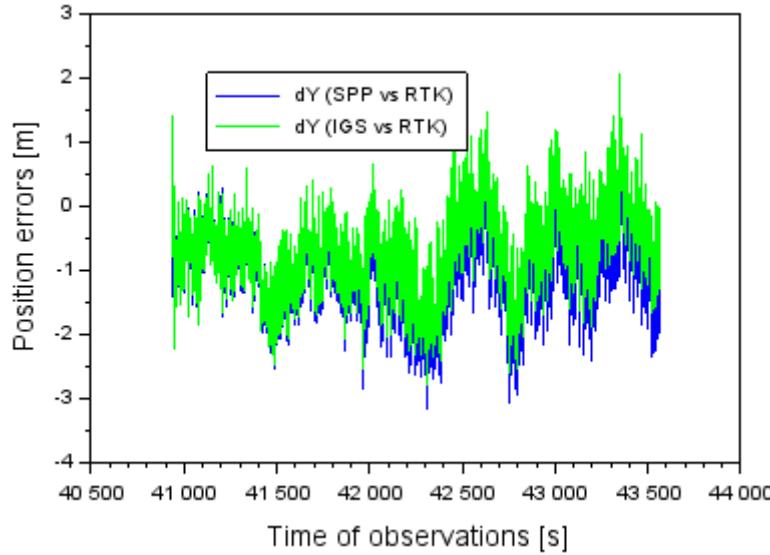


Fig. 8. The position errors for Y coordinate in the 2nd test flight

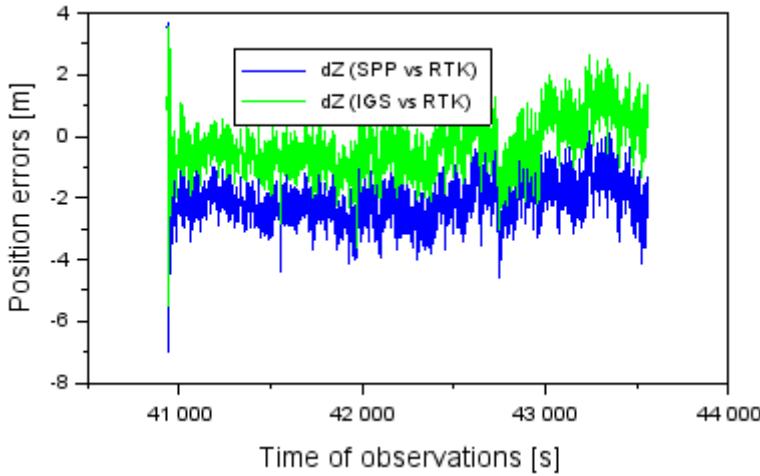


Fig. 9. The position errors for Z coordinate in the 2nd test flight

Additionally, Figure 10 shows the results of the dS parameter for test flight 2 with use of the UAV platform. Similarly, as in Figure 6, the accuracy of the positioning of UAV also improved by approx. 60% after the application of IGS products.

The second part of the discussion compares the obtained test results with another research method by comparing the results from the SPP solution with use of the IGS products to the SPP solution with EGNOS corrections [8]. The results of this comparison are presented in Figure 11. For the purposes of comparison, the accuracy results of dS term in 3D space from test flight 2 were also compared. The results for the dS term for the SPP solution with IGS products were also presented above, in Figure 10. They were, respectively, from 0.1 m to 11.2 m, while the results of the dS term from the SPP solution with EGNOS correction ranged from 0.1 m to 15.2 m. Thus, the application of IGS products enabled to improve the accuracy of UAV positioning by approximately 3÷4% in comparison to the application of EGNOS corrections.

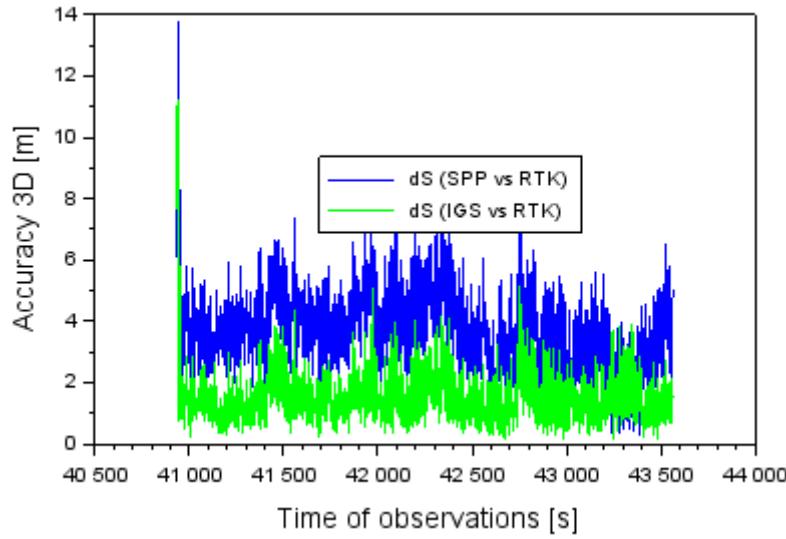


Fig. 10. The resultant accuracy of UAV in 3D space in the 2nd test flight

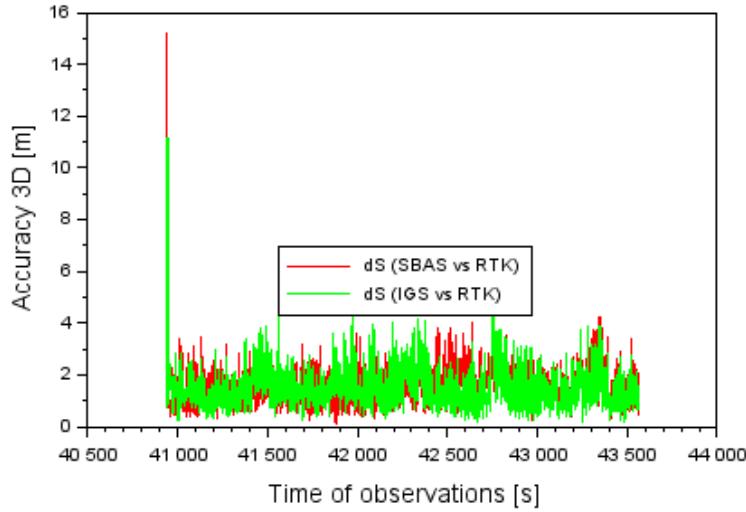


Fig. 11. Comparison of resultant accuracy dS using IGS products and EGNOS corrections in 2nd test flight

The last element of this part of the discussion is the comparison of the obtained results to the knowledge state analysis. The results of the research experiment presented in the work by Himanshu Sharma et al. [34] showed an improvement in the accuracy of the positioning of an UAV with the use of the SPP method extended by adding the Kalman filter. The obtained results demonstrated that the accuracy of UAV positioning improved by several tens of centimetres in comparison to the classical SPP method. The study by Angrisano et al. [3] presented an improvement in the accuracy of the absolute method of UAV positioning by applying a positioning algorithm that was based on the weighted average model. As a result, although the tests were conducted in an urban area that is difficult to measure, horizontal accuracy below 10 m was achieved. The attempts at improving the accuracy of positioning with use of the SPP method that were discussed in previous publications demonstrated that it is possible and realistic to obtain satisfactory results. However, the methodology of enhancing the accuracy of

determining the position of UAV proposed here, which consists in modifying the algorithm of the SPP method by including products of the IGS geodesic services, shows an improvement in the accuracy by as much as 95% along the X axis, by 40% along the Y axis, and by 80% along the Z axis.

4.2. UAV block adjustment

Evaluation of the effectiveness of the proposed method for increasing the accuracy of UAV position determination was carried out on the basis of a research experiment of adjustment of a block of images in two variants of the positioning method. The application of the classical navigation solution for the code-based SPP method with use of GPS navigation data allowed us to obtain the following accuracy values of the exterior orientation elements: from 3.16 m to 7.22 m for linear elements and from 0.211° to 0.256° for angular elements. The determination of the UAV coordinates with use of the algorithm of the SPP method modified by adding the products of IGS geodesic services resulted in improving the accuracy of the adjustment of the block of images by 58%, on average, for linear exterior orientation elements, and by 18%, on average, for the angular elements. The reliability of the results of the conducted accuracy analysis was compared to the accuracy of adjustment of the block of images where ground control points were used for the internal orientation of the model. The methodology presented in this paper to increase the accuracy of UAV positioning allowed to achieve block adjustment accuracy without the use of photogrammetric matrix points at a level higher than 3.22 m. Previous publications on the determination of the position of unmanned aerial vehicles for single-frequency GPS receivers usually pointed to the necessity to establish and measure a photogrammetric grid in the test area in order to improve the accuracy of the generated photogrammetric points [25, 16, 12]. Particular attention was paid to the influence of the number and distribution of ground control points in the whole test area [26, 19, 35, 33, 1]. As the research results are often quite ambiguous about this issue, the topic of the accuracy of UAV positioning and the accuracy of the generated photogrammetric products continues to evolve. In his studies, Shahbazi et al. [33] presented the possibility to obtain a high level of accuracy of the adjustment of the block obtained from a UAV equipped with a GPS receiver. Moreover, the RTK system that is also currently used is integrated with unmanned aerial vehicle and may contribute to reducing the number of GCPs or eliminating them completely, allows achieving an accuracy of UAV positioning on the level of only several centimetres.

5. CONCLUSION

This paper shows the results of the experiments and analyses concerning the determination of the position of an UAV. The main objective of the research was to develop a methodology to improve the accuracy of UAV positioning based on modifying the algorithm of the SPP method by adding products of the IGS geodesic services. The second objective was to improve the accuracy of photogrammetric products for aviation obstacles data collection without the need to conduct measurements of ground control points. The tests were conducted with the use of two methods. The first of them presented a classic navigation solution for the code-based SPP method with use of GPS navigation data. The second method employed the algorithm of the SPP method that was modified to include IGS products (i.e. precision ephemeris, precision clock, the IONEX format, the DCB format, and the ANTEX format). The conducted analyses revealed that the use of the modification of the absolute positioning SPP method by adding IGS

products allowed to improve the accuracy of determining the position of an UAV in order to obtain data about aviation obstacles by 95% along the X axis, by 40% along the Y axis, and by 80% along the Z axis.

The designation of the position of an UAV with use of the algorithm of the SPP method modified by adding the products of IGS geodesic services resulted in improving the accuracy of the adjustment of the block of images by 58%, on average, for linear exterior orientation elements, and by 18%, on average, for the angular elements. Applying the modification of the Single Point Positioning method by adding IGS products will enable to obtain the accuracy of collecting data about aviation obstacles that is required by the European standards [14] – for the X, Y coordinates on the level of 5 m, and for the Z coordinate on the level up to 3 m.

Acknowledgments

We are very grateful to Creotech Instruments S.A. for access to the UAV data.

References

1. Agüera-Vega Francisco, Fernando Carvajal-Ramírez, Patricio Martínez-Carricundo. 2017. „Assessment of photogrammetric mapping accuracy based on variation ground control points number using unmanned aerial vehicle”. *Measurement* 98: 221-227. DOI: <https://doi.org/10.1016/j.measurement.2016.12.002>.
2. Almawas Mohammad, Azmi Mastura. 2022. „A review on use of GIS technology for mapping and modelling urban floods”. *Journal of Hunan University (Natural Sciences)* 49(02).
3. Angrisano Antonio, Silvio Del Pizzo, Salvatore Gaglione, Salvatore Troisi, Mario Vultaggio, 2018. „Using local redundancy to improve GNSS absolute positioning in harsh scenario”. *Acta Imeko* 7(2): 16-23. DOI: https://doi.org/10.21014/acta_imeko.v7i2.538.
4. Arévalo-Verjel Alba Nely, José Luis Lerma, Juan F. Prieto, José Fernández. 2022. „Estimation of the Block Adjustment Error in UAV Photogrammetric Flights in Flat Areas”. *Remote Sensing* 14: 2877. DOI: <https://doi.org/10.3390/rs14122877>.
5. Ashraf Shahrukh, Priyanka Aggarwal, Praveen Damacharla, Hong Wang, Ahmad Y. Javaid, Vijay Devabhaktuni. 2018. „A low-cost solution for unmanned aerial vehicle navigation in a global positioning system-denied environment”. *International Journal of Distributed Sensor Networks* 14(6): 1-17. DOI: <https://doi.org/10.1177/1550147718781750>.
6. Butowitt Jerzy, Rómuuald Kaczyński. 2010. *Fotogrametria*. Warsaw: Military University of Technology. [In Polish: *Photogrammetry*]. ISBN: 9788361486398.
7. Chiang Kai-Wei, Meng-Lun Tsai, Chien-Hsun Chu. 2012. „The development of an UAV borne direct georeferenced photogrammetric platform for ground control point free applications”. *Sensors* 12(7): 9161-9180. DOI: <https://doi.org/10.3390/s120709161>.
8. Ciećko Adam, Mieczysław Bakuła, Grzegorze Grunwald, Janusz Ćwiklak. 2020. „Examination of Multi-Receiver GPS/EGNOS Positioning with Kalman Filtering and Validation Based on CORS Stations”. *Sensors* 20(9): 2732. DOI: <https://doi.org/10.3390/s20092732>.
9. Colpaert Alfred. 2022. „Satellite and UAV Platforms”. *Remote Sensing for Geographic Information Systems, Sensors* 22: 4564. DOI: <https://doi.org/10.3390/s22124564>.

10. Congress Surya Sarat Chandra, Anand J Puppala, Clayton Treybig, Charles F Gurganus, Jim Halley. 2022. „Application of Unmanned Aerial Vehicles for Monitoring Airport Asset Surfaces”. *Transportation Research Record*: 03611981221115729. DOI: <https://doi.org/10.1177/03611981221115729>
11. Daakir Mehdi, Marc Pierrot-Deseilligny, Pierre Bosser, Francis Pichard, Christian Thom, Yohann Rabot, Olivier Martin. 2017. „Lightweight UAV with on-board photogrammetry and single-frequency GPS positioning for metrology applications”. *ISPRS J. Photogramm. Remote Sens.* 127: 115-126. DOI: <https://doi.org/10.1016/j.isprsjprs.2016.12.007>
12. DeWitt Bon, Paul Wolf. 2000. *Elements of Photogrammetry (with Applications in GIS)*. 3rd ed. New York, USA: McGraw-Hill Higher Education. ISBN: 0-07-292454-3.
13. Eling Christian, Markus Wieland, Christophe Hess, Lasse Klingbeil, Heiner Kuhlmann, 2015. „Development and evaluation of a UAV based mapping system for remote sensing and surveying applications”. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* XL-1/W4: 233-239. DOI: <https://doi.org/10.5194/isprsarchives-XL-1-W4-233-2015>.
14. Eurocontrol. 2021. *Terrain and Obstacle Data Manual*. 3rd ed. Eurocontrol: Brussels, Belgium.
15. Forlani Gianfranco, Fabrizio Diotri, Umberto Morra Di Celli, Riccardo Roncella. 2020. „UAV block georeferencing and control by on-board gnss data”. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 43: 9-16. DOI: <https://doi.org/10.5194/isprs-archives-XLIII-B2-2020-9-2020>.
16. Fryer John, Harvey Mitchell, Jim Chandler. 2007. *Applications of 3D measurement from images*. Dunbeath, UK: Whittles. ISBN: 978-1-904445-63-0.
17. Gao Y., 2008. „GNSS biases, their effect and calibration”. In *IGS Workshop*: 24. Natoional Geographic Survey. 2-6 June, Miami Beach, USA.
18. Ge Yulong, Feng Zhou, Baoqi Sun, Shengli Wang, Bo Shi. 2017. „The Impact of Satellite Time Group Delay and Inter-Frequency Differential Code Bias Corrections on Multi-GNSS Combined Positioning”. *Sensors* 17(3): 602. DOI: <https://doi.org/10.3390/s17030602>.
19. Harwin Steve, Arco Lucieer. 2012. „Assessing the accuracy of georeferenced point clouds produced via multi-view stereopsis from Unmanned Aerial Vehicle (UAV) imagery”. *Remote Sens.* 4: 1573-1599. DOI: <https://doi.org/10.3390/rs4061573>.
20. Hosseinpoor Ahmad Reza, Farhad Samadzadegan, F. Dadras Javan. 2016. „Pricise target geolocation and tracking based on UAV video imagery”. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences* XLI-B6: 243-249. DOI: <https://doi.org/10.5194/isprs-archives-XLI-B6-243-2016>.
21. IGS. „Products”. Available at: <https://igs.org/products/#about>.
22. Kaniewski Piotr. 2006. „Aircraft Positioning with INS/GNSS Integrated System”. *Molecular and Quantum Acoustics* 27: 149-168. ISSN: 1731-8505.
23. Kaniewski Piotr, Rafal Gil, Stanisław Konatowski, 2016. „Algorithms of position and velocity estimation in GPS receivers”. *Annual of Navigation* 23: 53-68. DOI: <https://doi.org/10.1515/aon-2016-0004>.
24. Le Anh Quan, Christian Tiberius. 2007 „Single-frequency precise point positioning with optimal filtering”. *GPS Solutions* 11(1): 61-69. DOI: <https://doi.org/10.1007/s10291-006-0033-9>.
25. Luhmann Thomas, Stuart Robson, 2011. *Close Range Photogrammetry: Principles, Methods and Applications*. Cdr ed. Dunbeath, UK: Whittles. ISBN: 978-1-84995-057-2.

26. Mancini Francesco, Marco Dubbini, Mario Gattelli, Francesco Stecchi, Stefano Fabbri, Giovanni Gabbianelli. 2013. „Using Unmanned Aerial Vehicles (UAV) for High-Resolution Reconstruction of Topography: The Structure from Motion Approach on Coastal Environments”. *Remote Sens.* 5: 6880-6898.
DOI: <https://doi.org/10.3390/rs5126880>.
27. RTKLIB: An Open Source Program. „RTKLIB ver. 2.4.2 Manual, Package for GNSS Positioning”. Available at: http://www.rtklib.com/prog/manual_2.4.2.pdf.
28. RTKLIB Website. „RTKLIB: An Open Source Program Package for GNSS Positioning”. Available at: <http://rtklib.com/>.
29. Santerre Rock, Lin Pan, Changsheng Cai, Jianjun Zhu. 2014. „Single Point Positioning Using GPS, GLONASS and BeiDou Satellites”. *Positioning* 5: 107-114.
DOI: <https://doi.org/10.4236/pos.2014.54013>.
30. Sanz-Ablanedo Enoc, Jim H. Chandler, José Ramón Rodríguez-Pérez, Celestino Ordóñez. 2018. „Accuracy of unmanned aerial vehicle (UAV) and SfM photogrammetry survey as a function of the number and location of ground control points used”. *Remote Sensing* 10(10):1606. DOI: <https://doi.org/10.3390/rs10101606>.
31. Schaer S., 1999. „Mapping and predicting the Earth’s ionosphere using Global Positioning System”. *PhD thesis*. Berne: University of Berne.
32. Scilab Website. Available at: <https://www.scilab.org/>.
33. Shahbazi Mozhdeh, Gunho Sohn, Jérôme Théau, Patrick Menard. 2015. „Development and evaluation of a UAV-photogrammetry system for precise 3D environmental modeling”. *Sensors* 15: 27493-27524. DOI: <https://doi.org/10.3390/s151127493>.
34. Sharma Himanshu, Andreas Schütz, Thomas Pany. 2018. „Preliminary analysis of the RTK positioning using Android GNSS Raw Measurements and Application Feasibility for the Trajectory mapping using UAV’s”. In: *The 31st International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2018)*: 432-444. The Institute of Navigation, Manassas. 24-28 September 2018, Miami, Florida, USA. ISBN: 0-936406-10-0.
35. Tahar Khairul Nizam. 2013. „An evaluation on different number of ground control points in unmanned aerial vehicle photogrammetric block”. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* 40: 93-98. DOI: <https://doi.org/10.5194/isprsarchives-XL-2-W2-93-2013>.
36. Tahar Khairul Nizam, Suryani Kamarudin. 2016. „UAV onboard GPS in positioning determination”. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences* 41: 1037-1042. DOI: <https://doi.org/10.5194/isprs-archives-XLI-B1-1037-2016>.
37. Taro, S., Y. Takahashi, Y. Amano. 2016. „Precise UAV Position and Attitude Estimation by Multiple GNSS Receivers for 3D Mapping”. In: *The 29th International Technical Meeting of the Satellite Division of The Institute of Navigation (ION GNSS+ 2016)*: 1455-1464. The Institute of Navigation, Manassas. 12-16 September, Portland, Oregon. ISBN: 0-936406-12-7
38. Ueno M., T. Nimura, T. Fujiwara, K. Nonaka. 1997. „Evaluation of RTK-OTF positioning system for free running manoeuvrability test of a model ship”. In: *Oceans '97. MTS/IEEE Conference Proceedings* 2: 1120-1125.
DOI: 10.1109/OCEANS.1997.624149.
39. Wang Shizhuang, Xingqun Zhan, Yawei Zhai, Cheng Chi, Jiawen Shen. 2021. „Highly reliable relative navigation for multi-UAV formation flight in urban environments”. *Chin. J. Aeronaut.* 34(7): 257-270. DOI: <https://doi.org/10.1016/j.cja.2020.05.022>.

40. Wierzbicki Damian, Michał Kędzierski, Anna Sekrecka. 2019. „A Method for Dehazing Images Obtained from Low Altitudes during High-Pressure Fronts”. *Remote Sensing* 12(1): 25. DOI: <https://doi.org/10.3390/rs12010025>.

Received 15.12.2022; accepted in revised form 02.03.2023



Scientific Journal of Silesian University of Technology. Series Transport is licensed under
a Creative Commons Attribution 4.0 International License

Załącznik 3 – [Publikacja 3]

Methodology of Detection and Classification of Selected Aviation Obstacles Based on UAV Dense Image Matching

Marta Lalak  and Damian Wierzbicki 

Abstract—Currently, more and more accurate data provided by UAVs make it possible to analyze land cover, which requires the detection of objects and their individual elements. Object detection and determination of their geometric features is possible thanks to dense point clouds generated based on imagery obtained from low altitudes. 3D data from UAVs turn out to be extremely useful for ensuring safety in the airspace in the close vicinity of the airport. This article presents the methodology of automatic aviation obstacle detection based on low altitude data (UAV). The research was carried out on a dense 3D point cloud. The developed methodology for detecting aviation obstacles consists of three main stages. The first is point cloud filtration based on height—preliminary identification of aviation obstacles, followed by 3D point cloud segmentation using a modified RANSAC algorithm, supplemented with two-dimensional vector data of aviation obstacles to improve the accuracy of the segmentation process. The last stage is the classification of aviation obstacles according to the adopted height and cross-section criterion. The proposed method of detecting aviation obstacles is characterized by high accuracy. The mean error of fitting the point cloud to the obstacle database ranged from ± 0.04 m to ± 0.07 m.

Index Terms—Accuracy, air traffic control, image processing, remote sensing, unmanned aerial vehicles (UAVs).

I. INTRODUCTION

OVER the past decade, the cost of using unmanned aerial vehicles (UAVs) in photogrammetric and remote sensing applications has been increasingly low. UAVs are a cheap and effective alternative to obtaining data with the methods of classical aerial photogrammetry. Until recently, airborne laser scanning dominated the acquisition of spatial data. However, for several years there has been increasing use of UAVs to analyze 3-D objects using point clouds [1]. Thanks to easy and universal data acquisition and processing, the low-altitude technology is gaining an advantage over the previously used aerial photogrammetry.

Manuscript received October 17, 2021; revised January 8, 2022; accepted January 30, 2022. Date of publication February 7, 2022; date of current version February 24, 2022. This work was supported by the Military University of Technology in Warsaw and co-funded by the Military University of Aviation in Dęblin, Poland. (*Corresponding author: Damian Wierzbicki*.)

Marta Lalak is with the Institute of Navigation, Polish Air Force University, 08-521 Dęblin, Poland (e-mail: m.lalak@law.mil.pl).

Damian Wierzbicki is with the Department of Imagery Intelligence, Faculty of Civil Engineering and Geodesy, Military University of Technology, 00-908 Warsaw, Poland (e-mail: damian.wierzbicki@wat.edu.pl).

Digital Object Identifier 10.1109/JSTARS.2022.3149105

Automatic detection and recognition of individual objects and distinguishing their elements is critical for many applications, including damage assessment and all research related to these objects. One of such applications may also be the retrieval of information about aviation obstacles. Aviation obstacles with their location and dimensions, especially height, may endanger aircraft. First of all, it is essential during the aircraft's take-off and landing maneuvers. An unidentified obstacle may turn out to be a significant threat during critical phases of flight. As the detection of aviation obstacles is extremely important for the safety of aircraft in the airspace, The International Civil Aviation Organization (ICAO) introduced a series of planes to limit obstacles in order to ensure the safety of aircraft [2]. Objects that penetrate these planes constitute aviation obstacles. According to the latest data on the causes of air accidents, aviation obstacles belong to the group of the highest risk factors that contribute to such accidents [3], [4].

Currently, aerial photogrammetry may be the most efficient technique of collecting data about obstacles. It is less automated than such other techniques as the airborne laser scanning (ALS), traditional ground measurements or synthetic aperture radar (SAR), in particular for elongate objects [5]. Low-cost UAVs that ensure high time resolution provide digital images that are then used to create dense clouds of points describing 3-D objects. However, the need emerges to develop process automation in order to overcome the challenge of detecting air obstacles in form of elongate objects. The detection of such objects is difficult and, in fact, they may be detected only from lower altitudes, which are offered by UAV [5].

Point cloud segmentation is the primary step in 3-D point cloud processing. Considering a set of point clouds, the segmentation process aims to aggregate points with similar characteristics into homogeneous regions. The segmentation process can be helpful in scene analysis in various aspects, such as locating and recognizing objects, classifying, and extracting features of these objects [6], [7]. In general, the analyzed objects and their elements have unique geometrical features. Therefore, 3-D geometric features are used as basic information in object detection and categorization of its subelements [8]. 3-D point clouds are optimal for determining the geometric properties of objects. So far, oblique aerial images have been a suitable source for generating 3-D point clouds for object analysis because they provided detailed information about individual object elements: roofs, elevations, etc. Currently, UAVs offer photos with very

high coverage and high resolution, generating very dense 3-D point clouds in a minimum time and with a minimal financial outlay [9]. Thus, low-level 3-D point clouds have become more and more widely used to study 3-D objects.

The point clouds used so far from ALS are accurate and give ready 3-D data. However, the main disadvantage of ALS point clouds is that they are expensive to obtain [10]. For buildings, ALS can only capture the roof and other parts of the building that are only visible from a bird's eye view, and those visible from ground level, such as areas under balconies and building walls that are obscured, are not acquired. Maltezos and Ioannidis [11] argue that the LIDAR point clouds give false results because they misinterpret buildings with smooth roofs.

ALS involves high costs of using specialist photogrammetric equipment during the flight. As the UAVs are equipped with RTK receivers (positioning with the accuracy of one decimeter), the time of data collection and acquisition is very short, e.g., 25 hours are required to obtain and process 1000 ha. The overall costs of collecting and obtaining data with use of UAV may be even several times lower than with use of ALS [68]–[70]. Apart from that, the point clouds obtained from ALS are characterized by lower accuracy than the dense cloud of points generated as a result of processing the image structure from motion (Pix4D, Metashape-type software) from UAV. Images from UAV that are used in the developed method of detecting aviation obstacles are a source of 3-D data that reach the quality standards similar or even higher than those provided by ALS.

Object detection in a 3-D point cloud, segmentation of points belonging to an object, reconstruction of geometry, and object topology are the essential components in the process of 3-D object modelling.

The following section presents a literature review on the classification and segmentation of 3-D objects using photos obtained from UAVs. Additionally, the latest related works on classification and segmentation are presented.

A. Aviation Obstacles

High artificial or natural vertical objects (obstacles) situated near the runway can contribute to accidents during the take-off and landing. The automation of the object detection process in the vicinity of the airport is thus becoming extremely important and necessary for ensuring security around the airport areas. Safe movement at airports and on arrival areas in take-off areas, landing and maneuvering, is an essential element of air traffic safety. Terrain and obstacle data are key geospatial components of aeronautical information. There are international ICAO regulatory documents [2] and national aviation regulations that specify the requirements for collecting and assessing terrain and obstacle data. According to the ICAO, boundary surfaces correspond to the maximum allowable heights of objects in the traffic areas of aircraft. Few studies are dealing with the problem of detecting aviation obstacles in the vicinity of airports. Mitsevich [12] presented remote and effective obstacle identification and assessment process technology using stereoscopic remote sensing. Demir and Baltsavias [13] focused on the accuracy,

resolution, and timeliness of data about objects in the vicinity of airports and the automation of 3-D model generation processes using airborne laser scanning. In another work by Demir *et al.* [14], the authors focused on detecting buildings in the airport environment by combining information from aerial imagery and LIDAR data. They used four different methods. The first was based on a DSM/DTM comparison combined with an NDVI analysis. The second was the supervised multispectral classification refined by the standardized DSM. The third approach used empty spaces in the Lidar DTM and NDVI classification (method 3), while the last method was based on the density analysis of Lidar DTM and DSM raw data. A study by Parrish and Nowak [15] presents the methodology of modelling objects using very dense, detailed point clouds, in which the vertical structures of objects are well characterized. The existing recommendations [5] concerning the detection of aviation obstacles focused on using point clouds from ALS. However, as one cannot exclude omitting elongate obstacles, object detection is verified with use of traditional ground measurements, which significantly increased the duration of the process. Additionally, ALS does not ensure high time resolution of data. In terms of ensuring safety in the air space, time resolution and accuracy of data on aviation obstacles are of key importance in performing aviation operations. Objects that are taller than the boundary surfaces, in certain conditions may cause the need to increase the relative or absolute altitude of flight above the obstacles for precision instruments landing approach or any other flight procedure. Such objects may also have an operational influence on designing flight procedures. There is no doubt that the accuracy of determining aviation obstacles affects the safety during the flight of an aircraft [12].

According to the latest provisions of the Eurocontrol manual [5] the detection of elongate aviation obstacles should be ensured at a much higher image scale than that obtained from traditional photogrammetric missions.

B. Segmentation

Segmentation [16] is one of the critical phases of point cloud processing. It aims to group the points into significant clusters with homogeneous properties [17]. Point cloud segmentation, the aggregation of 3-D points into many homogeneous groups with standard features [18], has been studied for decades. A majority of the authors have focused on designing and developing hand-made algorithms for point classification and [19]–[29]. However, finding the optimal segmentation method remains a challenge [30].

Conventional segmentation methods such as region growing [31] or clustering examine points in the vicinity of initial seeds or origins and check if they belong to the same group or not according to the given criteria. Euclidean distance [32], density [33], [34], vector normal deviation [35], [36], surface smoothness [37], and curvature [38] of points are representative criteria. Besides, segmentation may also be performed in the feature space. Distinctive geometric features or RGB information are also

introduced as segmentation criteria [39]. However, all these segmentation methods are easily affected by noise and outliers in the dataset, resulting in over- or undersegmentation with different granularities of the segments obtained. Besides, complex segmentation criteria will significantly increase the computational time. In addition, the gaps between the point clouds (mismatch of the points from the image matching for each pixel of the image) and different point densities make this a more problematic issue. Overall, point cloud segmentation can be considered a difficult topic.

The review of methods, algorithms and solutions that can be applied at individual modelling stages is provided in [40]. At the last stage of modelling, buildings are usually formed as a combination of planes in 3-D space. For this reason, the second stage of the modeling process is crucial, as this is when subsets of points describing (modeling) individual planes are extracted. This task is complicated by the presence of erroneous points in the set. At this stage, the most commonly used algorithms are RANSAC, rising planes, and the Hough transform, with possible modifications, with the first two of the methods mentioned above being dominant.

In their research, Nguyen and Le [41] presented segmentation methods divided into five categories: edge-based; region-based; attribute-based; chart-based; and model-based. In model-based methods, all points with the same mathematical characteristics are grouped into a single segment, such as a sphere, plane, and cylinder. Schnabel *et al.* [42] proposed a model-based algorithm for detecting basic shapes from disordered point clouds. Their algorithm is based on RANSAC. In their works, Bauer *et al.* [43] and Boulaassal [44] use the RANSAC algorithm to detect building facades. To optimize the operation of this estimator in the plane extraction process, it has undergone numerous modifications. Awwad *et al.* [45] and Delmerico *et al.* [46] propose to consider the direction of the normal vector calculated at each point of the cloud. Concerning the detection and modeling of aviation obstacles, the application of several algorithms was presented, which allow to isolate the shape of obstacles and to adjust the point cloud [52], [53]. Knowing the height and location of the obstacles is sufficient for the aircraft to avoid them. Several other methods of detecting aviation obstacles have also been presented in subject literature [54], [55].

The authors of this article will attempt to prove the following hypothesis: point cloud segmentation with the modified RANSAC algorithm through the use of vector data parameter, the introduction of a new point cloud classification algorithm, which is adapted to the geometric features of aviation obstacles, and the criterion of point cloud filtration obtained from low altitude will allow for the detection of aviation obstacles with an accuracy compliant with ICAO regulations [56]–[59].

The research aimed to develop a methodology for automatic detection of aviation obstacles being elongated objects and their classification based on dense matching of UAV images.

The rest of this article is organized as follows: in Section II, the test data are introduced. In Section III, the research method

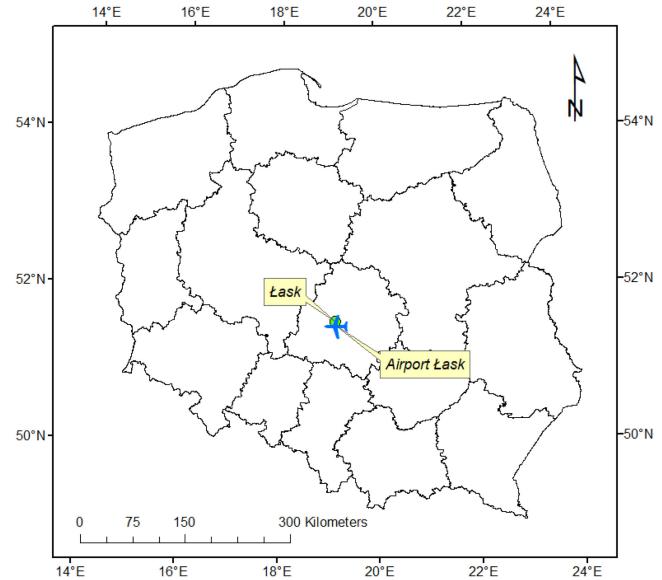


Fig. 1. Location of the Łask military airport.



Fig. 2. (a) Trimble UX-5 – before flight. (b) Example of GCP location.

is explained. Section IV presents experimental results. In Section V, the results are discussed. Finally, Section VI concludes this article.

II. MATERIALS

A. Study Area

The research was carried out on several selected experimental areas, which were located around the Łask military airport. It is an Air Force airport located in central Poland, south of the town of Łask ($51^{\circ}33'06''\text{N}$; $19^{\circ}10'45''\text{E}$) (see Fig. 1). The surface of the area covered with photos was approx. 25 km^2 .

B. Description of the Dataset

The source data for the dense point cloud generation was obtained using the Trimble UX-5 airframe [see Fig. 2(a)], equipped with a Sony a7R camera. The aerial platform was equipped with a single-frequency GPS receiver, recording data at a frequency of 10 Hz.

The flights were carried out in the test area in April 2019. The weather conditions were good, i.e., the sky was covered with a small number of cumulus clouds, and the average wind speed was about 2 m/s. Camera settings were defined in manual mode, while the focus of the lens was set to infinity. The test area covered the area around the Łask military airport. The measurement campaign consisted of 30 test blocks, where each block

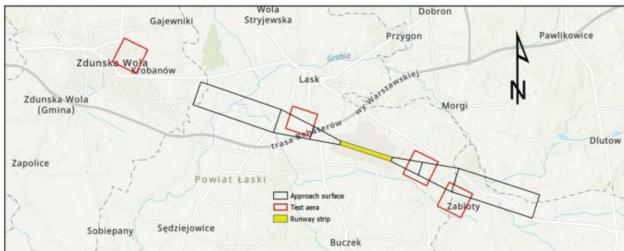


Fig. 3. Research areas.

TABLE I
CHARACTERISTICS OF THE TEST EXPERIMENTAL AREAS IN ŁASK

Experimental area number	1	2	3	4
Number of lines	18	17	16	17
Number of photos	608	576	565	580
Camera / lens focal length [mm]	Sony a7R / 36.34			
Average longitudinal/transverse coverage [%]	75/75			
Flight altitude [m]	300			
Number of control points	4	6	5	6
Number of independent checkpoints	5	8	5	7
Value of the standard deviation of a priori control points and checkpoints X, Y, Z [m]	0.03, 0.03, 0.03			
GSD [m]	0.04			

consisted of approximately 600 images on average. The data was obtained from about 250 m altitude above the ground. The flights were carried out in the east-west direction, assuming that the transverse and longitudinal coverage was 75%. In the study area, the marked control points were designed and measured [see Fig. 2(b)]. All points were measured using the RTK technique in the GNSS system. The terrain coordinates of the control points were determined with the mean error $m_{x,y,z} = \pm 0.03$ m.

C. Characteristics of the Experimental Area

Four experimental areas (1, 2, 3, and 4) were used for further research (see Fig. 3).

They were located close to the runway strip of the Łask airport. The 1st area consisted of 18 lines, 608 photos; the 2nd area included 17 ranks consisting of 576 photos. The 3rd area consisted of 16 lines with 565 photos, and, finally, the 4th area consisted of 17 lines with 580 photos (see Table I).

For the experimental areas, ground control points (which are used in the aerotriangulation process to determine elements of external orientation of images) were measured, as well as independent checkpoints to assess the accuracy of alignment of the block. All images are oriented to the Polish national coordinate system PL-2000 zone VI.

The military airport with the 32nd Tactical Air Base (BLT) is located in Łask (see Fig. 4). The recent modernization of the



Fig. 4. Diagram of the Łask airport based on [aip mil].

airport, i.e., extension of the runway and the modernization of the airport infrastructure, has made the 32nd BLT one of the most modern units of the Polish Air Force.

D. Experimental Areas

The research used data obtained from four flights (see Fig. 3). Each of the flights was carried out in the vicinity of the Łask military airport. The first criterion for selecting the research area was to fit into the area coinciding with one of the obstacle limiting surfaces, i.e., the approach surface. The second criterion was the presence of objects protruding above the ground surface, which may pose a potential threat to aircraft traffic. Due to the negligible number of obstacles in the vicinity of the Łask military airport, the research ignored the top-down dimensions and slopes of the approach surface in Poland [60]. That change allowed for the extension of the scope of the study, so that studies could be performed for a larger number of data. Additionally, the developed methodology was universal and possible to use under various constraints and limitations.

1) *First Experimental Area:* The first area was located very close to the runway of the Łask military airport. Four control points and five independent checkpoints were identified in the study area. Small, heterogeneous buildings characterized the studied area.

2) *Second Test Area:* The second area was approximately 20 km from the runway. In the study area, six control points and eight independent checkpoints were measured. Most of the area was covered with high, compact buildings.

3) *Third Experimental Area:* The third area was located approximately 3 km from the runway strip. In the three study area, five control points and five independent checkpoints were determined. The research area was distinguished by small buildings and the presence of numerous power lines.

4) *Fourth Experimental area:* The fourth area was approximately 10 km from the runway strip. Six control points and seven independent checkpoints were identified in the study area. The site is characterized by scattered development.

E. Obstruction Identification Surfaces

The airspace around the airport should be clear of all aviation obstacles to enable the safe conduct of flight operations and to prevent the airport from being unusable due to obstacles forming in its vicinity. This objective is achieved by establishing

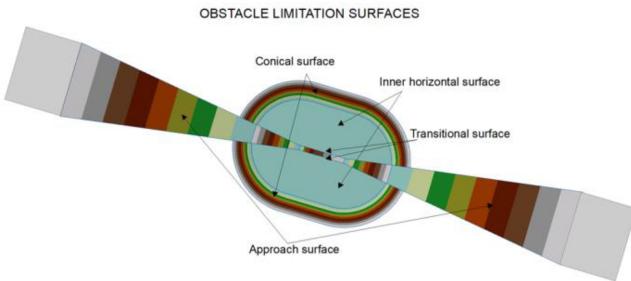


Fig. 5. Obstacle limitation surfaces based on [56].

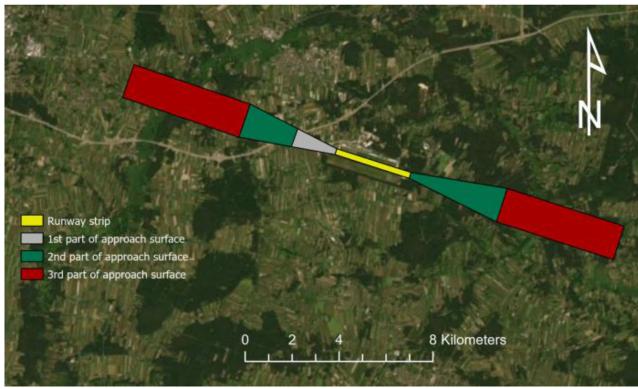


Fig. 6. Obstruction identification surfaces for the Łask military airport based on [56].

a series of obstacle limitation surfaces that define the limits to which objects in the air can protrude. Objects that exceed the obstacle limitation surfaces under certain conditions may require an increase in the altitude or obstacle crossing altitude for instrument approach procedures or any other circular visual flight procedure. These objects may also have an operational impact on the design of flight procedures.

Obstacle limitation surfaces at aerodromes for airplanes shall be established considering the number and location of runways at the airfield, airfield reference code digits, landing approach category, and visual aids for navigation. The dimensions and slopes of the obstacle limiting surfaces for the runways for the Łask military airport have been determined based on Annex 3 to the Aviation Obstacle Ordinance [60], obstacle limiting surfaces and devices of a hazardous nature. Obstacle limiting surfaces include but are not limited to a conical surface, an inner horizontal surface, a transitional surface, and an approach surface (see Fig. 5).

An approach surface is an inclined plane or pattern of planes located at a specified distance from the runway strip. The approach area for the Łask military airport consists of three planes (see Fig. 6). The first (1) plane is 3000 m long and rises by 2%, the second (2) plane is 3600 m long and rises by 2.5%, and the third (3) plane is 8400 m long and horizontal. The approach surface boundary determines the height which objects in the airspace in the vicinity of the airport can reach.

TABLE II
TYPE OF AVIATION OBSTACLE

Type of aviation obstacle	
Mast, antenna	
Wind turbine	
Building, skyscraper	
Chimney	
Tower	
Energy pole	

F. Characteristic of Aviation Obstacles

Aviation obstacles are all fixed (permanent or temporary) or movable objects or their elements that:

- 1) are located in the zone designated for the movement of air vessels on the ground; or
- 2) exceed a specific surface designated to protect the air vessel during the flight; or
- 3) remain outside those defined surfaces, but have been classified as threats for air traffic [5], [57].

Data about aviation obstacles are necessary for the design of landing approach procedures, the creation of aeronautical charts and base databases, and the analysis of aircraft operating limitations. The collected data may also determine the height restrictions or the removal of obstructions that pose a risk to air navigation [57]. The following types of elongated aviation obstacles are listed in the register of aviation obstacles or marked on aerial charts: masts and antennas; wind farms (i.e., wind turbines); buildings, blocks and skyscrapers; chimneys; towers; energy poles (see Table II) [5]. The aviation obstacles listed above represent man-made objects.

III. METHODS

This section introduces and describes a mathematical model that can be used to automatically detect aviation obstacles and classify them based on a random point cloud obtained from a low altitude. The entire process is shown using a flowchart (see Fig. 7). The diagram shows the stages of detection of objects in the vicinity of the airport, assuming that objects above a certain height are considered obstacles to the air. The first stage consisted in acquiring photos from a low level. Then, using the Pix4D software, the images were processed, and point clouds were generated for the various research areas. The works started with the automatic filtration of the point cloud, where the height of aviation obstacles above the approach surface was adopted as the filtration criterion. Then, point cloud segmentation was performed to determine obstacles to aviation. This process started with the implementation of vector data about 2-D objects on the basis of an orthophotomap. The attributes of 2-D objects were directly loaded into segmented point clouds. The use of

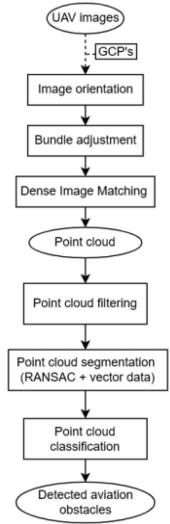


Fig. 7. Scheme of detection of the aviation obstacles.

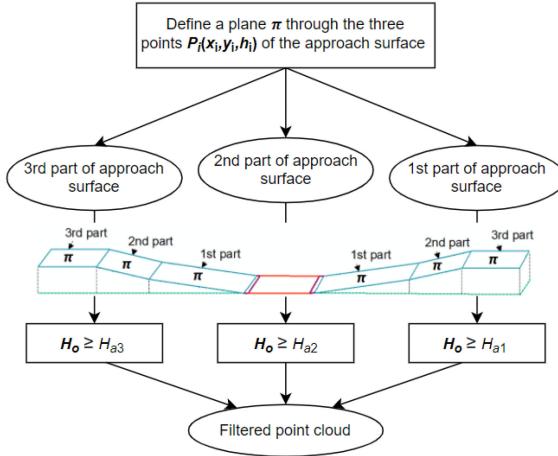


Fig. 8. Scheme of filtering of point clouds.

the geometry of the examined objects made it possible to fit the point cloud into the obstacle database precisely and save the attributes from the 2-D layer to the structure of each segmented point cloud. The final stage was the automatic classification of the point cloud based on the ratio of the object height to its width and geometric relationships of the cross-section of the objects. This classification made it possible to determine the type of obstacle, where GCP's is ground control points.

A. Aviation Obstacle Detection

This section describes the raw point cloud filtering to identify points that may be part of aviation obstacles. The point cloud filtration was carried out in the vicinity of the airport for the area contained in the obstacle limiting surface, called the approach surface. The primary purpose of point filtration was to detect points on or above the approach surface automatically. At this stage, filtered point cloud applied only to the filtration of point clouds by their height, according to the set criterion H_o (see Fig. 8). The use of the altitude criterion made it possible to detect points that may belong to aviation obstacles (see Fig. 8).

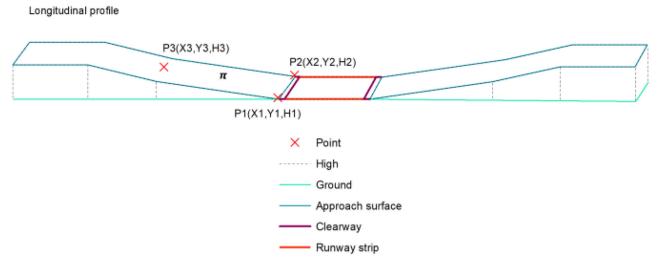


Fig. 9. Approach surface—longitudinal profile.

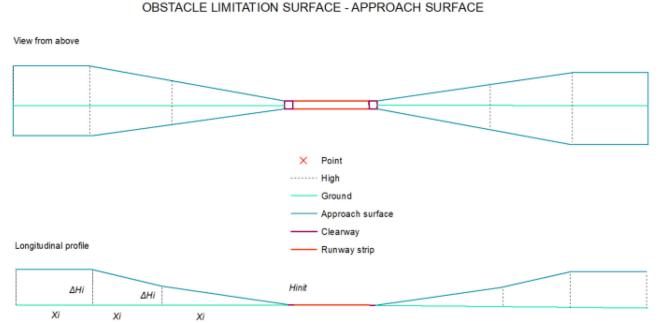


Fig. 10. Obstacle limitation surface—approach surface (plan view and cross section).

where π is planes of approach surface, $P_i(x_i, y_i, h_i)$ is points belonging to the π plane, H_o is the height of the obstacle, H_{a1} is the height of the approach surface for the first plane, H_{a2} is the height of the approach surface for the second plane, and H_{a3} is the height of the approach surface for the third plane.

The first stage of point plane cloud filtration involved defining a plane that would uniquely identify points belonging to the approach surface. For this purpose, the equation π (1) passing through three points was used. Every three noncollinear points $P_i(x_i, y_i, h_i)$, where $i = 1, 2, 3$, define exactly one plane π that contains it. The equation for this plane has the form

$$\pi : \begin{aligned} x - x_1 y - y_1 h - h_1 \\ x - x_2 y - y_2 h - h_2 = 0. \\ x - x_3 y - y_3 h - h_3 \end{aligned} \quad (1)$$

This is called the determinant equation of the plane. The extreme points being the beginning of the approach surface were adopted as point $P_1(x_1, y_1, h_1)$ and point $P_2(x_2, y_2, h_2)$, (see Fig. 9). Point $P_3(x_3, y_3, h_3)$ is at the end of the approach surface passing through the axis of the runway at a distance n from the edge of the runway strip.

After defining the planes π of the approach surface, the point cloud was filtered with the height of the H_i points as the main filtering criterion. The airspace object on the approach surface has a specified H_o height. If the H_o is equal to or greater than the height of the approach surface, then the object is considered an obstacle to flight (see Fig. 10).

For the first part of the approach surface, the object will be an obstacle if

$$H_o \geq H_{a1}. \quad (2)$$

The approach surface height was calculated using the following formula:

$$H_{a1} = X_i i + H_{\text{init}}. \quad (3)$$

where X_i is the distance from the runway and H_{init} is the height above sea level at the end of the runway.

For the second part of the approach surface, the object will be an obstacle if

$$H_o \geq H_{a2}. \quad (4)$$

The approach surface height was calculated using the following formula

$$H_{a2} = X_i i + H_{a1} \quad (5)$$

where X_i is the distance from the runway.

For the third approach plane, an object will be an obstacle if

$$H_o \geq H_{a3}. \quad (6)$$

The 3rd approach plane height, a horizontal surface, is equal to the maximum height of second plane and is constant

$$H_{a3} = \text{constans}. \quad (7)$$

The points above the designated planes were classified as obstacle points and used for further research. Points below the plane did not constitute aviation obstacles; therefore, they were omitted in further studies.

B. Point Cloud Segmentation

The second part of the methodology is the extraction of flat features using the RANSAC algorithm operating on nonground points classified in the previous step.

A new vector data parameter has been added to the RANSAC algorithm, defining the shape and attributes of the tested objects (aviation obstacles).

The RANSAC algorithm is an iterative method used to estimate the parameters of the searched mathematical model of an object in a data set containing a significant number of points not belonging to the modeled surface [61], [62]. That fact makes the RANSAC estimator particularly interesting for processing point clouds with noise and erroneous measurements. The algorithm's operation consists of two phases: initialization and test, repeated iteratively (see Fig. 11). The initialization phase was preceded by creating 2-D vector data on the basis of an orthophotomap for the detected aviation obstacles, containing information about these obstacles and automatic loading of vector data in the .shp format, where i is initiation stage, CS is consensus set, t is number of points matching the set, M_t is model, S is data, P is plane, M_d is maximum distance between the tested point and the hypothetical model, p is point matching the model, d is distance between the point and the assumed model, s_t is minimum sets, T_{iter} is number of minimum sets, k is the smallest number of data necessary to unambiguously define the assumed geometric model, ε is probability of identification of the wrong plane, and t_{rest} is threshold value.

The initialization stage consisted in randomly selecting the minimum set of points that are necessary for the unequivocal determination of the parameters of the estimated geometric model.

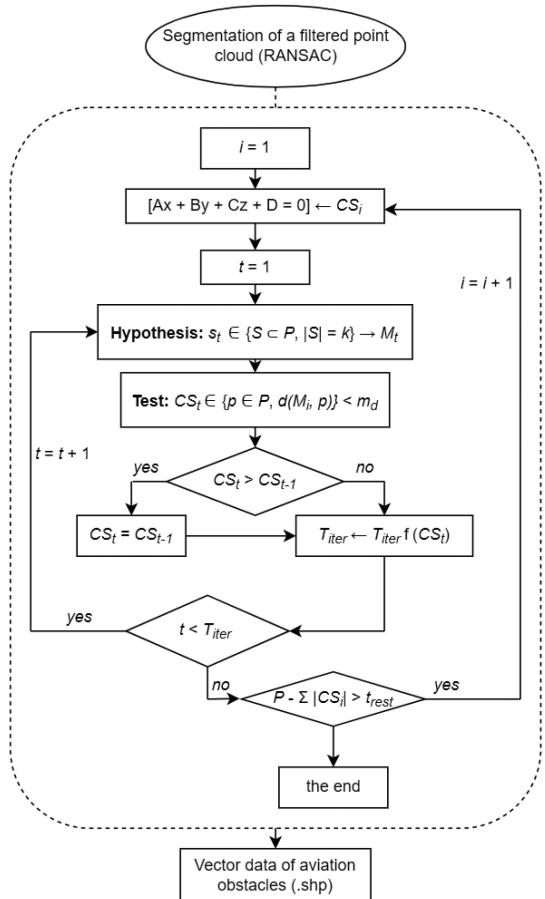


Fig. 11. Point cloud segmentation—algorithm RANSAC and vector data of aviation obstacles.

It is the smallest number of k data necessary to unequivocally define the assumed geometric model. For plane extraction, the minimum set consists of three points. The implementation of the algorithm begins with the drawing of a predetermined number of T_{iter} of minimal sets s_t (8), which is successively modified during the algorithm

$$s_t \in \{S \subset P, |S| = k\} \rightarrow 1 \quad (8)$$

Next, the parameters of the M_t model are calculated for each of the sets (in the case under consideration, the model is a plane passing through three points). The identified model is a hypothesis that is tested in the next step—the test. The test stage requires the determination of the value of the m_d parameter, which defines the maximum distance of the tested point from the hypothetical model. If the point meets the distance criterion, it is added to the so-called CS (Consensus Set). In this article, the set consists of data that were considered to belong to the considered plane: Σ

$$CS_t \in \{p \in P, d(M_t, p) < m_d\} \quad (9)$$

where

$$d(M_t, p) \quad (10)$$

determines the distance of the point from the assumed model [63].

After performing the test (9) for all data, the next minimal set is selected as the basis for the sequence of two steps—hypothesis and test—that are then repeated. If a CS set containing a greater number of points than the previous one is found, the existing set is replaced with the more numerous one and the T_{iter} value is modified (number of samples of the minimum sets)

$$T_{\text{iter}} = \frac{\log \varepsilon}{\log(1-q)}. \quad (11)$$

where ε is the probability of identifying the wrong plane, and q is calculated from the following equation [64]

$$q = \left(\frac{N_I}{N}\right)^k. \quad (12)$$

wherein

N_I is number of points belonging to the identified plane,
 N is number of all points belonging to the input data set, and
 k is the smallest number of data allowing for an unambiguous determination of the model.

When the identification of the first plane is completed, the described process is repeated, except for the points qualified to it. Identification of successive planes is completed when the number of points not added to them is lower than the assumed threshold value of t_{rest} .

C. Point Cloud Classification

The point cloud classification was aimed to detect aviation obstacles representing a specific group of elongated objects with regular cross-sections. The first criterion was the height of the objects determined based on point clouds. The second classification criterion was based on the geometric properties of objects formed by point clouds (see Fig. 12), where w_o is the obstacle width and H_o is the obstacle height

It was assumed that for objects belonging to the group of obstacles: masts, wind turbines, chimneys, towers, power poles and skyscrapers, the ratio of the width w_o of the object to its height H_o [65] should be within the following range:

$$\frac{1}{10} < \frac{w_o}{H_o} < \frac{1}{2}. \quad (13)$$

For aviation obstacles belonging to a group of buildings, the ratio of the width of the object w_o to its height H_o should be in the range:

$$\frac{w_o}{H_o} \geq \frac{1}{2}. \quad (14)$$

The height of aviation obstacles was determined in iterations, based on the cloud of points. Points that belonged to a plane at a certain height were searched in the dataset. Point searches were performed at 10-cm intervals, until the top point of the obstacle was found. This point was the basis for determination of height. The divisions for classifying obstacles, considering their width and height, were determined at the confidence level of $\Pr(\mu - 1\sigma \leq X \leq \mu + 1\sigma) \approx 68.27\%$. Obstacles that did not fall into the ranges described above (13, 14) did not meet the adopted criteria

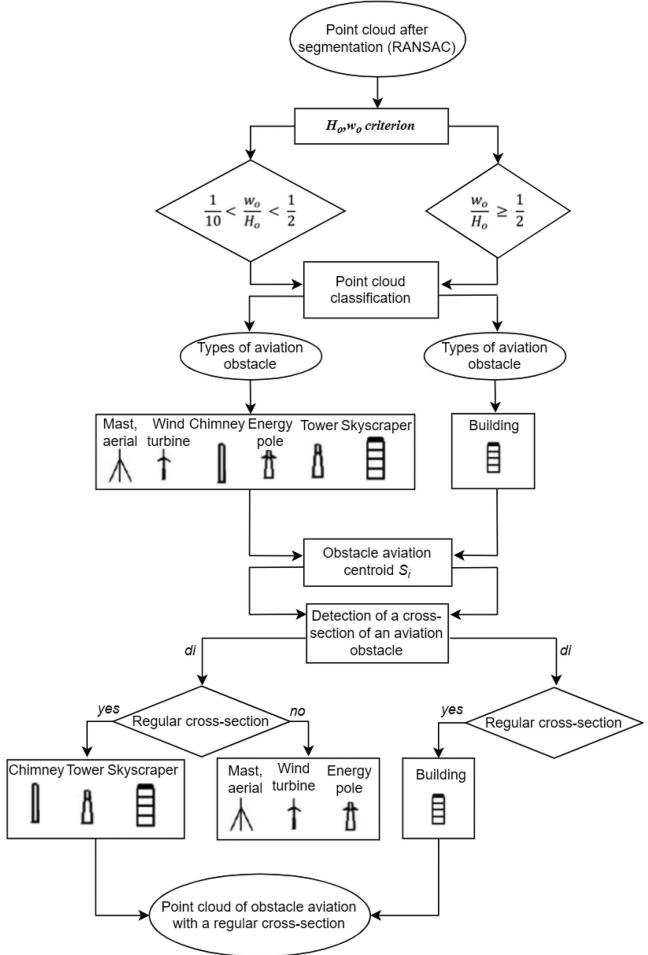


Fig. 12. Aviation obstacle filtration process.

for elongated objects, so they were excluded from further stages of the analysis.

The point clouds assigned to the appropriate groups of obstacles were classified according to their cross-sections. For this purpose, for each object, its centroid S_i was determined by calculating its coordinates (x_s, y_s) based on the following formulas:

$$x_S = \frac{\sum x_i}{n} \quad (15)$$

$$y_S = \frac{\sum y_i}{n} \quad (16)$$

where x_s is x coordinate of the centroid [m], y_s is y coordinate of the centroid [m], and n is number of points in the point cloud of the tested object.

The tested objects were classified based on the distance d_i [see Fig. 13(a) and (b)] of each point cloud point from the object's centroid C_i . The distance of the points from the centroid was calculated using the following formula:

$$d_i = \sqrt{(x_S - x_i)^2 + (y_S - y_i)^2} \quad (17)$$

where d_i is the distance of the points from the centroid, x_s is x coordinate of centroid [m], y_s is y coordinate of centroid [m], x_i

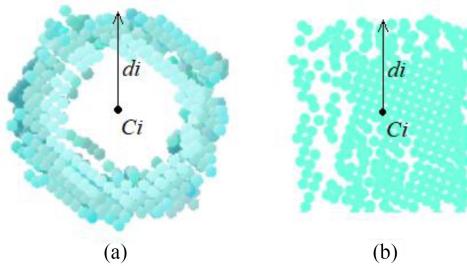


Fig. 13. Cross-section of an aerial obstacle. (a) Circular. (b) Polygonal.

is x coordinate of a point from a point cloud [m], y_i is y coordinate of a point from a point cloud [m].

Based on the distance of the point cloud along object edges, a group of regular and irregular cross-section objects was defined. For objects with a typical cross-section, it was assumed that if the distance from the extreme points of the cloud of points constituting the object's edge is constant, we are dealing with objects with a circular cross-section [see Fig. 13(a)]. On the other hand, if the distance from the extreme points of the cloud of points constituting the object's edge was not constant, we are dealing with objects whose cross-section was a polygon [see Fig. 13(b)]. Therefore, objects such as chimneys, towers, buildings, and skyscrapers were classified as objects with a regular cross-section. Objects with an irregular shape included masts, wind turbines and power poles. Objects classified as regular (i.e., typical cross-section) were used for further research.

IV. EXPERIMENTS AND RESULTS

This section presents the research experiments and the corresponding results obtained from the UAV images. Initial filtration of the point cloud was performed to detect objects that exceed the boundary surfaces, i.e., aviation obstacles. Then, using the RANSAC algorithm, segmentation of the point cloud was performed. The final stage consisted in the automatic segmentation of the point cloud based on the geometric relationships in the detected objects, which allowed for the selection of objects of a regular cross-section and uniform shape. During the experiment, the authors attempted to use the developed method to detect obstacles of irregular cross-sections and shapes, such as poles, masts, and antennas, but the obtained results were difficult to interpret.

A. Generating a Dense Point Cloud

After determining the external orientation of the photos, the so-called “rare” 3-D point cloud, which is the starting position to generate the so-called “dense” point cloud, the point cloud was generated using the image matching algorithm. The point cloud extraction process requires relatively small effort, as the only input elements are photos with external orientation. The results of the point cloud compaction are presented in Table III. The RMS error of the 3-D point location for the first test area was 0.02 m, for the second test area 0.01 m, for the third test area 0.03 m, and for the fourth test area 0.01 m.

TABLE III
POINT CLOUD DENSIFICATION RESULTS

Number of test area	RMSE 3D point [m]	Average Density (per m ³)
1	0.02	81.62
2	0.01	80.22
3	0.03	77.20
4	0.01	80.49



Fig. 14. Lask military airport—location of the terrains profiles.

B. Assessment of the Height Accuracy of Dense Point Clouds Based on the Terrain Profile

The accuracy of dense point clouds was then assessed by means of the following.

- 1) Comparing the altitude accuracy of point cloud profiles with the terrain profile measured in the open area using the GPS RTK method,
- 2) *Semi Global Matching* (SGM): Generated point cloud profiles comparison with LiDAR point clouds [66].

Five field profiles were measured in the study area (see Fig. 14).

Field profiles 1, 2, and 5 were measured in open areas, where the satellite signal reaching the receiver is characterized by the maximum possible strength, which affects the quality of the obtained results. Profiles 3 and 4 ran close to the forest, where growing trees could somewhat disrupt the signal.

The terrain profiles used to determine the precision characteristics of the point cloud were measured for each of the four test areas. Profile no. 1, approximately 750 m long, consisted of 131 points and was measured with an interval of 4–9 m. Profile no. 2, approximately 600 m long, consisted of 91 points, and was measured with an interval of 4–8 m. Profile no. 3 with a length of about 500 m and the number of points 82 was measured with an interval of 5–9 m. Profile no. 4, about 650 m long, consisted of 119 points, was measured from interval 4–9 m. Finally, profile no. 5, about 670 m long, consisted of 123 points.

Based on the differences in height between the examined point clouds and the measured field profile, parameters characterizing the accuracy were calculated, such as the average height difference, maximum negative, and positive deviations, mean error and standard deviation. The results are summarized in Table IV.

TABLE IV

STATISTICAL VALUES CHARACTERIZING THE HEIGHT ACCURACY ALONG THE TERRAIN PROFILE, CALCULATED FOR THE DENSE POINT CLOUDS STUDY

Profile	GSD [m]	Mean height difference [m]	Maximum negative deviation [m]	Maximum positive deviation [m]	Mean error [m]	Standard deviation [m]
1	0.04	-0.06	-0.16	+0.05	0.06	0.07
2	0.04	-0.03	-0.05	+0.10	0.08	0.11
3	0.04	-0.04	-0.04	+0.11	0.08	0.08
4	0.04	+0.03	-0.12	+0.18	0.06	0.15
5	0.04	-0.05	-0.07	+0.09	0.07	0.12

TABLE V

STATISTICAL VALUES CHARACTERIZING THE HEIGHT ACCURACY ALONG THE TERRAIN PROFILE, CALCULATED FOR THE LiDAR POINT CLOUDS

Profile	Density [pt/m ²]	Mean height difference [m]	Maximum negative deviation [m]	Maximum positive deviation [m]	Mean error [m]	Standard deviation [m]
1	4.0	0.09	-0.07	+0.18	0.11	0.06
2	4.0	0.08	-0.06	+0.15	0.09	0.04
3	4.0	0.09	-0.06	+0.18	0.09	0.08
4	4.0	0.10	-0.04	+0.17	0.09	0.07
5	4.0	0.07	-0.08	+0.14	0.12	0.06

Terrain profiles were measured on point clouds obtained from airborne laser scanning. It was assumed that the satellite measurement data are error-free, and that the error would be determined in relation to them.

The assessment of the accuracy of dense point clouds was compared with the parameters characterizing the accuracy of the LiDAR point clouds. The results are summarized in the table.

The data presented in Tables IV and V constitute the basis for assessing the altitude accuracy of SGM point clouds compared to LiDAR point clouds, taking into account the factors influencing the properties of SGM point clouds. Based on the results of the accuracy analysis, several regularities were noticed are as follows.

- 1) LiDAR point clouds are burdened with a greater systematic error than SGM point clouds.
- 2) Images obtained from UAV provide a point cloud with greater horizontal accuracy (lower mean error) than LiDAR point clouds.
- 3) Standard deviation of the LiDAR point cloud is smaller than almost all SGM point clouds.
- 4) Value of the standard deviation is slightly higher for the SGM point cloud, which indicates that the images obtained from the UAV also provide a point cloud that correctly reflects the topography.

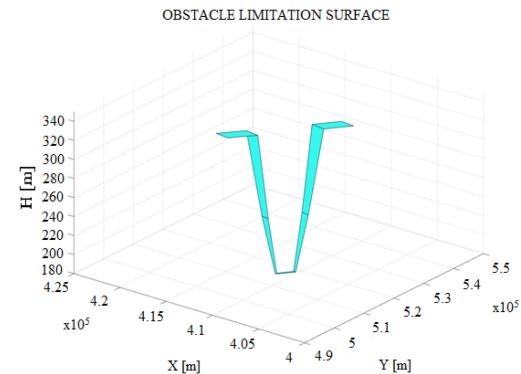


Fig. 15. Obstacle limitation surface as specified in ICAO.

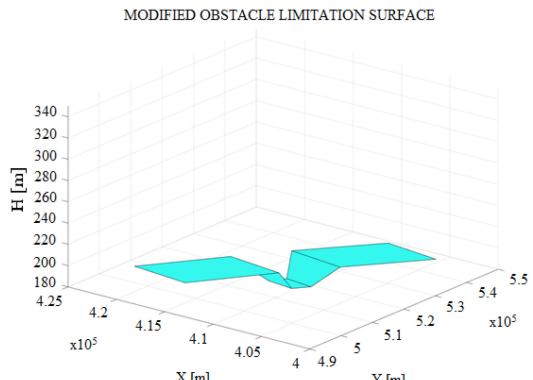


Fig. 16. Obstacle limitation surface as modified obstacle limitation surface.

C. Detection of Objects That are Aviation Obstacles

Dense point cloud became the basis for further research on the detection of aviation obstacles. After the initial processing of data obtained from the UAV and testing the accuracy of the point cloud, the point cloud was filtered. To do so, obstacle limiting surfaces were determined as the initial step in detecting aviation obstacles. The Łask military airport belongs to the first class of airports [2], [60] and has strictly defined surfaces limiting obstacles. Each of these surfaces is at a certain height, and objects whose height is higher than the obstacle limiting surfaces are called air obstacles. The equations of planes π constituting the obstacle limiting surfaces were determined in compliance with the ICAO requirements (see Fig. 15).

Each of the planes rises to a particular height H . This height became the point cloud filtration criterion. Points with a height equal to or greater than the height of the approach surface were classified as elements of aviation obstacles $H_o \geq H_{a1}$ (see Fig. 15) and were used in further stages of the research. During the study, they were introduced to the regulations that define the range of obstacle limiting surfaces. The altitude requirements in the close vicinity of the airport have changed. In the area of the Łask airport, the obstacle limitation surface was modified for research purposes (see Fig. 16) by increasing the range of the surface and lowering the height, which allowed the authors to obtain more research material in the form of further obstacles.

The modified obstacle limitation surface has defined the limit heights above which objects become aviation obstacles. Points

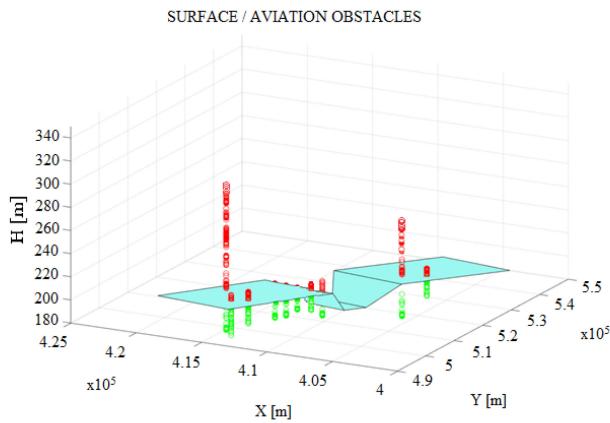


Fig. 17. Modified obstacle limitation surface with aviation obstacles.

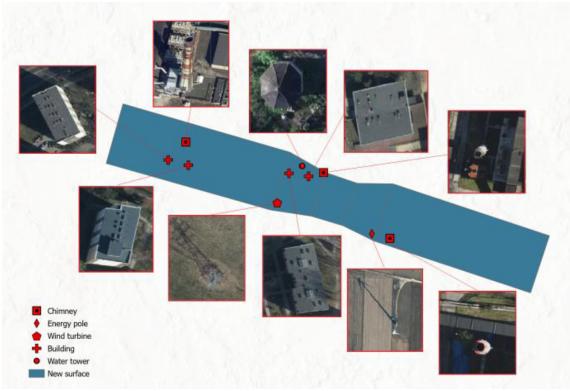


Fig. 18. Location of aviation obstacles near the Łask military airport.

from the point cloud that pierced the limiting surface were used for further development. Ten obstacle objects were detected in the four experimental areas (see Fig. 17). Points below the boundary surface are marked in green. Points above the boundary surface are marked in red.

D. Segmentation and Classification of Point Cloud

After the filtration of the point cloud, ten objects were selected for further analysis as aviation obstacles in the vicinity of the Łask military airport. Three obstacles were chimneys, and four more were buildings; a power line pole; a wind turbine; and the last one was a water tower. All of the abovementioned obstacles were located near the airport (see Fig. 18).

The ten analyzed data sets were characterized by the fact that they represented tall structures. The facilities differ significantly in terms of their architecture. However, three groups of objects may be distinguished based on their cross-section. The industrial chimney is a slender structure but similar in its round cross-section to a water tower. The skyscraper is a tall building, slightly different from the apartment block, but there is an analogy in the cross-section. Both the power line pole and the wind turbine are elongated objects, but their cross-sections are irregular. The primary objective of the research was to develop a methodology for detecting aviation obstacles of an elongated shape, where the main emphasis was placed on the most accurate reflection of their actual height. Given the above, the segmentation algorithm

was aimed at the most precise determination of the height of aviation obstacles.

All analyzed objects were segmented and classified to detect their actual shapes and heights. The previously filtered point clouds were used as input data. The implementation of the segmentation algorithm began, on the basis of an orthophotomap, with the creation of 2-D vector data about objects that are aviation obstacles. Then, the vector data in the X , Y horizontal planes was implemented in MATLAB. The work began with withdrawing a predetermined number T_{iter} of minimal sets s_t , which were modified online. Then, for the collection of points, the parameters of the plane surface passing through the three points were calculated. The model detected in this way became the hypothesis that was then tested in the next step, i.e., the test. The algorithm started with determining the maximum distance from the tested point to the hypothetical model. If a specific point met the distance criterion, it was added to the so-called set consisting of data that belonged to the considered plane M_t . After the test was performed, the next minimal set was selected. From this set of points, the hypothesis and test steps were repeated. When the algorithm found a set of points with more points than the previous one, the existing set was replaced with the larger set. After the detection of the first plane, the whole process was repeated, but without the participation of points belonging to the first plane. The plane detection was performed until the number of points not added to any of the planes was lower than the assumed threshold value of t_{rest} .

The presented algorithm was applied to all four data sets, which enabled the detection, segmentation and classification of the point cloud. The input data for all examined objects was the point cloud of individual objects. The first photogrammetric treatment was an industrial chimney. In this case, the algorithm detected the object automatically and quickly. As a result of the application of the RANSAC algorithm, data on an obstacle with known coordinates X , Y , H were obtained (see Fig. 19). The height of the obstacle was determined with an accuracy of 0.03 m. The second tested object was the water tower. Both the tower and the chimney have a common feature—despite the different architectural styles, both buildings have circular cross-sections. The water tower data set was characterized by the lowest number of points among all the tested objects. In this case, the input data set consisted of 20 thousand points. Here, the segmentation of the point cloud allowed the detection of the water tower, which was an aviation obstacle. The following data sets were much more numerous, and the number of their elements was in the range of 115 000 points up to 150 thousand. The clouds of points corresponding to the power line pole and wind turbine were also subjected to segmentation. In these two cases, the obtained results were ambiguous, so obstacles with an irregular cross-section were excluded from the subsequent part of the research. The last segmented objects were two industrial chimneys located in the vicinity of the airport.

E. Comparison of Segmentation Results

The preliminary analysis of UAV point cloud segmentation results was carried out based on a comparison with the segmentation results for the point cloud obtained from airborne

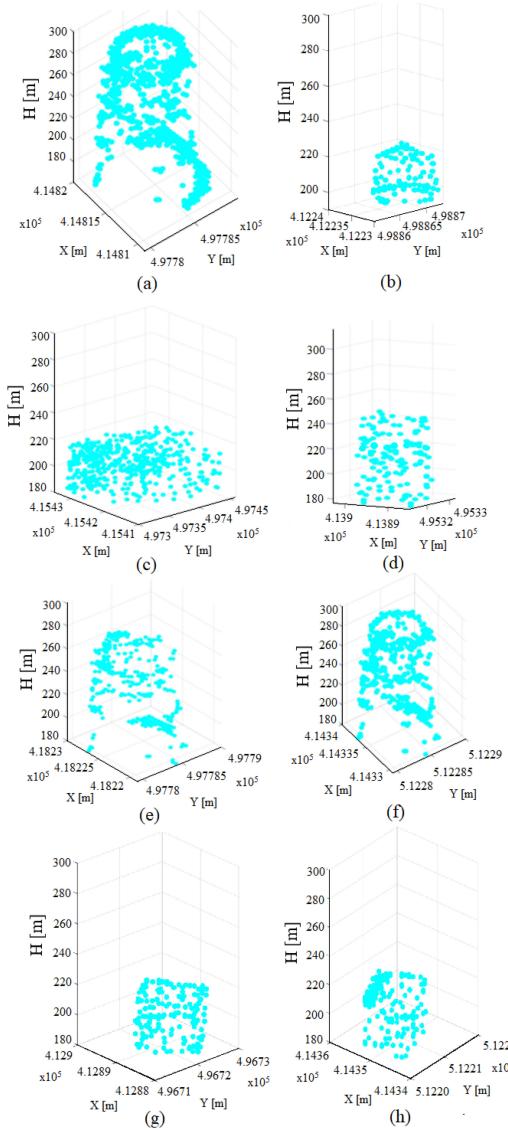


Fig. 19. Detected aviation obstacles. (a) Chimney. (b) Water tower. (c) Building. (d) Building. (e) Chimney. (f) Chimney. (g) Building. (h) Building.

laser scanning. All correctly detected aviation obstacles were analyzed. It was noticed that in the case of both groups of data, the RANSAC algorithm, in most cases, correctly qualified the points belonging to objects that were aviation obstacles. The LiDAR point cloud was characterized by a more significant, evenly distributed number of points on the ground and base. The algorithm incorrectly qualified the ground points to the set belonging to the obstacle. The analysis of segmentation results for both data sets has been extended to include a summary of the algorithm execution time, processing data sets of various sizes (see Table VI). Based on the outline of the results, one may notice that the number of points does not increase the number of surface planes and thus the time needed to perform the segmentation.

F. Analysis of the Accuracy of the Point Cloud Fit

The analysis of the accuracy of the point cloud fit was carried out based on the reference data contained in the eTOD database (electronic Terrain and Obstacle Data). The aerodrome obstacle

TABLE VI
SUMMARY OF THE ALGORITHM EXECUTION TIME FOR THE UAV POINT CLOUD
AND LiDAR POINT CLOUD

Obstac le	Num ber of point s UAV	Num ber of points LiDAR	Num ber of planes UAV	Number of planes LiDAR	Time UAV [s]	Time LiDAR [s]
1 (chimne y)	841	952	5	5	10	11
2 (chimne y)	798	818	4	4	9	11
3 (chimne y)	803	812	4	4	9	10
4 (buildin g)	1404	1558	3	3	12	14
5 (buildin g)	1656	1688	5	5	18	19
6 (buildin g)	1894	1902	7	7	21	22
7 (buildin g)	1528	1533	6	6	19	21
8 (water tower)	702	731	3	3	9	10

TABLE VII
STATISTICAL VALUES CHARACTERIZING THE ACCURACY OF THE POINT
CLOUD FITTING

Obstacle	Mean X coordinat e differenc e [m]	Mean Y coordinate difference [m]	Mean height differe nce H [m]	Mean error [m]	Stan dard devia tion [m]
Chimney 1	0.02	0.03	0.03	0.05	0.04
Chimney 2	0.03	0.01	0.04	0.07	0.06
Chimney 3	0.02	0.02	0.02	0.04	0.06
Building 1	0.04	0.03	0.03	0.06	0.07
Building 2	0.05	0.04	0.02	0.07	0.07
Building 3	0.03	0.02	0.04	0.06	0.05
Building 4	0.02	0.05	0.04	0.06	0.05
Water tower	0.02	0.03	0.03	0.04	0.05

database includes information on objects penetrating the aerodrome boundary surfaces. The database contains information on the longitude and latitude of the obstacle, its absolute height, height above the ground surface, location—locality, type of obstacle, etc. The analysis of the accuracy of fitting the cloud of points took into account whether it fit into the horizontal plane (X , Y coordinates) and fitting into the vertical plane (H coordinate) (see Table VII).

The accuracy analysis was carried out for eight aviation obstacles—three industrial chimneys, four buildings, and one water tower located in the vicinity of the airport.

Based on the above table, it can be seen that the average difference in horizontal coordinates (X , Y) was in the range from 0.01 to 0.05 m. The average difference in height (H) fell in the range from 0.02 to 0.04 m. Mean error of the point cloud fitting to the obstacle data set was from ± 0.04 to ± 0.08 m, and the standard deviation ranged from 0.04 to 0.07 m.

Based on the accuracy results, it can be concluded that the developed method of aviation obstacle detection and classification guarantees horizontal and vertical accuracy at the level of several centimeters.

V. DISCUSSION OF RESULTS

This section covers the results of detection, low altitude point cloud segmentation, and elongated aviation obstacle classification.

The research on the algorithm of aviation obstacle detection was preceded by an analysis of the altitude accuracy of dense point clouds based on the measured terrain profiles. For this purpose, the accuracy parameters were calculated based on the differences in height between the dense point clouds and the measured terrain profiles. The standard deviation ranged from 0.07 to 0.15 m. The accuracy assessment was supplemented with the measurement of field profiles on point clouds obtained from airborne laser scanning. Based on the height determined from ALS point cloud and field profiles, the standard deviation ranged from 0.04 to 0.08 m. The mean error for the dense point clouds was lower by 0.03 m. The standard deviation for the dense point clouds was more significant by 0.04 m than the standard deviation of the LiDAR point cloud. In his research, Wallace *et al.* [67] presented a similar vertical accuracy obtained with the use of ALS and UAV, pointing to the advantage of UAVs due to the relative ease and speed of data acquisition.

The initial detection of objects resulting from automatic filtration of points located above the designated surface allowed for the identification objects that may be aviation obstacles. The processing time of this method and the complete automation of the process demonstrate the high efficiency of the presented approach.

This article presents a modified RANSAC algorithm to perform point cloud segmentation. The algorithm was enriched by adding the parameter of vector data that define the attributes and shapes of the analyzed objects.

The culmination of the aviation obstacle detection process was the automatic classification of the aviation obstacle point cloud based on the width and height of the obstacle as well as on the centroid and the cross-section of the object. Thanks to this method, it was possible to determine to which group the tested point cloud belongs more accurately.

The article focuses on detecting the exact position of an obstacle (X , Y) and its height (H). The obtained accuracy results proved that the RANSAC algorithm is a sufficient method for examining geometrically uncomplicated objects [50]. The authors took an attempt to use the developed method to detect such obstacles as masts, turbines, poles, etc., i.e., objects of irregular shapes. However, the obtained results were ambiguous, so that, at this stage, it remained impossible to detect obstacles other than those of geometrically uncomplicated shapes. In spite of these limitations, the presented method still ensures, among others, the required accuracy for detecting obstacles [56], the automation of the procedure, and shortening the duration of the whole detection process.

The accuracy analysis of aviation obstacles detection and classification has been enriched with creating a synthetic model

to determine the accuracy of plane identification. The analysis results made it possible to conclude that the algorithm allows for the determination of the exact location of the planes; however, a slight flaw was noticed, which was the incorrect inclusion of points located in the same plane, but not belonging to the aerial obstacle. However, this did not affect the vertical accuracy of the determined obstacles.

The developed methodology enabled the detection of obstacles of regular cross-sections, with a uniform structure of the point clouds. The positioning accuracy was checked with the obstacle database. The mean error of fitting the point cloud in eTOD was from ± 0.04 to ± 0.07 m. The standard deviation ranged from 0.04 to 0.07 m. The mean difference in the X coordinate was from 0.02 to 0.05 m, in the Y coordinate from 0.01 to 0.05 m, and in the H coordinate from 0.02 to 0.04 m. Mitsevich [12] obtained lower accuracy of determining aviation obstacles in this article, achieving accuracy on the level of 0.3 to 0.5 m.

The experiment presented here demonstrates the advantages of using imagery from UAV to detect aviation obstacles. Data from UAV are obtained depending on the needs and the only limitation are the meteorological conditions, while data from airborne laser scanning are obtained usually only once a year. Although the ALS enables to cover a larger area, the necessity to ensure a high frequency of obtaining data, considering the emerging needs, forces us to use a more cost-effective method, which is the UAV.

However, despite the satisfactory results, the presented method has some limitations. The first limitation of the proposed method and other similar algorithms based on statistical image values is that they may not be suitable for specific examples of images, e.g., those obtained in poor weather conditions. An example may be intense fog that obscures only a part of the object captured in the photograph. In that case, the use of the algorithm will negatively affect the color reproduction in the image and, consequently, degrade the spectral quality of the image. Another limitation resulted from narrowing down the research to aviation obstacles that were elongated objects. The developed methodology is used to study objects, which may include towers, chimneys, skyscrapers, or buildings i.e., those that have a regular cross-section and uniform shape. The detection of obstacles of an irregular shape (heterogeneous distribution of the point cloud), such as a power line pole or wind turbine, brought ambiguous results, which suggests that the method still requires further development. The authors are planning to conduct further research to detect all types of aviation obstacles in the vicinity of airports.

VI. CONCLUSION

The article attempts to describe the automatic detection and classification of elongated aviation obstacles based on dense point clouds. The authors used a modified RANSAC algorithm, presented a new approach to aviation obstacle detection and classification and to point cloud filtration. The main objective of the methodology is to detect elongated aviation obstacles in the close vicinity of the airport.

As a result of the conducted research, eight aviation obstacles were detected, and the obtained accuracy seems to be promising. Based on the data contained in eTOD, the accuracy of

the point cloud fit was calculated. The mean error of fitting the point cloud was ± 0.05 m. The mean difference in the X coordinate was from ± 0.03 m, the mean difference in the Y coordinate was from ± 0.02 m, the mean difference in the H coordinate was from ± 0.03 m—precision limits imposed by ICAO rules [56]–[59]. The authors of this article presented a methodology that enables detecting obstacles of an elongated shape. Tests were conducted on a dense point cloud generated based on imagery obtained from UAV and dense image matching algorithms. So far, research on the detection of aviation obstacles was conducted on point clouds obtained from airborne laser scanning [5]. However, the correct detection of elongated obstacles was difficult and required additional control by means of traditional ground measurements, which significantly increased the duration of the detection process [5]. The method presented here offers higher spatial accuracy, lower data acquisition costs, higher time resolution, i.e., up-to-dateness of data, the possibility to analyze large areas, automation of the process, detecting elongated obstacles, and, finally, shortening the total duration of the detection procedure. The developed methodology may significantly improve the process of analyzing aircraft operational limitations, designing procedures, creating aeronautical charts, and improving safety in the airspace by reducing the risk of an aircraft collision with an obstacle to a minimum. The presented approach can be used for airports of various categories, with differing constraints imposed by obstacle limiting surfaces.

Future research will improve the presented methodology and extend the study to other types of aviation obstacles. The authors plan to expand the classification algorithm to cover all kinds of aviation obstacles.

REFERENCES

- [1] M. Zeybek and İ. Şanlıoğlu, “Point cloud filtering on UAV based point cloud,” *Measurement*, vol. 133, pp. 99–111, 2019.
- [2] Annex 14 to the convention on international civil aviation, “Aerodromes: Aerodromes design and operations,” ICAO, 8th ed., vol. I, 2018. [Online]. Available: <https://ffac.ch/wp-content/uploads/2020/10/ICAO-Annex-14-Aerodromes-Vol-I-Aerodromes-Design-and-Operations.pdf>
- [3] ICAO, “Safety report,” Int. Civil Aviation Org., Montreal, Canada, 2020. [Online]. Available: https://www.icao.int/safety/Documents/ICAO_SR_2020_final_web.pdf
- [4] ULC, “Sprawozdanie o stanie bezpieczeństwa lotnictwa cywilnego za rok 2019,” (in Polish), Urząd lotnictwa cywilnego, 2020. [Online]. Available: https://www.ulc.gov.pl/_download/bezpieczenstw_lotow/analizy/Sprawozdanie_2019.pdf
- [5] Terrain and Obstacle Data Manual, Eurocontrol, 3.0 ed., 2021. [Online]. Available: <https://www.eurocontrol.int/sites/default/files/2021-07/eurocontrol-tod-manual-ed-3-0.pdf>
- [6] L. Dong and J. Shan, “A comprehensive review of earthquake-induced building damage detection with remote sensing techniques,” *ISPRS J. Photogramm. Remote Sens.* 2013, vol. 84, pp. 85–99, 2013, doi: [10.1016/j.isprsjprs.2013.06.011](https://doi.org/10.1016/j.isprsjprs.2013.06.011).
- [7] S. Sun and C. Salvaggio, “Aerial 3D building detection and modeling from airborne LiDAR point clouds,” *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, vol. 6, no. 3, pp. 1440–1449, Jun. 2013, doi: [10.1109/JSTARS.2013.2251457](https://doi.org/10.1109/JSTARS.2013.2251457).
- [8] F. Rottensteiner, G. Sohn, M. Gerke, J. D. Wegner, U. Breitkopf, and J. Jung, “Results of the isprs benchmark on urban object detection and 3D building reconstruction,” *ISPRS J. Photogramm. Remote Sens.*, vol. 93, pp. 256–271, 2014, doi: [10.1016/j.isprsjprs.2013.10.004](https://doi.org/10.1016/j.isprsjprs.2013.10.004).
- [9] I. Colomina and P. Molina, “Unmanned aerial systems for photogrammetry and remote sensing: A review,” *ISPRS J. Photogramm. Remote Sens.*, vol. 92, pp. 79–97, 2014.
- [10] R. R. Gamage and H. A. Nalani, “A grid-based automated building extraction technique for low-cost UAV images,” *J. Geospatial Surv.*, vol. 1, pp. 23–31, 2021, doi: [10.4038/jgs.v1i1.26](https://doi.org/10.4038/jgs.v1i1.26).
- [11] E. Maltezos and C. Ioannidis, “Automatic detection of building points from lidar and dense image matching point clouds,” *ISPRS Ann. Photogramm., Remote Sens. Spatial Inf. Sci.*, vol. II-3/W5, pp. 33–40, 2015, doi: [10.5194/isprsaannals-II-3-W5-33-2015](https://doi.org/10.5194/isprsaannals-II-3-W5-33-2015).
- [12] L. Mitsevich, “3D Aerodrome obstacle assessment using stereo remote sensing imagery,” *Int. Arch. Photogramm., Remote Sens. Spatial Inf. Sci.*, vol. XLIII-B2-2020, pp. 1115–1119, 2020.
- [13] N. Demir and E. Baltsavias, “Object extraction at airport sites using DTMs/DSMs and multispectral image analysis,” international archives of photogrammetry,” *Remote Sens. Spatial Inf. Sci.*, vol. 36, pp. 25–30, 2007.
- [14] N. Demir, N. Poli, and E. Baltsavias, “Detection of buildings at airport sites using images & LIDAR data and a combination of various methods,” *Int. Arch. Photogramm., Remote Sens. Spatial Inf. Sci.*, vol. 38, pp. 71–76, 2009.
- [15] C. Parrish and R. Nowak, “Improved approach to LIDAR airport obstruction surveying using full-waveform data,” *J. Surv. Eng.*, vol. 135, no. 2, pp. 72–82, 2009.
- [16] Y. Xu, S. Tuttas, L. Hoegner, and U. Stilla, “Geometric primitive extraction from point clouds of construction sites using VGS,” *IEEE Geosci. Remote. Sens. Lett.*, vol. 14, no. 3, pp. 424–428, Mar. 2017, doi: [10.1109/LGRS.2017.2647816](https://doi.org/10.1109/LGRS.2017.2647816).
- [17] Y. Xu, S. Tuttas, L. Hoegner, and U. Stilla, “Reconstruction of scaffolds from a photogrammetric point cloud of construction sites using a novel 3D local feature descriptor,” *Automat. Construction*, vol. 85, pp. 76–95, 2018.
- [18] E. Grilli, F. Menna, and F. Remondino, “A review of point clouds segmentation and classification algorithms,” *ISPRS Int. Arch. Photogramm. Remote. Sens. Spatial Inf. Sci.*, vol. XLII-2/W3, pp. 339–344, 2017.
- [19] A. Frome, D. Huber, R. Kolluri, T. Bülow, and J. Malik, “Recognising objects in range data using regional point descriptors,” in *Proc. 8th Eur.Comput. Vis.*, 2004, pp. 224–237.
- [20] M. Rutzinger, B. Höfle, M. Hollaus, and N. Pfeifer, “Object-based point cloud analysis of full-waveform airborne laser scanning data for urban vegetation classification,” *Sensors*, vol. 8, no. 8, pp. 4505–4528, 2008.
- [21] N. Chehata, L. Guo, and C. Mallet, “Airborne LiDAR feature selection for urban classification using random forests,” *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. 38, pp. 207–212, 2009.
- [22] B. Höfle and M. Hollaus, “Urban vegetation detection using high density full-waveform airborne LiDAR data-combination of object based image and point cloud analysis,” in *Proc. ISPRS TC VII Symp. 100 Years ISPRS*, pp. 281–286, 2010.
- [23] C. Mallet, F. Bretar, and U. Soergel, “Analysis of full-waveform LiDAR data for classification of urban areas,” in *Proc. ISPRS Congr.*, 2008, pp. 337–349.
- [24] M. Bassier, B. Van Genechten, and M. Vergauwen, “Classification of sensor independent point cloud data of building objects using random forests,” *J. Build. Eng.*, vol. 21, pp. 468–477, 2019.
- [25] T. Hackel, J. D. Wegner, and K. Schindler, “Fast semantic segmentation of 3D point clouds with strongly varying density,” *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. 3, pp. 177–184, 2016.
- [26] M. Weinmann, B. Jutzi, and C. Mallet, “Feature relevance assessment for the semantic interpretation of 3D point cloud data,” *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. 2, pp. 313–318, 2013.
- [27] T. Hackel, N. Savinov, L. Ladicky, J. D. Wegner, K. Schindler, and M. Pollefeys, “Semantic3D net: A new large-scale point cloud classification benchmark,” *ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. 4, pp. 91–98, 2017.
- [28] J. Zhang, X. Lin, and X. Ning, “SVM-based classification of segmented airborne LiDAR point clouds in urban areas,” *Remote Sens.*, vol. 5, no. 8, pp. 3749–3775, 2013.
- [29] B. Jutzi and H. Gross, “Nearest neighbour classification on laser point clouds to gain object structures from buildings,” *Int. Arch. Photogramm. Remote Sens. Spatial Inf. Sci.*, vol. 38, pp. 4–7, 2009.
- [30] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, “Pointnet: Deep learning on point sets for 3D classification and segmentation,” in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit.*, 2017, pp. 652–660, doi: [10.1109/CVPR.2017.16](https://doi.org/10.1109/CVPR.2017.16).
- [31] A. Bab-Hadiashar and N. Gheissari, “Range image segmentation using surface selection criterion,” *IEEE Trans. Image Process.*, vol. 15, no. 7, pp. 2006–2018, 2006, doi: [10.1109/TIP.2006.877064](https://doi.org/10.1109/TIP.2006.877064).
- [32] A. Aldoma *et al.*, “Tutorial: Point cloud library: Three-dimensional object recognition and 6 dof pose estimation,” *IEEE Robot. Autom. Mag.*, vol. 19, no. 3, pp. 80–91, Sep. 2012, doi: [10.1109/mra.2012.2206675](https://doi.org/10.1109/mra.2012.2206675).

- [33] X. Lu, J. Yao, J. Tu, K. Li, L. Li, and Y. Liu, "Pairwise linkage for point cloud segmentation," *ISPRS Ann. Photogramm. Remote. Sens. Spatial. Inf. Sci.*, vol. III-3, pp. 201–208, 2016.
- [34] H. Aljumaily, D. F. Laefer, and D. Cuadra, "Urban point cloud mining based on density clustering and mapreduce," *J. Comput. Civil Eng.*, vol. 31, 2017, Art. no. 04017021.
- [35] A. V. Vo, L. Truong-Hong, D. F. Laefer, and M. Bertolotto, "Octree-based region growing for point cloud segmentation," *ISPRS J. Photogramm. Remote. Sens.*, vol. 104, pp. 88–100, 2015.
- [36] D. Tóvári and N. Pfeifer, "Segmentation based robust interpolation-a new approach to laser data filtering," *ISPRS Int. Arch. Photogramm. Remote. Sens. Spat. Inf. Sci.*, vol. 36, pp. 79–84, 2005.
- [37] T. Rabbani, F. Van Den Heuvel, and G. Vosselman, "Segmentation of point clouds using smoothness constraint," *ISPRS Int. Arch. Photogramm. Remote. Sens. Spat. Inf. Sci.*, vol. 36, pp. 248–253, 2006.
- [38] P. Besl and R. Jain, "Segmentation through variable-order surface fitting," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 10, no. 2, pp. 167–192, Mar. 1988, doi: [10.1109/34.3881](https://doi.org/10.1109/34.3881).
- [39] A. Nurunnabi, D. Belton, and G. West, "Robust segmentation for large volumes of laser scanning three-dimensional point cloud data," *IEEE Trans. Geosci. Remote. Sens.*, vol. 54, no. 8, pp. 4790–4805, Aug. 2016.
- [40] P. Dorniger and N. Pfeifer, "A comprehensive automated 3D approach for building extraction, reconstruction and regularisation from air borne laser scanning point cloud," *Sensors*, vol. 8, pp. 7323–7343, 2008.
- [41] A. Nguyen and B. Le, "3D point cloud segmentation: A survey," in *Proc. 6th Conf. Robot., Automat. Mechatronics*, Nov. 2013, pp. 225–230.
- [42] R. Schnabel, R. Wahl, and R. Klein, "Efficient RANSAC for point-cloud shape detection," *Comput. Graph. Forum*, vol. 26, pp. 214–226, 2007.
- [43] J. Bauer, K. Karner, K. Schindler, A. Klaus, and C. Zach, "Segmentation of building from dense 3D point-clouds," in *Proc. 27th Workshop Austrian Assoc. Pattern Recognit.*, 2005, pp. 253–259.
- [44] H. Boulaassal, "Segmentation et modélisation géométrique de façades de bâtiments à partir de relevés laser terrestres," Ph.D. Thesis, Université de Strasbourg, Strasbourg, France, 2010.
- [45] T. M. Awwad, Q. Zhu, Z. Du, and Y. Zhan, "An improved segmentation approach for planar surfaces from unstructured 3D point clouds," *Photogramm. Rec.*, vol. 25, no. 129, pp. 5–23, 2010.
- [46] J. A. Delmerico, P. David, and J. J. Corso, "Building facade detection, segmentation, and parameter estimation for mobile robot localization and guidance," in *Proc. Int. Conf. Intell. Robots Syst.*, 2011, doi: [10.1109/IROS.2011.6094778](https://doi.org/10.1109/IROS.2011.6094778).
- [47] M. Y. Yang and W. Forstner, "Plane detection in point cloud data," 2010. [Online]. Available: <https://ris.utwente.nl/ws/files/103953896/Yang2010Plane.pdf>
- [48] J.-E. Deschaud, "Traitements de nuages de points denses et modélisation 3D d'environnement par système mobile LIDAR/Caméra," Ph.D. Thesis, MINES ParisTech, Paris, France.
- [49] S. Tuttas and U. Stilla, "Window detection in sparse point clouds using indoor points," international archives of photogrammetry," *Remote Sens. Spatial Inf. Sci.*, vol. 38, no. 3/W22, pp. 131–136, 2011.
- [50] M. Jarząbek-Rychard and A. Borkowski, "Porównanie algorytmów RANSAC oraz rosnących płaszczyzn w procesie segmentacji danych z lotniczego skaningu laserowego," (in Polish), *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 21, pp. 119–129, 2010.
- [51] F. Tarsha Kurdi, "Extraction et reconstruction de bâtiments en 3D à partir de relevés lidar aéroportés," Ph.D. Thesis, Université de Strasbourg, Strasbourg, France, 2008.
- [52] Z. Rozsa and T. Sziranyi, "Obstacle prediction for automated guided vehicles based on point clouds measured by a tilted LIDAR sensor," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 8, pp. 2708–2720, Aug. 2018, doi: [10.1109/TITS.2018.2790264](https://doi.org/10.1109/TITS.2018.2790264).
- [53] Y. Choe, S. Ahn, and M. J. Chung, "Online urban object recognition in point clouds using consecutive point information for urban robotic missions," *Robot. Auton. Syst.*, vol. 62, no. 8, pp. 1130–1152, 2014, doi: [10.1016/j.robot.2014.04.007](https://doi.org/10.1016/j.robot.2014.04.007).
- [54] M. Hammer, M. Hebel, M. Laurenzis, and M. Arens, "Lidar-based detection and tracking of small UAVs," *Proc. SPIE*, 2018, vol. 10799, Art. no. 107990S.
- [55] P. Wu, S. Xie, H. Liu, J. Luo, and Q. Li, "A novel algorithm of autonomous obstacle-avoidance for mobile robot based on LIDAR data," in *Proc. IEEE Int. Conf. Robot. Biomimetics*, 2015, pp. 2377–2382.
- [56] Annex 15 to the Convention on International Civil Aviation, "International standards and recommended practices," Aeronautical Information Services, ICAO, 15ed., 2016. [Online]. Available: <https://ffac.ch/wp-content/uploads/2020/10/ICAO-Annex-15-Aeronautical-Information-Services.pdf>
- [57] Annex 4 to the Convention on International Civil Aviation, "Aeronautical charts," ICAO, 11ed., 2009. [Online]. Available: <https://aviation-is.better-than.tv/icaodocs/Annex%204%20-%20Aeronautical%20Charts/Annex%204%20Aeronautical%20Charts,%20Edition%20no%2011.pdf>
- [58] DOC-9674, "World geodetic system-1984 (WGS84) manual," ICAO, 2ed., 2002. [Online]. Available: <https://skybrary.aero/sites/default/files/bookshelf/5854.pdf>
- [59] DOC-1006, Aeronautical informationmanagement, ICAO, 1ed., 2018. [Online]. Available: <https://ffac.ch/wp-content/uploads/2020/11/ICAO-Doc-10066-Aeronautical-Information-Management.pdf>
- [60] "Rozporządzenie ministra infrastruktury z dnia 12 stycznia 2021 r. w sprawie przeszkoł lotniczych, powierzchni ograniczających przeszkoły oraz urządzeń o charakterze niebezpiecznym," Dziennik Ustaw, 2021, poz. 264., in Polish. [Online]. Available: <https://isap.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20210000264>
- [61] M. A. Fischler and R. C. Bolles, "Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography," *Commun. ACM*, vol. 24, no. 6, pp. 381–395, 1981.
- [62] M. Zuliani, "RANSAC for dummies," Los Gatos, pp. 8–93, 2012. [Online]. Available: <https://www.ic.unicamp.br/~sim;rocha/teaching/2012s1/mc949/aulas/ransac-4-dummies.pdf>
- [63] G. Vosselman, B. G. H. Gorte, G. Sithole, and T. Rabbani, "Recognising structure in laser scanner point clouds," *Int. Arch. Photogramm., Remote Sens. Spatial Inf. Sci.*, vol. 36, pp. 33–38, 2004.
- [64] M. Zuliani, RANSAC, 2009. [Online]. Available: <http://vision.ece.ucsb.edu/~zuliani/Research/RANSAC/docs/>
- [65] M. Rogowski and J. A. Prusiel, "Budynek wysokościowy," (in Polish), Przegląd Budowlany, Warsaw, Poland, 2019.
- [66] W. Dominik, "Comparison of point clouds derived from aerial image matching with data from airborne laser scanning," *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 26, pp. 53–66, 2014.
- [67] L. Wallace, A. Lucieer, Z. Malenovský, D. Turner, and P. Vopěnka, "Assessment of forest structure using two UAV techniques: A comparison of airborne laser scanning and structure from motion (SfM) point clouds," *Forests*, vol. 7, no. 3, pp. 1–16, 2016.
- [68] T. Gobakken, O. M. Bollandsås, and E. Næsset, "Comparing biophysical forest characteristics estimated from photogrammetric matching of aerial images and airborne laser scanning data," *Scand. J. Forest Res.*, vol. 30, pp. 73–86, 2015.
- [69] S. Puliti, T. Gobakken, H. O. Ørka, and E. Næsset, "Assessing 3D point clouds from aerial photographs for species-specific forest inventories," *Scand. J. Forest Res.*, vol. 32, pp. 68–79, 2017.
- [70] S. Tuominen, A. Balazs, H. Saari, I. Pöölönen, J. Sarkeala, and R. Viitala, "Unmanned aerial system imagery and photogrammetric canopy height data in area-based estimation of forest variables," *Silva Fennica*, vol. 49, 2015, Art. no. 1348.



Marta Lalak received the M.Sc. degree in geoinformatics from Military University of Technology, Warsaw, Poland, in 2010. She is currently working toward the Ph.D. degree in engineering and technical sciences from Polish Air Force University.

She is a Lecturer with the Institute of Navigation of the Military University of Aviation, where she conducts classes on "GIS in navigation," "basics of photogrammetry," "basics of remote sensing," "image recognition." Her research interests include UAV-acquired data processing and aviation obstacle detection.

He was with the Department of Imagery Intelligence, Faculty of Civil Engineering and Geodesy, Military University of Technology, Warsaw, Poland.



Damian Wierzbicki received the Ph.D degree in photogrammetry and remote sensing from Military University of Technology, Warsaw, Poland, in 2015.

He is currently an Associate Professor with the Department of Imagery Intelligence, Faculty of Civil Engineering and Geodesy, Military University of Technology where he teaches: "Photogrammetry and Remote Sensing" and "Image Processing." His research interests include UAV navigation and image processing, deep learning in remote sensing. His research interests also include development of new algorithms for object detection and classification in image sequences from UAV.

Załącznik 4 – [Publikacja 4]

Article

Automated Detection of Atypical Aviation Obstacles from UAV Images Using a YOLO Algorithm

Marta Lalak ¹  and Damian Wierzbicki ^{2,*} 

¹ Institute of Navigation, Polish Air Force University, 08-521 Dęblin, Poland

² Department of Imagery Intelligence, Faculty of Civil Engineering and Geodesy, Military University of Technology, 00-908 Warsaw, Poland

* Correspondence: damian.wierzbicki@wat.edu.pl; Tel.: +48-261-83-90-21

Abstract: Unmanned Aerial Vehicles (UAVs) are able to guarantee very high spatial and temporal resolution and up-to-date information in order to ensure safety in the direct vicinity of the airport. The current dynamic growth of investment areas in large agglomerations, especially in the neighbourhood of airports, leads to the emergence of objects that may constitute a threat for air traffic. In order to ensure that the obtained spatial data are accurate, it is necessary to understand the detection of atypical aviation obstacles by means of their identification and classification. Quite often, a common feature of atypical aviation obstacles is their elongated shape and irregular cross-section. These factors pose a challenge for modern object detection techniques when the processes used to determine their height are automated. This paper analyses the possibilities for the automated detection of atypical aviation obstacles based on the YOLO algorithm and presents an analysis of the accuracy of the determination of their height based on data obtained from UAV.



Citation: Lalak, M.; Wierzbicki, D. Automated Detection of Atypical Aviation Obstacles from UAV Images Using a YOLO Algorithm. *Sensors* **2022**, *22*, 6611. <https://doi.org/10.3390/s22176611>

Academic Editors: Sylvain Girard, Marios Antonakakis and Michalis Zervakis

Received: 2 July 2022

Accepted: 29 August 2022

Published: 1 September 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

In recent years, a rapid development of investment areas in large cities has been witnessed. This involves intensive construction works of new objects. Such works often require the use of additional equipment, such as cranes, lifting cranes, etc., whose position and height are often of great importance, especially if the works are conducted in the direct vicinity of an airport. In such an event, these objects become temporary aviation obstacles. Accurate data indicating the location and height of this type of obstacles are necessary to ensure safety in the air space. Information about temporary aviation obstacles is provided in the NOTAM (Notice to Airmen) announcements and is delivered by the air traffic controller who supervises the security of the aviation operations. The emergence of an aviation obstacle of temporary nature is the main factor that may generate risk in the direct proximity of the airport. The area where the obstacle is located must be constantly monitored by the airport manager [1]. However, temporary aviation obstacles are not the only elements that pose a threat to air traffic safety. Permanent obstacles situated in the vicinity of an airport also carry a risk and require flight procedures that will take into account the elevation of such obstacles to be developed. There are certain recommendations concerning the methods of obtaining data about obstacles, where an emphasis is placed on the automation of processes for the purposes of collecting large sets of data. Still, although the requirements and techniques for obtaining data about aviation obstacles have been systematised, the automation of the mechanisms used to obtain data about elongated obstacles, such as antennas, masts, etc., is still being developed [1]. In order to capture very thin objects, a larger image scale than one used for traditional exploratory flights is required. This, in turn, requires lower altitudes. The techniques used so far for aviation obstacle detection have been based on the use of point clouds from airborne laser scanning (ALS). These techniques have several drawbacks. To begin with, missing an

elongated obstacle is impossible [1]. Secondly, the object detection control is performed with the use of traditional ground measurements, which extend the entire process and eliminate the possibility of its automation. Furthermore, to ensure safety in the airspace, it is necessary to maintain the obstacle data, updating it regularly. Finally, the airborne laser scanning does not provide a high time resolution of data acquisition. According to the latest provisions of the Eurocontrol [1] manual, the detection of obstructions of an elongated shape should be provided at a much larger image scale than that obtained in the case of traditional photogrammetric flights. This is possible with a lower flight altitude obtained with UAV flights. At a lower flight altitude, the obtained spatial accuracy (X, Y, Z) will be the highest. Updating information about aviation obstacles involves obtaining and processing large amounts of data. As a result, the process of obtaining and processing these data must be automated. Currently, the process of reporting temporary aviation obstacles takes a long time and often requires traditional, time-consuming geodetic measurements. The automation of the process of obtaining data about temporary aviation obstacles and ensuring the required accuracy levels for coordinates X, Y, Z of the obstacle pose a new challenge in the research on obtaining data, which has been reliable so far.

The authors of this paper presented an innovative methodology for the automatic detection and classification of elongated aviation obstacles based on data obtained from unmanned aerial vehicles. The novelty of their approach consists of the fusion of the YOLOv3 algorithm operating with the use of neural networks extracting features from the image for the detection of atypical aviation obstacles. The authors also proposed and used a new algorithm for obstacle classification, which is based on a dense point cloud for the estimation of the height of these obstacles.

2. Related Works

Currently, aerial photogrammetry is the most efficient technique of collecting data about obstacles, although it involves less automation than other techniques, such as ALS (airborne laser scanning). The binding requirements for detecting atypical aviation obstacles, which usually are “thin” objects of an elongated shape, require lower altitude of flight than those applied in traditional aerial photogrammetry [1]. Achieving a lower flight altitude becomes possible thanks to the use of unmanned aerial vehicles (UAVs). At lower altitudes, the spatial accuracy (X, Y, Z) of temporary obstacles is much higher. Apart from the altitude of flight, the temporal resolution of obtaining data as well as the availability and low operating costs offer an attractive alternative for traditional tele-detection platforms [2–6]. UAVs, which are used increasingly often, provide digital images that are used to create dense point clouds to describe 3D objects [7]. This creates new possibilities of object classification based on point clouds combined with the use of the properties that are present in the images from the data obtained by UAVs [8]. However, there is an emerging need to develop the automation of the processes in order to address the challenge of detecting atypical aviation obstacles of elongated shapes where the correct detection is only possible at such a low altitude of flight that can be ensured by a UAV.

2.1. Object Classification Based on RGB Imagery

Extracting objects from high-resolution images obtained by UAVs plays an important role in geospatial applications, including urban planning, telecommunications, disaster monitoring, navigation, updating geographic databases, and dynamic monitoring of cities. Automated extraction of objects is a challenging task, as the objects in various regions have different spectral and geometric properties. As a result, classic image processing techniques are insufficient for automated extraction of objects from high-resolution data. The deep learning and semantic segmentation models, which have become popular in recent years, are used to extract objects from high-resolution images in an automated way. However, the effective classification, detection, and segmentation of various objects in remote sensing images also poses a challenge for scientists due to various factors, such as the appearance of the object, various backgrounds, and environmental conditions. In

general, image segmentation is a process that enables labelling pixels in the input image, so that the pixels in the same region/area or object are correlated with the same class label. It helps to determine whether the given UAV image contains one or more objects that belong to the category of interest and locate any predicted position of the object in the image.

Object detection based on deep learning may be divided into two categories: two-stage and single-stage detection. The RCNN (Region Based Convolutional Neural Networks) (RCNN [9], Fast RCNN [10], and Faster RCNN [11]) series are a two-step algorithm, whose accuracy highly exceeds that of many other detection algorithms. However, this type of approach requires higher computational costs, which extends the processing time. In the single-stage category, one may distinguish the SSD (Single Shot MultiBox Detector) [12,13] and the YOLO (You Only Look Once) algorithm proposed by Joseph Redmon and Ross Girshick [14]. YOLO solves the detection of objects like a regression problem and displays the position and classification of the object in an end-to-end network within a single step. Due to the detection speed, it is currently one of the most commonly used algorithms. The YOLO algorithm is being constantly improved due to the significant errors emerging in the accuracy of the detection of small objects. The version that deserves attention is YOLOv3, which applies the method of grouping K-averages in order to automatically select the best initial regression frame for the dataset. The multi-scale anchor mechanism [15] is adapted to improve the accuracy of detecting small objects.

Anguelov et al., presented in the work by Liu, D., proposed an SSD algorithm that uses the regression method for detection, integrates the positioning, and classifies it within a single network. The SSD was modified into VGG16 [16], to replace the fully integrated VGG16 layer with a convolutional layer.

As opposed to other methods, the deep learning methods are capable of distinguishing the low and high-level properties automatically [17,18]. Such deep learning methods as the Convolutional Neural Networks (CNNs) use convolutions to distinguish features automatically. In 2014, pixel-based classification was enabled as a result of adapting the CNNs model to a fully convolutional neural network [19]. Since then, deep learning methods have often been used in research on semantic segmentation and object extraction [20]. In recent years, research with the use of deep learning methods has been conducted in various areas of remote sensing, including pre-processing of images [21], detecting objects [22], pixel-based classification [23], and scene understanding [24]. Various research projects on automated object extraction have also been conducted. Yang et al. [25] proposed a new network dependent on DenseNets networks and the attention mechanism for the rational use of functions at various levels. X. Li et al. [26] designed a new deep opponent network named Building-A-Nets, which uses the opponent's structure as a solid segmentation of the roofs of buildings. L. Li et al. [27] presented a new model of CNNs called a Multiple-Feature Reuse Network (MFRN) in order to reduce the requirements for GPU memory. Lu et al. [28] used richer convolutional features (RCFs) to detect edges of objects based on remote sensing images with high spatial resolution. Bittner et al. [29] developed a fully convolutional network (FCN), which effectively combines high-resolution images with normalised DSM and automatically generates prognoses for the objects. Xu et al. [30] extracted objects from high-resolution remote sensing images with use of the Res-U-Net deep learning architecture and directed filters. Boonpook et al. [31] applied the SegNet deep learning architecture to build extraction from very high-resolution imagery from unmanned aerial vehicles (UAVs). H. Liu et al. [32] proposed a fully convolutional network (DE-Net) that was created to store information with the use of network calculations, especially in down-sampling, encoding, and up-sampling procedures.

2.2. Research Purpose

This study attempts to verify the following research hypothesis: the detection of atypical aviation obstacles with the use of a deep neural network whose structure is based on the YOLO architecture, introducing a new algorithm for the classification of point clouds, which is adapted to the geometrical features of atypical aviation obstacles and

the criterion for the filtration of a point cloud obtained from a low altitude enabling the detection of aviation obstacles with an accuracy that meets the requirements of ICAO regulations [33–36].

The aim of the research was to develop a methodology for the automated detection and classification of atypical aviation obstacles based on the data obtained from unmanned aerial vehicles.

The paper is structured as follows: in Section 3, the research method is explained. Section 4 presents test data and the experiment results. In Section 5, the results are discussed. Finally, Section 6 provides a brief summary of this work.

3. Methods

This section describes the methodology of detecting atypical aviation obstacles based on data obtained from UAVs. The whole process is presented in the block diagram below (Figure 1). The diagram illustrates the essential stages of the developed methodology of detecting atypical aviation obstacles. The first stage consisted in obtaining the photos from the unmanned aerial vehicle. The next step was photogrammetric processing in Pix4D. As a result, a point cloud and an orthophotomap were obtained. They were then the basis for further analyses. The orthophotomap was used to detect obstacles in the image with the use of the YOLO algorithm, which is based on a convolutional neural network (CNN) [14]. The objects detected in the orthophotomap were the basis for the determination of the x, y coordinates of the centroid C_i for each atypical obstacle. The previously generated point cloud was then used to determine the height of the obstacles. Based on the x, y coordinates of the objects that were determined with the use of the YOLO algorithm, these coordinates were defined in the point cloud. As a result, the search area in the point cloud was narrowed. Later, areas for collecting data about obstacles were generated and used to determine which of the detected objects penetrate through the surface of the areas and thus become aviation obstacles [37]. A new algorithm was used to determine the height of atypical aviation obstacles based on the point cloud. It assumed an iterative search of the point cloud in reference to the determined centroid in order to determine the height H_{max} . The accuracy of the developed method was analysed based on the conducted experiments and data about aviation obstacles contained in the Aeronautical Information Publication (AIP), in the supplements that contain information about temporary aviation obstacles in the vicinity of airports. Both the horizontal coordinates x, y and the vertical H coordinate were analysed.

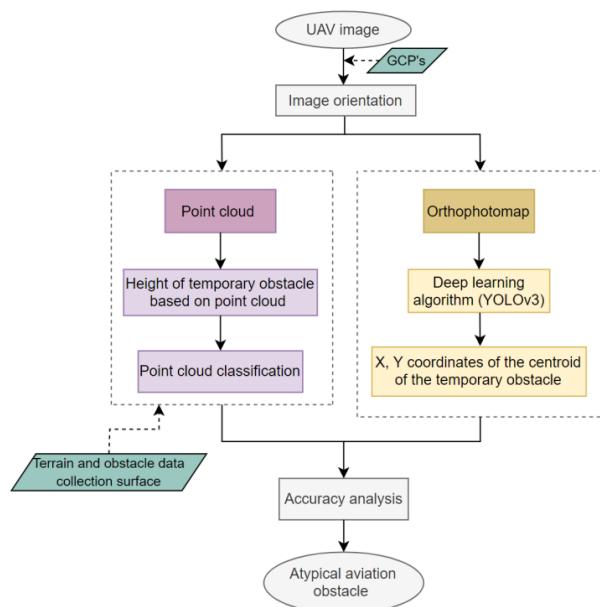


Figure 1. The scheme of detection of the atypical aviation obstacles.

3.1. Detection of Atypical Aviation Obstacles Using YOLOv3

The detection of atypical aviation obstacles based on image analysis was performed with use of the YOLOv3 algorithm. The general course of detecting objects in an image is presented in Figure 2. Data obtained from UAVs were subjected to photogrammetric processing. As a result, an orthophotomap was obtained. This orthophotomap then became the source of data for creating a set of data about atypical aviation obstacles. The objects in the image were enclosed in envelopes. After the YOLO network was optimised and trained on the developed datasets, the effectiveness of detection was checked. Finally, the best model of selecting atypical aviation obstacles in an orthophotomap was selected.

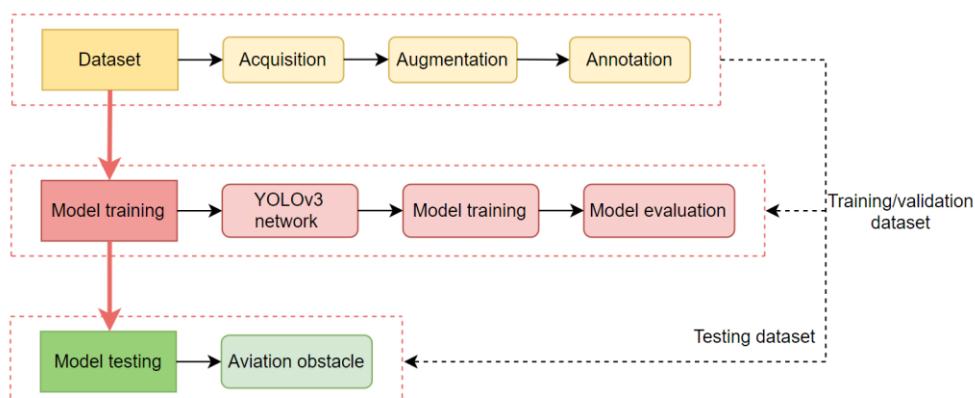


Figure 2. Overall architecture of the proposed methodology.

The YOLOv3 algorithm employs convolutional neural networks for the detection of objects. Neural networks separate the features from images by layers of the convolution and use the fully connected layers to predict the probability of output and information about the position of the limiting rectangle. The main advantage of the algorithm as a single-stage approach is the fact that the whole image is assessed by a single neural network. It generates all prognoses based on the actual image, instead of the proposed regions, as it is done in two-stage methods. The input image is represented as a tensor of the dimensions $n \times m \times 3$, where n and m refer to the width and height in pixels, and 3 refers to three colour channels. The YOLOv3 algorithm was created based on the YOLOv2 algorithm, which had a relatively low accuracy of detecting small objects. Due to that, certain improvements were introduced, resulting in the new version of the algorithm: YOLOv3. Firstly, the algorithm performs classification with numerous labels [38], where independent logistic classifiers are used instead of the softmax classifier to predict classes with multiple labels. In the learning phase, YOLOv3 uses binary cross-entropy loss instead of the general mean square error to predict classes. A different bounding box prediction was presented in the work of Al-Saffar et al. [39], where the objectness score is set to 1 if the bounding box prior overlaps a ground truth object more than others. However, if the bounding box prior overlaps a ground truth object by more than a chosen threshold, the prediction is ignored. Therefore, YOLOv3 has only one bounding box anchor for each ground truth object. The work of Y. Li et al. [40] presented predictions across scale, where YOLOv3 can predict boxes on three different scales and then extracts features from those scales using feature pyramid networks.

The YOLO algorithm is an end-to-end network, so the whole process uses the method of calculating loss which is referred to as the sum-squared error [41]. It is a simple sum of the differences, including coordinate errors, IoU (Intersection-over-Union) errors, and classification errors. YOLOv3 uses the Darknet-53 convolutional skeleton that consists of 53 convolutional layers, where it uniformly samples the input image to the dimensions 416×416 and assumes that the image is divided into 3×3 grids.

3.2. Determination of the Centroid of an Atypical Aviation Obstacle

Detecting the temporary aviation obstacles with use of the YOLOv3 algorithm allowed for the determination of the x, y coordinates of the centroid C_i of each obstacle. The determination of centroid C for the obstacle, whose cross-section was a non-intersecting polygon defined by N vertices $(x_0, y_0), (x_1, y_1), \dots, (x_{n-1}, y_{n-1})$ at the point (Cx, Cy) , was calculated using the following formula:

$$C_x = \frac{1}{6A} \sum_{i=0}^{n-1} (x_i + x_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (1)$$

$$C_y = \frac{1}{6A} \sum_{i=0}^{n-1} (y_i + y_{i+1})(x_i y_{i+1} - x_{i+1} y_i) \quad (2)$$

where A is the signature area of the polygon

$$A = \frac{1}{2} \sum_{i=0}^{n-1} (x_i - x_{i+1} y_i) \quad (3)$$

The x, y coordinates of the C_i centroid of the obstacles, whose cross-section is an ellipse with extremes A_i, B_i of known x, y coordinates, were calculated using the following formula:

$$C = \left(\frac{x_A + x_B}{2}, \frac{y_A + y_B}{2} \right) \quad (4)$$

where: x_A, y_A are coordinates of the extreme point of ellipse A , and x_B, y_B are coordinates of the extreme point of ellipse B .

The determination of the coordinates of the centroid of each detected obstacle was essential for the subsequent stage of analysis, i.e., determining the heights of the aviation obstacles.

3.3. Estimation of Height of Temporary Aviation Obstacle

The determination of the H_{max} height of an atypical obstacle consisted in an interactive search of the point cloud with the aim to detect the highest point that belonged to the analysed object. The subjects of the analysis were atypical aviation obstacles, which include, among others, construction cranes, wind turbines, energy poles, and masts. In order to define the height of a construction crane, data about the centroid of obstacle C (x, y) were used and the maximum radius r of the crane boom reach was determined (Figure 3).

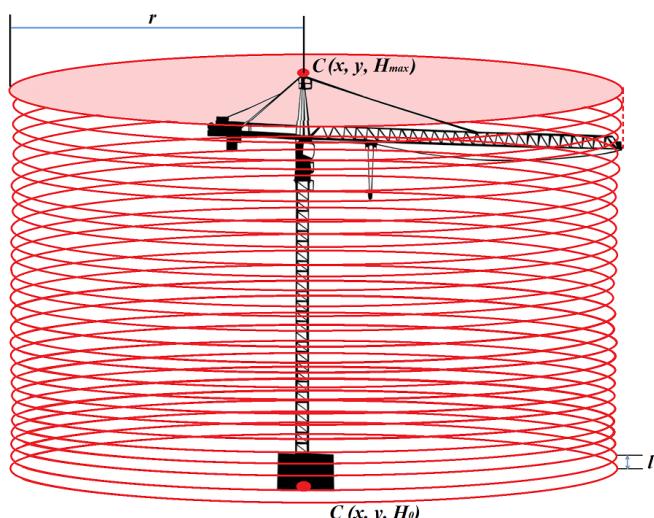


Figure 3. Determination of the centroid of the detected obstacle.

The maximum value of the r radius was calculated using the data that define the technical parameters of this type of objects. According to the assumptions, the maximum value of the r radius is 90 m.

The first stage of searching the point cloud consisted in the determination of the initial height H_0 in the point cloud. For the centroid C of the obstacle, of the known coordinates x , y , the S_i plane with the r radius was defined:

$$(x - a)^2 + (y - b)^2 = r^2 \quad (5)$$

The realisation of the algorithm (iteration $i = 1$) started with searching the S_i plane for the height H_0 . The found point A of the point cloud belonged to the dataset B of the point cloud of the temporary obstacle. The next stage ($i = 2$) was conducted at the distance $l = H_0 + 10$ cm. Each subsequent iteration was performed for the S_i plane situated 10 cm above the preceding one. The height search was continued until the last point belonging to the set of point cloud B was found.

$$H_{max} \rightarrow A \in B, B \geq 1 \quad (6)$$

The height of other types of obstacles (wind turbines, energy poles, and masts) was determined in a similar way as the height of the construction crane. The x , y coordinates of the C centroid of the obstacle and the radius r of the reach of the analysed obstacle were used (Figure 4). The value of the r radius was defined based on the maximum technical parameters of the given type of object. In the subsequent step, the iterative search of the point cloud was performed with the aim to determine the height of the obstacles H_{max} .

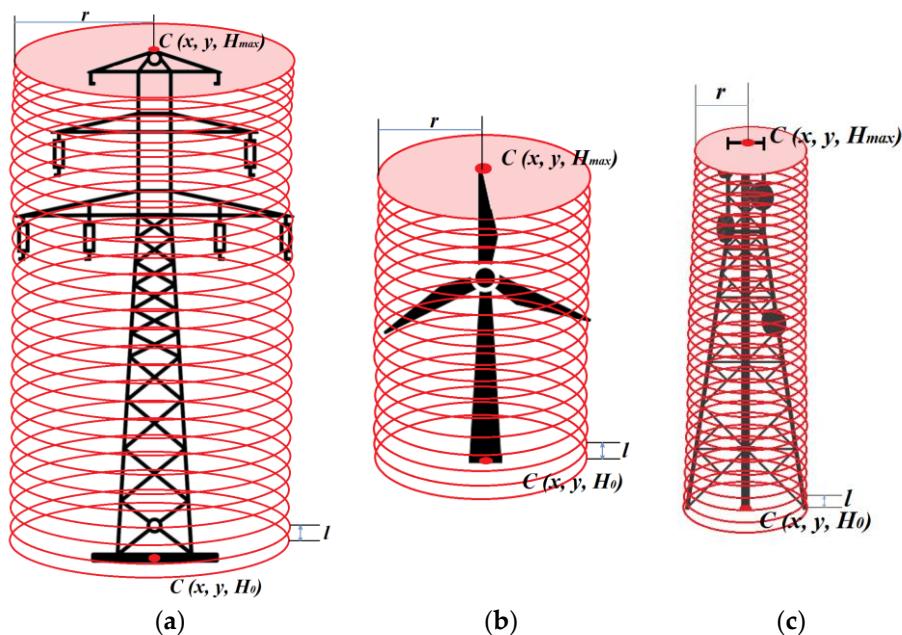


Figure 4. Determination of the height of the detected obstacle: (a) energy pole, (b) wind turbine, (c) mast.

3.4. Classification of Point Cloud

The aim of the classification of point cloud was to detect aviation obstacles that belong to the group of atypical obstacles. The course of the classification procedure is presented in the diagram below (Figure 5). It was assumed that the characteristic features that define atypical obstacles are their elongated shape and irregular cross-section. The first adopted classification criterion was the height of the objects which was determined based on the point cloud. The second criterion was based on the distribution of the points in the point cloud in relation to the centroid C_i of the analysed object.

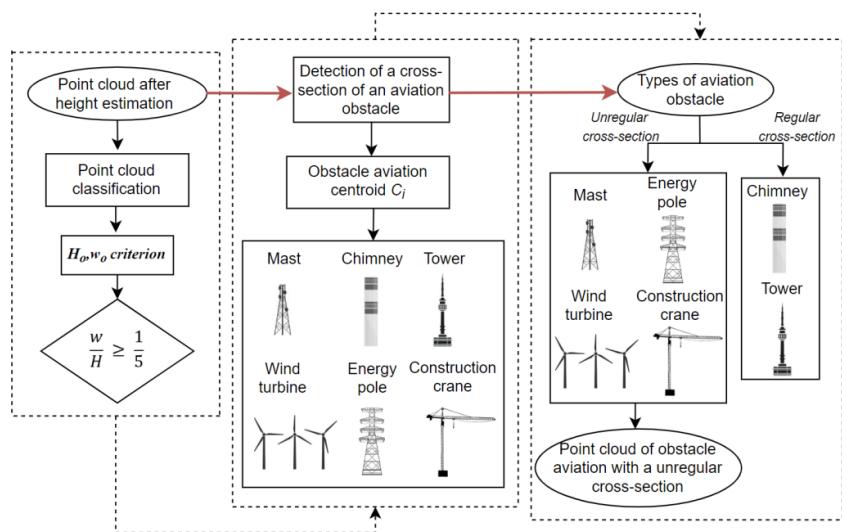


Figure 5. Scheme of classification of point cloud.

It was assumed that for objects belonging to the group of elongated obstacles, the ratio of the width w of the object to its height H [42] should meet the following condition:

$$\frac{w}{H} \geq \frac{1}{5} \quad (7)$$

where: w is the width of the obstacle and H is the height of the obstacle.

The ranges of obstacle classification considering their width and height were defined with a confidence interval of 68%.

Then, the point clouds assigned to the relevant groups of obstacles were classified taking into account their cross-section, where the characteristics of the distribution of points in the point cloud in relation to the centroid C_i were analysed. To this end, an iterative search of the point cloud was conducted in belts p_i of a fixed width m (Figure 6a). The position of the points of the point cloud in p_i belts was calculated based on the determined distance d_i of the points in the cloud from the centroid C_i (Figure 6b), using the following formula:

$$d_i = \sqrt{(x_C - x_i)^2 + (y_C - y_i)^2} \quad (8)$$

where: x_c is the coordinate x of the centroid [m], y_s is the coordinate y of the centroid [m], x_i is the coordinate x of the point in the point cloud [m], and y_i is the coordinate y of the point in the point cloud [m].

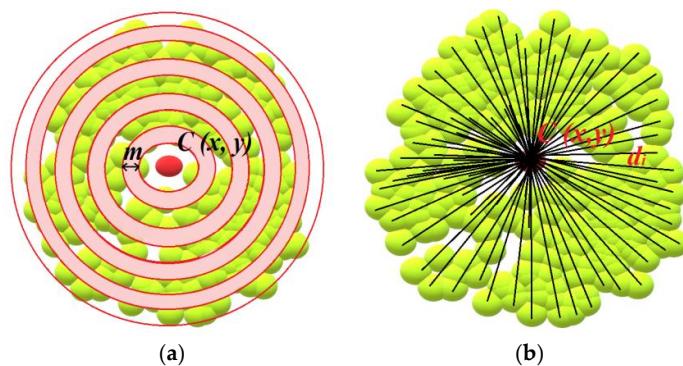


Figure 6. Analysis of the distribution of the points in the point cloud in relation to centroid C_i : (a) Searching the point cloud in belts p_i of a fixed width m ; (b) The determination of the position of the points of the point cloud in p_i belts based on the determined distance d_i of the points in the cloud from the centroid C_i .

The maximum number of iterations and searches of the point cloud was calculated based on the ratio between the maximum distance d_{max} of the point in the point cloud from centroid C_i to the width m of the p_i belt, using the following formula:

$$i_{max} = \frac{d_{max}}{m} \quad (9)$$

4. Materials and Experimental Results

4.1. Study Area

The research was conducted at two test sites, located in the direct vicinity of the Łask military airport (ICAO code: EPLK) and the Radom–Sadków airport (ICAO code: EPRA) (Figure 7). The Łask airport (ARP: 51°33'04" N; 019°10'57" E) is situated in central Poland, while the Radom–Sadków airport (ARP: 51°23'20" N; 021°12'42" E) is located east of the Łask airport.

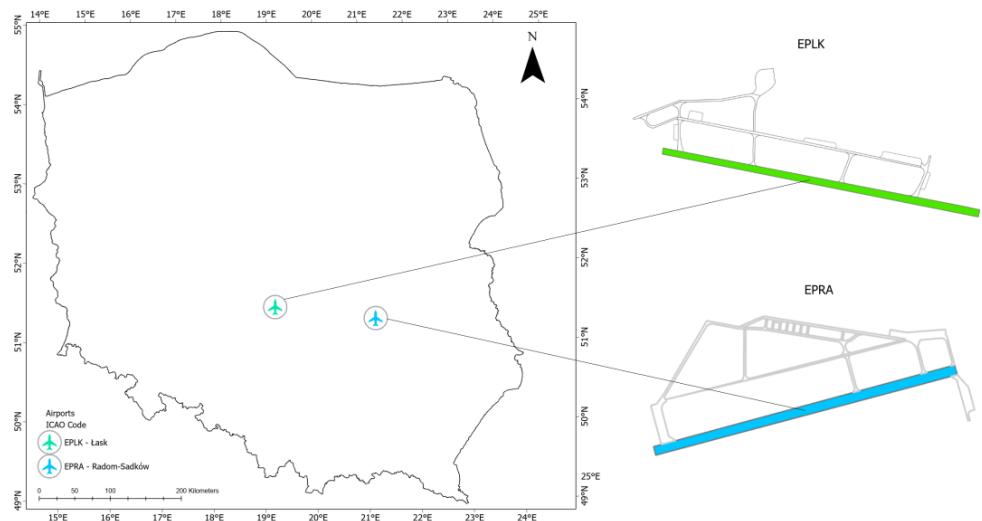


Figure 7. Location of the research areas.

4.2. Description of Data Sets

4.2.1. EPLK

The source data for the generation of the dense point cloud was obtained using the Trimble UX-5 airframe, equipped with a Sony a7R camera. The aerial platform was equipped with a single-frequency GPS receiver, recording data at the frequency of 10 Hz.

Flights were conducted in two test areas in April 2019. The photographic conditions were good, i.e., the sky was covered with a small amount of cumulus clouds, and the average wind velocity was approximately 2 m/s. Camera settings were defined in the manual mode, while the focus of the lens was set to infinity. The first and the second test sites were the areas surrounding the Łask military airport. The measurement campaign consisted of 15 test blocks, where each block contained about 600 images. The data were obtained at the altitude of approx. 250 m above the ground level. Flights were performed in the East–West direction, based on the assumption that the longitudinal and transverse coverage was approx. 75%. The signalled photopoints were designed and measured in the test area. All the points were measured with use of the RTK technique in the GNSS system. The terrain coordinates of the photopoints were determined with the mean error of $m_{x,y,z} = \pm 0.03$ m. The first area contained six photopoints and eight independent control points, while for the second the numbers were, respectively, six and seven. The ground sampling distance (GSD) was 0.04 m.

4.2.2. EPRA

The source data for aerotriangulation was obtained using the VTOL WingtraOne system, equipped with a Sony RX1R II camera. The aerial platform was equipped with a single-frequency GPS receiver, recording data at the frequency of 10 Hz. As part of the research analysis, the GNSS data recorded by an AsteRx-m2 UAS receiver placed on the Tailsitter unmanned platform was used. The flight was carried out in the two research areas in June 2021. The imaging conditions were good. The first and the second research area covered the area around the Radom–Sadków airport. Fourteen test blocks were realised during the flight, and each of them contained almost 600 images. The data were obtained at the altitude of 250 m above the ground level. The flight was conducted in the East–West direction, assuming that the transverse and longitudinal coverage was 75%. The signalled photopoints were designed and measured with use of the RTK technique in the GNSS system in the test area. The terrain coordinates of the control points were determined with the mean error $m_{x,y,z} = \pm 0.03$ m. The first area contained six photopoints and seven independent control points, while for the second the numbers were, respectively, four and seven. The ground sampling distance (GSD) was 0.04 m.

4.3. Atypical Aviation Obstacles

Objects that may pose a threat to aerial vehicles due to their dimensions are referred to as aviation obstacles. Apart from permanent objects such as buildings or terrain elevations, aviation obstacles may also be fixed objects of a temporary nature, or mobile objects (e.g., construction cranes), which are called temporary aviation obstacles. Obstacles whose height exceeds the limiting planes, are considered to be objects that may pose a threat in the aviation space. Temporary objects, such as construction cranes, are slender structures, and their atypical shape makes it more difficult to determine their height. Permanent obstacles may also have the form of elongated or slender objects, which include, among others: masts, wind turbines, chimneys, and energy poles (Table 1).

Table 1. Atypical aviation obstacles.

Type of Aviation Obstacle
Mast
Wind turbine
Chimney
Tower
Energy pole
Construction crane

The diagram shows five icons representing different types of atypical aviation obstacles. From top to bottom: 1. Mast: A tall vertical tower with a small crossbar at the top. 2. Wind turbine: Two blades on a vertical tower. 3. Chimney: A tall, narrow, cylindrical structure. 4. Tower: A tall, multi-tiered tower with a small crossbar at the top. 5. Energy pole: A tall, multi-tiered tower with a horizontal arm extending from the side at the top.

4.4. Surfaces of Obtaining Data about Obstacles

Ensuring safety in the aviation space is a very complex process. Some of its numerous elements include creating aviation maps, designing procedures, etc. The basis for creating aviation materials is obtaining and collecting data about aviation obstacles.

As a result of the need to gather and store such data, the following coverage areas are distinguished: 1, 2 (2a, 2b, 2c, 2d). Area 2a is a rectangular area around the runway that includes the runway itself and the abandoned take-off security area, if it exists. Area 2b is the area that stretches from the end of area 2a in the direction of take-off, 10 km long

and opening at an angle of 15% to each side. The inclination of this area is 1.2%. Area 2c stretches outside areas 2a and 2b to a maximum of 10 km from the border of area 2a. Its surface has an inclination of 1.2%. Finally, area 2d is an area located outside areas 2a, 2b, and 2c, which reaches up to 45 km from the reference point of the airport or to the existing TMA border; whichever is closer [37].

Collecting data on obstacles in areas 2a and 2b (Figure 8) is directly related to ensuring safety in the airspace during the critical phases of the aircraft's flight, i.e., take-off and landing. Therefore, it is necessary to update the data on obstacles in these areas on an ongoing basis.



Figure 8. Obstacle data collection surfaces—Area 2a and area 2b (side profile view).

Areas 2b and 2c are inclined planes that rise starting from area 2a. These areas determine the threshold altitudes for collecting data about aviation obstacles. The most important data about the obstacles are their horizontal location, height, and type of obstacle.

4.5. Experimental Results

The experiments were conducted in two test areas located in the vicinity of the Łask airport (EPLK) and two test areas near the Radom–Sadków airport (EPRA). Tests were conducted on data obtained from UAVs during four photogrammetric flights. Two of them took place in the direct vicinity of the Łask airport (Figure 9) and the other two near the Radom–Sadków airport (Figure 10). The test areas were selected based on two criteria: the first one assumed that the study area should match the 2b area, i.e., the area of collecting data about terrain and obstacles. The second criterion was the existence of tall objects that might interfere with safety in the aviation space. The test areas were selected so as to gather the largest possible amount of data.

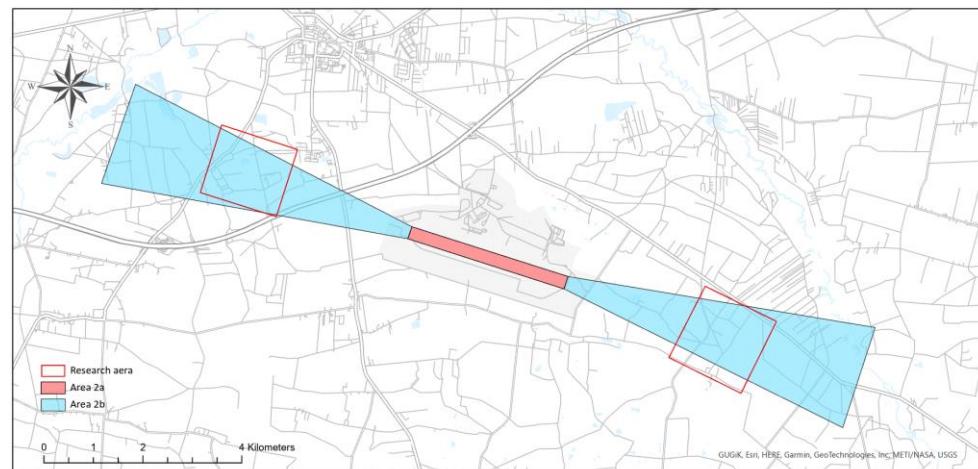


Figure 9. Test areas—Łask airport.

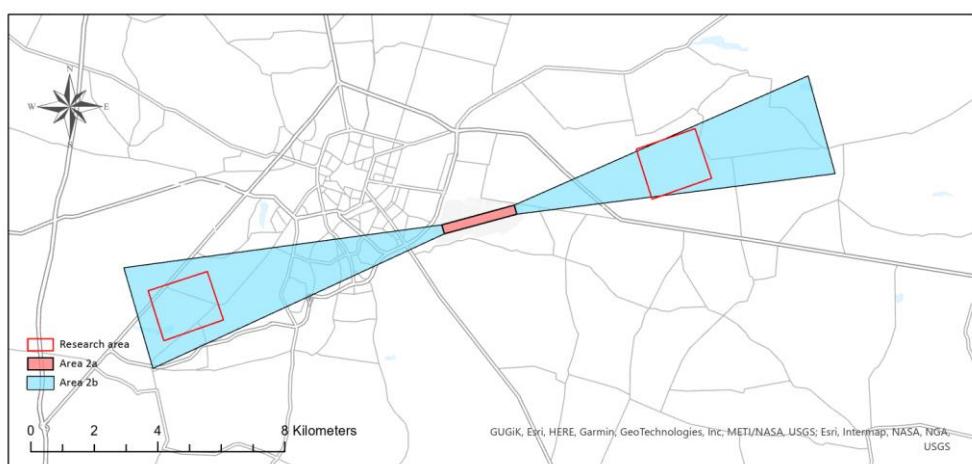


Figure 10. Test areas—Radom–Sadków airport.

At the first stage, images were obtained from the UAVs and then processed in specialist Pix4D software. During the photogrammetric data processing, a dense point cloud was generated, which was later used to determine the height of atypical aviation obstacles. Apart from that, an orthophotomap was created and used to detect atypical aviation obstacles with use of the YOLOv3 algorithm and to define their location. The detection of atypical aviation obstacles started with the analysis of the orthophotomap. To this end, artificial neural networks were used to separate the features from the images. The C_i centroids were defined for each detected object. The data about the location of atypical aviation obstacles obtained in this way made it possible to find these objects in the point cloud and were the starting point for further analyses of the point cloud.

4.6. Detecting Atypical Aviation Obstacles in the Orthophotomap

At this stage, the YOLOv3 algorithm based on convolutional neural networks was used to detect atypical aviation obstacles. Artificial neural networks separate the features from the images by layers of the convolution and use the fully connected layers to predict the probability of output and information about the position of the limiting rectangle.

Although several trained YOLO networks containing some known datasets exist, the neural network still requires training to improve its precision in working with such specific objects as atypical aviation obstacles.

The model was trained with the use of Google Colab. A notebook based on YOLOv3 that employs trained Darknet-53 weights was used. A set of data for atypical aviation obstacles was added to the notebook. The training parameters recommended by the authors of the solution were used for network training purposes. Additionally, the training consisted of 400 epochs, which took approx. 120 min.

The network was trained for four classes of objects: construction crane, energy pole, wind turbine, and mast. This resulted in the size of the first scale output tensor of $13 \times 13 \times 16$.

Non-standard image databases containing objects from the following classes: construction crane, energy pole, wind turbine, and mast were prepared based on the orthophotomaps being a part of the digital database for Poland created by the National Geodetic and Cartographic Resource (PZGiK). Orthophotomaps in the standard $0.10 \text{ m} \times 0.10 \text{ m}$ were used for tests. The database for the wind turbine class of elevators was enriched with a publicly accessible database [43].

Most of the images used contained more than one object for the three classes: construction crane, energy pole, and wind turbine. On the other hand, in the mast class, a majority of the images contained single objects representative of the class. Objects from all classes were fully placed inside boxes. Images, where only a part of the object was visible, were excluded from the training set or the object was not marked as belonging to a specific class.

The research experiment was conducted on 800 images that contained a total of 1023 objects. The images were randomly divided into three sets of data: training data (70% images) used to estimate the weights of the artificial neural network, validation data (20% images) used to test the trained network, and test data (10% images) used to test the functioning of the network after training. The set of training data consisted of 560 images that contained a total of 716 objects, the validation data set consisted of 160 images containing a total of 205 objects, while the test data set consisted of 80 images containing a total of 102 objects. The full distribution of the data set is presented in the table below (Table 2).

Table 2. Contents of the data set.

Data Set	Category	Number of Images	Number of Objects
Training set	Construction crane	143	184
	Energy pole	141	196
	Wind turbine	140	188
Validation set	Mast	136	148
	Construction crane	44	52
	Energy pole	39	63
	Wind turbine	41	49
Test set	Mast	36	41
	Construction crane	22	27
	Energy pole	19	30
	Wind turbine	21	26
	Mast	18	19

The results of the detection of atypical aviation obstacles on the data from the test dataset are presented in Figure 11a–d. A sample limiting box for the construction crane class, in green, is presented in Figure 11a,d. A sample limiting box for the energy pole class, in pink, is presented in Figure 11b,c. A sample limiting box for the wind turbine class, in beige, is presented in Figure 11b,c. A sample limiting box for the mast class, in magenta, is presented in Figure 11d.



Figure 11. Cont.



Figure 11. Sample detection (fragment of orthophotomap): (a) construction cranes; (b) wind turbines and energy poles; (c) wind turbines and energy poles; (d) construction crane and mast.

The detection of atypical aviation obstacles in the orthophotomap allowed for the determination of the centroid $C(x, y)$ for each detected object. Data about the location of aviation obstacles obtained in this way enabled research conduction on the point cloud.

4.7. Accuracy Evaluation of YOLOv3 Algorithm

The indicators used to assess the accuracy of the detected aviation obstacles are average precision (AP) and mean average precision (mAP). AP defines the proportion of the correct detections to the sum of the correct detections (i.e., the correct determination of the location and classification) and false detections of objects. A high value of the AP coefficient means that there are few false predictions. The mAP coefficient is used to measure the average accuracy of detection of multiple types of objects. The higher the mAP , the more comprehensive the model is in all categories. Average precision and mean average precision are calculated using the formula below [44]:

$$AP = \sum_{k=1}^N Precision(k) \Delta Recall(k) \quad (10)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (11)$$

where: AP_i is the average accuracy of class i , and N is the number of classes.

During the measurement of mAP , the efficiency of both the classification and the positioning with the use of limiting frames in the image are assessed. The mAP formula is based on Confusion Matrix, Intersection over Union (IoU), and Recall and Precision.

Objects are detected based on the Intersection over Union (IoU) concept [45,46]. IoU measures the overlapping of two borders and is used to estimate the extent to which the predicted border overlaps with the actual border of the object. The IoU value is a measure of the accuracy of the determination of the position and size of the object. The measure is calculated based on the actual frame of the object and the frame returned by the artificial neural network. It is defined as the ratio of the product (intersection of the boxes) to their sum.

Based on the data in Table 3, it was found that the value of the IoU index for the construction crane class was 69.4%, for the energy pole it was 78.2%, for the wind turbine class it was 74.2%, and, finally, for the mast class it was 64.9%. These results demonstrate

that the accuracy of the positioning and location was better for objects belonging to the energy pole and wind turbine classes. However, the IoU index for the construction crane and mast classes was slightly lower. The value of the average precision (*AP*) for the construction crane category was 74.8%, for the energy pole class it was 67.6%, for the wind turbine class it was 65.2%, and for the mast class 75.3%. A high value of the *AP* coefficient means that few false predictions were obtained. The *mAP* value of the applied YOLOv3 algorithm reached the value of 70.7%. Such relatively high value of *mAP* confirms that the model is comprehensive and that this algorithm may be used to detect atypical aviation obstacles.

Table 3. Accuracy of test results in various categories.

Category	IoU (%)	AP (%)	<i>mAP</i> (%)
Construction crane	69.4	74.8	
Energy pole	78.2	67.6	
Wind turbine	74.6	65.2	70.7
Mast	64.9	75.3	

One may distinguish three different types of loss: box loss, objectness loss, and classification loss. The box loss shows how well the algorithm is able to locate the centre of the object and how well the predicted bounding box covers the object, while objectness is, in general, a measure of the likelihood of the presence of the object in the proposed area of interest. Finally, the classification loss provides an idea of how well the algorithm can predict whether the given object belongs to a class. The curves of loss of the applied YOLOv3 algorithm for 400 epochs are presented in Figure 12a–h. For the training data, the box loss and objectness loss diagrams show high fluctuations for the first half of the epochs. After approx. 200 epochs, the curve stabilises. The classification loss curve flattens after about 50 epochs. For validation data, the box loss curve begins to stabilise after 200 epochs, while the objectness loss curve stabilises after about 50 epochs. The course of the classification loss curve for validation data is very dynamic in the initial epochs. Then, it stabilises after approx. 200 epochs. Based on these curves, it was found that the loss of the model decreases gradually with the increase in the number of epochs. Recall and precision curves (Figure 12d,e) stabilise after 200 epochs and demonstrate that the model is reliable. The *mAP* diagram for $\text{IoU} = 0.5$ (Figure 12i) shows that the model stabilises after 200 epochs, giving a high *mAP* index. The dynamics of the course of the *mAP* curve for $\text{IoU} = 0.5\text{--}0.95$ (Figure 12j) is similar. However, in this case the value of the *mAP* index is lower.

Based on the obtained results, it was found that the *mAP* index achieved higher values for lower values of the IoU (Figure 12i), which means that the boxes are not perfectly matched to the dimensions of the objects. The system obtained poorer results for small objects that belonged to the mast class and for objects of an elongated shape in the image which belonged to the construction crane category. This was an expected result, as one of the characteristic properties of the YOLO network is fast operating speed, but at the expense of a slightly worse detection of small objects. Additionally, it was noted that the efficiency of the network was lower for objects from the classes mentioned above, which were mostly situated in densely developed areas. Slightly lower values of the *mAP* index were achieved for higher values of IoU. In this group, obstacles belonging to the energy pole and wind turbine classes were detected. It was noted that a high value of the *mAP* index confirms that the model is comprehensive and that this algorithm may be used to detect atypical aviation obstacles.

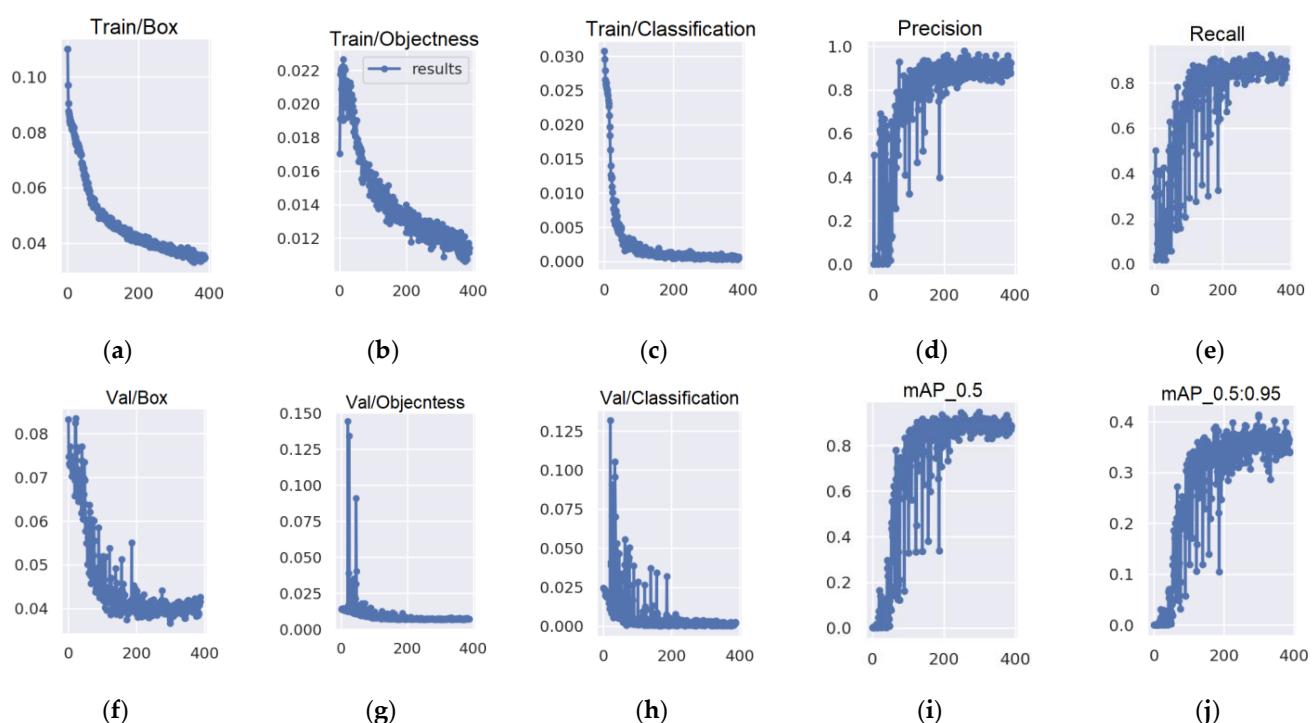


Figure 12. Accuracy evaluation curves: (a) Box loss function in the training process; (b) Objectness loss function in the training process; (c) Classification loss function in the training process; (d) Precision; (e) Recall; (f) Box loss function in the validation process; (g) Objectness loss function in the validation process; (h) Classification loss function in the validation process; (i) mAP when IoU is set to 0.5; (j) mAP when IoU is set from 0.5 to 0.95.

4.8. Detection of Atypical Aviation Obstacles Based on Point Cloud

Atypical aviation obstacles were classified based on the point cloud. It was assumed that such atypical obstacles are characterised by a slender, elongated shape, and an irregular cross-section. These characteristics were the basis for the determination of the classification criteria of atypical aviation obstacles. The first criterion was the height of the analysed objects, which was determined based on the point cloud. The second criterion was the geometric properties of the point cloud in transverse cross-section in reference to the defined centroid C_i of the object.

4.8.1. Generating a Dense Point Cloud

The photos obtained during UAV flights were subjected to photogrammetric processing in the Pix4D software. The matching of multiple images made it possible for the research team to obtain a “dense” cloud of points. The input data for generating the point cloud were the images and their external orientation. Based on the obtained point cloud, the RMS error of the position of the 3D point was determined. For the first test area it was 0.4 m, for the second test area it was 0.3 m, for the third test area it was 0.3 m, and for the fourth test area it was 0.2 m.

4.8.2. Classification of Point Cloud

The detection of atypical aviation obstacles conducted on the orthophotomap enabled to determine their location ($C(x, y)$). The data of the horizontal coordinates x, y of aviation obstacles were used to locate these objects in the point cloud. The classification of the cloud was performed with use of the iterative method for each previously located aviation obstacle. The determination of the H_{max} height of an atypical obstacle consisted in an iterative search of the point cloud with the aim to detect the highest point that belonged to the analysed object. The initial stage of point cloud search was performed for $C(x, y, H_0)$, where H_0 is the minimum height of the object determined based on the point cloud

(Figure 13). Iterations were performed until the last point belonging to the object was found in the point cloud.

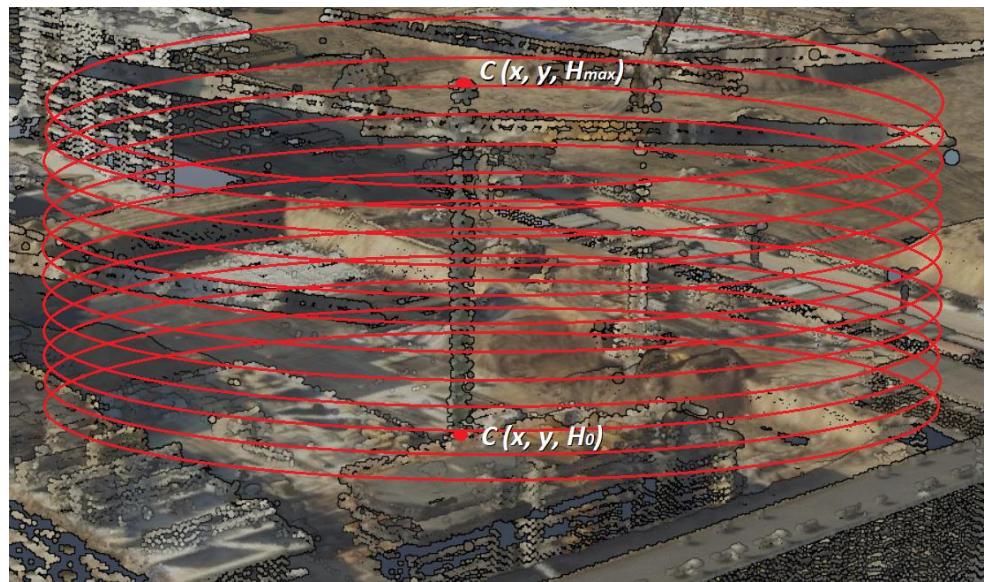


Figure 13. Classification of construction crane point cloud.

The classification of the point cloud was followed by its filtration. The aim of this stage was to analyse the previously detected objects based on the heights obtained from the point cloud. To achieve it, areas 2a and 2b were created to collect data about obstacles for the Radom–Sadków and Łask airports. Area 2a was a flat plane, while area 2b was a plane inclined by 1.2% in relation to area 2a.

The generated planes constituted the border above which data on aviation obstacles are collected. Plane 2b rose to the specified height H . The data concerning height allowed for the filtration of the point cloud. The points from the point cloud that penetrated through the plane (Figure 14) automatically became obstacles and were included in the set of obstacles' data.

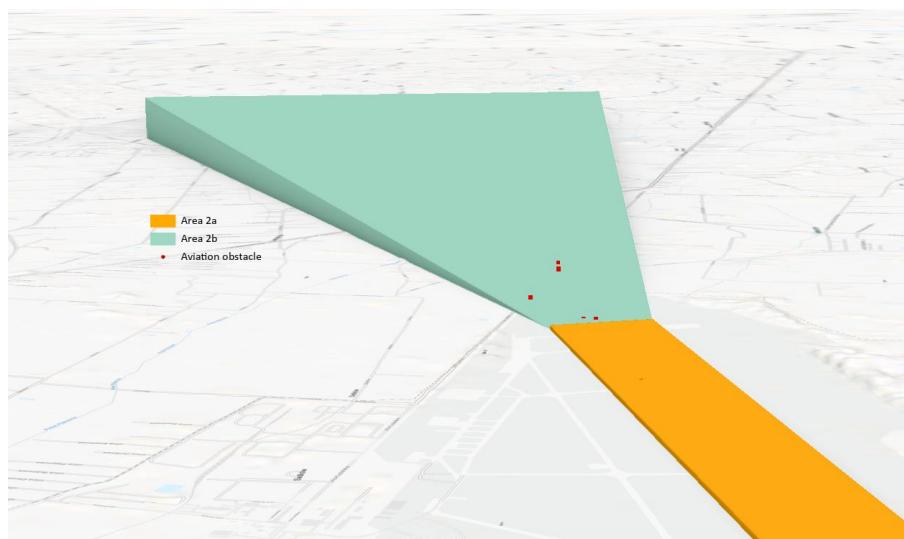


Figure 14. Area 2a and area 2b with atypical aviation obstacles—Airport Radom–Sadków.

4.9. Analysis of the Matching Accuracy of the Point Cloud

The matching accuracy of the point cloud was analysed based on the reference data contained in the database on obstacles, as well as in the supplements attached to the

Aeronautical Information Publication. The supplement contains, among others, information about temporary aviation obstacles. The obstacles' database is developed taking into account all reported aviation obstacles. It contains information concerning: the geographical latitude and longitude of the obstacle, its absolute height, elevation above ground level, location (town), type of obstacle, etc. The analysis of the matching accuracy of the point cloud took into consideration how well it fit in the horizontal plane (coordinates X, Y) and in the vertical plane (coordinate Z) (Table 4).

Table 4. Statistical values that characterise the matching accuracy of the point cloud.

Obstacle	Average Difference in Coordinate X (m)	Average Difference in Coordinate Y (m)	Average Difference in Height H (m)	Mean Error (m)	Standard Deviation (m)
Construction crane	0.6	0.7	0.4	0.7	0.5
Energy pole	0.4	0.3	0.5	0.5	0.4
Wind turbine	0.3	0.4	0.5	0.5	0.6
Mast	0.6	0.5	0.6	0.6	0.5

The accuracy analysis was conducted for four classes of aviation obstacles: construction crane, energy pole, wind turbine, and mast.

The analysis of the statistical values that characterise the matching accuracy of the point cloud revealed that the average difference in horizontal coordinates (X, Y) fell into the range from 0.3 m to 0.7 m, while the average difference in height (Z) ranged from 0.4 m to 0.6 m. The average error of matching between the point cloud and the set of data about obstacles ranged from ± 0.4 m to ± 0.7 m, whereas the standard deviation was between 0.5 m and 0.6 m. The results of the accuracy analysis demonstrated that the method of detection and classification of aviation obstacles guarantees horizontal and vertical accuracy at the level of several tens of centimetres.

5. Discussion

Section 4, which presents the research experiments and the results of detecting atypical obstacles, confirms the high efficiency of the developed method. That section discussed the complexity of the process of accurate detection of aviation obstacles. The complexity consisted in combining two different techniques of obtaining data: from the image, with the use of the YOLOv3 algorithm, and as a result of the point cloud analysis. The latter consisted in an iterative search of the point cloud in reference to the previously defined centroid in order to determine the height. The point cloud matching results met the accuracy requirements provided in the ICAO documentation [33–36]. The results of the detection of atypical aviation obstacles demonstrated that the performance of the neural network determined with the use of the *mAP* index was better for objects where the boxes were less accurately matched to the dimensions of the objects. This case referred to the mast category, which was represented by small objects. Previous research on the detection of small objects based on images from UAV revealed that using the YOLOv3 algorithm to detect such objects results in lower accuracy [47]. Apart from that, a lower IoU index was noted in the construction crane category. Objects belonging to this group were characterised by a thin shape in the image. Both masts and construction cranes were usually located in densely built-up areas. A slightly lower value of the *mAP* index was found in the wind turbine and energy pole categories. However, in these cases, the value of the IoU index was higher, which proved that such objects were detected with higher accuracy. Most of them were located in open areas, free from dense development.

Although the efficiency of detecting small objects with the use of deep learning methods has improved significantly in recent years, there is still a difference between the accuracy levels achieved for small and large objects [48]. Most research studies present satisfactory results in the detection of large objects. The YOLOv3 algorithm is being continuously improved in order to enhance the efficiency of detecting small objects in images. Liu et al., in their work [47], proposed improving the darknet structure by means of increasing the convolutional operations in the early layer in order to enrich the spatial

information. Some studies also revealed an effective reduction of the gap in detecting small objects by means of increasing the number of datasets that use vast amounts of data to train the models [49,50].

UAV provides the images which then become the basis for detecting various types of objects with the use of the YOLOv3 algorithm. Kharchenko et al., [51] in their research on the detection of objects in the vicinity of an airport demonstrated that the YOLOv3 algorithm was characterised by a high detection capacity and positioning accuracy. Moreover, the works by Junos, Mohamad Haniff et al. [52] showed the influence of the correction of images from UAVs on the results of the detection of objects with the use of the YOLOv3 algorithm. Similar accuracy was obtained at the level of 0.3 m to 0.5 m by Mitsevich [53], who proposed a solution for remote and effective obstacle identification and assessment processes with the use of remote sensing stereo imagery. The photogrammetric methods based on the three-dimensional vector models were used, which were integrated into the stereo pair of satellite and aviation scanner images.

The results of detection of atypical aviation obstacles were also compared with the use of methods standardly used for the acquisition of data for the needs of GIS. Wierzbicki et al. [54] have proposed a modified, fully convolutional U-Shape Network (U-Net) for the segmentation of a high-resolution aerial orthoimages and dense LiDAR data in order to automatically extract building outlines. Rottensteiner et al. [55] detected buildings with the Dempster–Shafer method using LiDAR data and aerial photos, and they reached an accuracy of 85%. Sohn and Dowman [56] achieved a building detection accuracy of 80.5% using a combination of IKONOS and LiDAR satellite data. A detailed analysis of the accuracy has been presented in the work of Khoshboresh-Masouleh et al. [57], where various types of areas have been examined, reaching an IoU value of 76%. The position accuracy of the detection of buildings for the purposes of GIS ranges from 0.7 m to 1.5 m in a wide variety of research [58–60]. Therefore, the results of aviation obstacle detection presented in this article correspond to the results of object detection carried out by different authors using other techniques.

6. Conclusions

The presence of aviation obstacles in the direct proximity of the airport may have a negative influence on ensuring safety in the aviation space. The existing databases about aviation obstacles have to meet certain requirements concerning accuracy, which are provided in the legal standards that regulate international aviation law. These documents also contain the requirements and techniques for obtaining data about aviation obstacles. Although the issues related to collecting data about obstacles have been regulated, the automation of the process of collecting data about elongated obstacles still needs improvement [1]. In order to capture very thin objects, a larger image scale than one used for traditional exploratory flights is required. This, in turn, requires lower altitudes, which may be achieved by using UAVs to detect this type of obstacles. At a lower flight altitude, the obtained spatial accuracy (x, y, z) will be the highest. The automation of the process of obtaining data about obstacles, in particular elongated ones that may be described as atypical, still remains a challenge.

The paper constitutes an attempt to present the method of automated detection and classification of atypical aviation obstacles based on data obtained from UAVs. The research was conducted with the use of the YOLOv3 algorithm to detect objects in the image. The methodology of the classification of the point cloud that had been presented in the previous study by Lalak et al. [61] has also been modified. The main aim of the methodology is to detect atypical aviation obstacles in the direct vicinity of an airport by combining the image and the point cloud data.

Based on the conducted analysis of the matching accuracy of the point cloud, it was found that the average differences in horizontal coordinates x, y were, respectively, ± 0.3 m and ± 0.4 m, while the average difference in height was ± 0.5 m. The accuracy levels obtained on the horizontal and vertical planes met the requirements contained in the ICAO

regulations [33–36]. As a result of training the model with the YOLOv3 algorithm, the value of average precision (*AP*) for the construction crane class was 74.8%, for the energy pole class 67.6%, for the wind turbine class 65.2%, and, finally, for the mast class 75.3%. A high value of the *AP* coefficient means that few false predictions were obtained. The *mAP* value of the applied YOLOv3 algorithm reached the value of 70.7%. Such a high value of *mAP* confirms that the model is comprehensive and that this algorithm may be used to detect atypical aviation obstacles.

The developed methodology may significantly improve the process of analysing the operational limitations of aerial vehicles, designing procedures or creating aviation maps, as well as enhance the security in the aviation space by limiting the risk of collision of the aerial vessel with an obstacle to a minimum.

Author Contributions: Conceptualization, D.W.; methodology, M.L. and D.W.; software, M.L.; validation, M.L.; formal analysis, M.L.; investigation, M.L. and D.W.; resources, M.L.; data creation, M.L. and D.W.; writing—original draft preparation, M.L.; writing—review and editing, D.W.; visualization, M.L.; supervision, D.W.; project administration, D.W.; funding acquisition, M.L. All authors have read and agreed to the published version of the manuscript.

Funding: This paper was supported by the Polish Air Force University in the year of 2022.

Acknowledgments: We are sincerely grateful to Creotech Instruments S.A. for providing the UAV images dataset.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Eurocontrol. *Terrain and Obstacle Data Manual*, 3rd ed.; Eurocontrol: Brussels, Belgium, 2021.
2. Nex, F.; Remondino, F. UAV for 3D mapping applications: A review. *Appl. Geomat.* **2014**, *6*, 1–15. [[CrossRef](#)]
3. Everaerts, J. The use of unmanned aerial vehicles (UAVs) for remote sensing and mapping. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2008**, *XXXVII*, 1187–1192.
4. Carvajal-Ramírez, F.; Agüera-Vega, F.; Martínez-Carricando, P.J. Effects of image orientation and ground control points distribution on unmanned aerial vehicle photogrammetry projects on a road cut slope. *J. Appl. Remote Sens.* **2016**, *10*, 34004. [[CrossRef](#)]
5. Zein, T. Fit-For-Purpose Land Administration: An implementation model for cadastre and land administration systems. In Proceedings of the Land and Poverty Conference 2016: Scaling up Responsible Land Governance, Washington, DC, USA, 14–18 March 2016.
6. Stöcker, C.; Bennett, R.; Nex, F.; Gerke, M.; Zeverbergen, J. Review of the Current State of UAV Regulations. *Remote Sens.* **2017**, *9*, 459. [[CrossRef](#)]
7. Zeybek, Z.; Şanlıoğlu, İ. Point cloud filtering on UAV based point cloud. *Measurement* **2019**, *133*, 99–111. [[CrossRef](#)]
8. Gevaert, C.M.; Persello, C.; Sliuzas, R.; Vosselman, G. Informal settlement classification using point-cloud and image-based features from UAV data. *ISPRS J. Photogramm. Remote Sens.* **2017**, *125*, 225–236. [[CrossRef](#)]
9. Girshick, R.; Donahue, J.; Darrell, T.; Malik, J. Rich feature hierarchies for accurate object detection and semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA, 23–28 June 2014.
10. Girshick, R. Fast R-CNN. In Proceedings of the IEEE International Conference on Computer Vision (ICCV), Santiago, Chile, 7–13 December 2015.
11. Ren, S.; He, K.; Girshick, R.; Sun, J. Faster R-CNN: Towards real-time object detection with region proposal networks. In Proceedings of the Advances in Neural Information Processing Systems 28: Annual Conference on Neural Information Processing Systems 2015, Montreal, QC, Canada, 7–12 December 2015.
12. Liu, W.; Anguelov, D.; Erhan, D.; Szegedy, C.; Reed, S.; Fu, C.Y.; Berg, A.C. SSD: Single shot multibox detector. In Proceedings of the European Conference on Computer Vision (ECCV), Amsterdam, The Netherland, 8–16 October 2016.
13. Fu, C.Y.; Liu, W.; Ranga, A.; Tyagi, A.; Berg, A.C. DSSD: Deconvolutional single shot detector. *arXiv* **2017**, arXiv:1701.06659. Available online: <https://arxiv.org/abs/1701.06659> (accessed on 9 August 2022).
14. Redmon, J.; Divvala, S.; Girshick, R. You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 27–30 June 2016.
15. Erhan, D.; Szegedy, C.; Toshev, A.; Anguelov, D. Scalable object detection using deep neural networks. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Columbus, OH, USA, 23–28 June 2014.
16. Simonyan, K.; Zisserman, A. Very deep convolutional networks for large-scale image recognition. *arXiv* **2014**, arXiv:1409.1556. Available online: <https://arxiv.org/abs/1409.1556> (accessed on 9 August 2022).

17. Esetlili, M.; Bektas Balcik, F.; Balik Sanli, F.; Kalkan, K.; Ustuner, M.; Goksel, Ç.; Gazioğlu, C.; Kurucu, Y. Comparison of Object and Pixel-Based Classifications for Mapping Crops Using Rapideye Imagery: A Case Study of Menemen Plain. *Int. J. Environ. Geoinformatics* **2018**, *5*, 231–243. [CrossRef]
18. Çelik, O.; Gazioğlu, C. Coastline Difference Measurement (CDM) Method. *Int. J. Environ. Geoinformatics* **2020**, *7*, 1–5. [CrossRef]
19. Long, J.; Shelhamer, E.; Darrell, T. Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 7–12 June 2015.
20. Lin, J.; Jing, W.; Song, H.; Chen, G. ESFNet: Efficient Network for Building Extraction From High-Resolution Aerial Images. *IEEE Access* **2019**, *7*, 54285–54294. [CrossRef]
21. Huang, W.; Xiao, L.; Wei, Z.; Liu, H.; Tang, S. A new pan sharpening method with deep neural networks. *IEEE Geosci. Remote Sens. Lett.* **2015**, *12*, 1037–1041. [CrossRef]
22. Chen, X.; Xiang, S.; Liu, C.L.; Pan, C.H. Vehicle detection in satellite images by hybrid deep convolutional neural networks. *IEEE Geosci. Remote Sens. Lett.* **2014**, *11*, 1797–1801. [CrossRef]
23. Hu, W.; Huang, Y.; Wei, L.; Zhang, F.; Li, H. Deep convolutional neural networks for hyperspectral image classification. *J. Sens.* **2015**, *2015*, 258619. [CrossRef]
24. Zhang, F.; Du, B.; Zhang, L. Scene classification via a gradient boosting random convolutional network framework. *IEEE Trans. Geosci. Remote Sens.* **2016**, *54*, 1793–1802. [CrossRef]
25. Yang, H.; Wu, P.; Yao, X.; Wu, Y.; Wang, B.; Xu, Y. Building extraction in very high resolution imagery by dense-attention networks. *Remote Sens.* **2018**, *10*, 1768. [CrossRef]
26. Li, X.; Yao, X.; Fang, Y. Building-A-Nets: Robust Building Extraction from High-Resolution Remote Sensing Images With Adversarial Networks. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2018**, *11*, 3680–3687. [CrossRef]
27. Li, L.; Liang, J.; Weng, M.; Zhu, H. A multiple-feature reuse network to extract buildings from remote sensing imagery. *Remote Sens.* **2018**, *10*, 1350. [CrossRef]
28. Lu, T.; Ming, D.; Lin, X.; Hong, Z.; Bai, X.; Fang, J. Detecting building edges from high spatial resolution remote sensing imagery using richer convolution features network. *Remote Sens.* **2018**, *10*, 1496. [CrossRef]
29. Bittner, K.; Adam, F.; Cui, S.; Körner, M.; Reinartz, P. Building footprint extraction from VHR remote sensing images combined with normalized DSMs using fused fully convolutional networks. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2018**, *11*, 2615–2629. [CrossRef]
30. Xu, Y.; Wu, L.; Xie, Z.; Chen, Z. Building extraction in very high resolution remote sensing imagery using deep learning and guided filters. *Remote Sens.* **2018**, *10*, 144. [CrossRef]
31. Boonpook, W.; Tan, Y.; Ye, Y.; Torteeka, P.; Torsri, K.; Dong, S. A Deep Learning Approach on Building Detection from Unmanned Aerial Vehicle-Based Images in Riverbank Monitoring. *Sensors* **2018**, *18*, 3921. [CrossRef] [PubMed]
32. Liu, H.; Luo, J.; Huang, B.; Hu, X.; Sun, Y.; Yang, Y.; Zhou, N. DE-Net: Deep Encoding Network for Building Extraction from High-Resolution Remote Sensing Imagery. *Remote Sens.* **2019**, *11*, 2380. [CrossRef]
33. ICAO. Annex 15 to the Convention on International Civil Aviation—Aeronautical Information Services, 15th ed.; International Standards and Recommended Practices; ICAO: Montreal, QC, Canada, 2016.
34. ICAO. Annex 4 to the Convention on International Civil Aviation, 11th ed.; Aeronautical Charts; ICAO: Montreal, QC, Canada, 2009.
35. ICAO. DOC-9674, World Geodetic System-1984 (WGS84) Manual, 2nd ed.; ICAO: Montreal, QC, Canada, 2002.
36. ICAO. DOC-1006, Aeronautical Information Management, 1st ed.; ICAO: Montreal, QC, Canada, 2018.
37. ICAO. Annex 14 to the Convention on International Civil Aviation, 8th ed.; Aerodrome Design and Operations; ICAO: Montreal, QC, Canada, 2018; Volume I.
38. He, K.; Zhang, X.; Ren, S.; Sun, J. Deep residual learning for image recognition. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016.
39. Al-Saffar, A.A.M.; Tao, H.; Talab, M.A. Review of deep convolution neural network in image classification. In Proceedings of the 2017 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET), Jakarta, Indonesia, 23–24 October 2017.
40. Li, Y.; Zhang, H.; Xue, X.; Jiang, Y.; Shen, Q. Deep learning for remote sensing image classification: A survey. *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.* **2018**, *8*, e1264. [CrossRef]
41. Ranjbar, M.; Mori, G.; Yang, W. Optimizing complex loss functions in structured prediction. In Proceedings of the European Conference on Computer Vision, Heraklion Crete, Greece, 5–11 September 2010.
42. Praca zbiorowa, Geodezja inżynierijna, Tom II.; Państwowe Przedsiębiorstwo Wydawnictw Kartograficznych: Warszawa, Poland, 1980. (In Polish)
43. Kaggle. Wind Turbine Detection. Available online: <https://www.kaggle.com/datasets/saurabhshahane/wind-turbine-object-detection> (accessed on 9 August 2022).
44. Afonso, M.; Fonteijn, H.; Fiorentin, F.; Lensink, D.; Mooij, M.; Faber, N. Tomato fruit detection and counting in greenhouses using deep learning. *Front. Plant Sci.* **2020**, *11*, 571299. [CrossRef]
45. He, H.; Garcia, E.A. Learning from imbalanced data. *IEEE Trans. Knowl. Data Eng.* **2009**, *21*, 1263–1284.
46. Csurka, G.; Larlus, D.; Perronnin, F. What is a good evaluation measure for semantic segmentation? In Proceedings of the 24th BMVC British Machine Vision Conference, Bristol, UK, 9–13 September 2013.

47. Liu, M.; Wang, X.; Zhou, A.; Fu, X.; Ma, Y.; Piao, C. Uav-yolo: Small object detection on unmanned aerial vehicle perspective. *Sensors* **2020**, *20*, 2238. [[CrossRef](#)]
48. Nguyen, N.D.; Do, T.; Ngo, T.D.; Le, D.D. An Evaluation of Deep Learning Methods for Small Object Detection. *J. Electr. Comput. Eng.* **2020**, *2020*, 3189691. [[CrossRef](#)]
49. Lin, T.Y.; Maire, M.; Belongie, S.; Hays, J.; Perona, P.; Ramanan, D.; Zitnick, C.L. Microsoft COCO: Common objects in context. In Proceedings of the European Conference on Computer Vision, Zurich, Switzerland, 6–12 September 2014.
50. Russakovsky, O.; Deng, J.; Su, H.; Krause, J.; Satheesh, S.; Ma, S.; Fei-Fei, L. Imagenet large scale visual recognition challenge. *Int. J. Comput. Vis.* **2015**, *115*, 211–252. [[CrossRef](#)]
51. Kharchenko, V.; Chyrka, I. Detection of airplanes on the ground using YOLO neural network. In Proceedings of the IEEE 17th International Conference on Mathematical Methods in Electromagnetic Theory (MMET), Kyiv, Ukraine, 2–5 July 2018.
52. Junos, M.H.; Mohd Khairuddin, A.S.; Thannirmalai, S.; Dahari, M. Automatic detection of oil palm fruits from UAV images using an improved YOLO model. *Vis. Comput.* **2021**, *38*, 2341–2355. [[CrossRef](#)]
53. Mitsevich, L. 3D Aerodrome Obstacle Assessment Using Stereo Remote Sensing Imagery. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2020**, *XLIII-B2-2020*, 1115–1119. [[CrossRef](#)]
54. Wierzbicki, D.; Matuk, O.; Bielecka, E. Polish Cadastre Modernization with Remotely Extracted Buildings from High-Resolution Aerial Orthoimagery and Airborne LiDAR. *Remote Sens.* **2021**, *13*, 611. [[CrossRef](#)]
55. Rottensteiner, F.; Trinder, J.; Clode, S.; Kubik, K. Using the Dempster–Shafer method for the fusion of LIDAR data and multispectral images for building detection. *Inf. Fusion* **2005**, *6*, 283–300. [[CrossRef](#)]
56. Sohn, G.; Dowman, I. Data fusion of high-resolution satellite imagery and LIDAR data for automatic building extraction. *ISPRS J. Photogramm. Remote Sens.* **2007**, *62*, 43–63.
57. Khoshboresh-Masouleh, M.; Alidoost, F.; Hossein, A. Multiscale building segmentation based on deep learning for remote sensing RGB images from different sensors. *J. Appl. Remote Sens.* **2020**, *14*, 034503. [[CrossRef](#)]
58. Kocur-Bera, K.; Stachelek, M. Geo-Analysis of Compatibility Determinants for Data in the Land and Property Register (LPR). *Geosciences* **2019**, *9*, 303. [[CrossRef](#)]
59. Hanus, P.; Benduch, P.; Pęska-Siwik, A. Budynek na mapie ewidencyjnej, kontur budynku i bloki budynku. *Przegląd Geod.* **2017**, *7*, 15–20. (In Polish) [[CrossRef](#)]
60. Buško, M. Modernization of the Register of Land and Buildings with Reference to Entering Buildings into the Real Estate Cadastre in Poland. In Proceedings of the International Conference on Environmental Engineering, Vilnius, Lithuania, 27–28 April 2017.
61. Lalak, M.; Wierzbicki, D. Methodology of Detection and Classification of Selected Aviation Obstacles Based on UAV Dense Image Matching. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2022**, *15*, 1869–1883. [[CrossRef](#)]