

POLITECHNIKA OPOLSKA
Wydział Elektrotechniki, Automatyki i Informatyki



ROZPRAWA DOKTORSKA

mgr inż. Rafał Gasz

**Wykorzystanie metod wizyjnych do identyfikacji
obiektów przestrzennych**

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

Opole 2018

pamięci
Adelajdy i Rajnholda
moich ukochanych Dziadków

*Człowieka kształtują przeżyte chwile oraz ludzie,
których spotyka na swojej życiowej drodze.
Dlatego pragnę podziękować wszystkim,
bez których dziś nie byłbym człowiekiem jakim
jestem oraz bez których niniejsza praca
nie mogła by powstać.*

*Przede wszystkim pragnę podziękować
mojemu promotorowi i mistrzowi
Profesorowi Sławomirowi Zatorowi,
za zauważenie we mnie zacięcia naukowca
oraz wprowadzenie w tajniki pracy badacza.
Za wszelką pomoc, ogrom pomysłów oraz cenne uwagi.*

*Pragnę podziękować także kolegom z zespołu
za świetną współpracę i atmosferę
dla której dziennie przychodzenie do pracy jest nie tylko obowiązkiem
ale i przyjemnością.*

*Szczególne podziękowania kieruję pod adresem Michała i Bogdana,
za wsparcie i pomoc a zwłaszcza za długie godziny
merytorycznych dyskusji, motywację i okazane wsparcie.*

*Dziękuję wszystkim kolegom z którymi przez
ostatnie lata dane mi było współpracować
na płaszczyźnie naukowej jak i organizacyjnej.*

*Szczególne podziękowania pragnę skierować do moich bliskich
za ciągłe wsparcie i zachętę.
Szczególnie pragnę podziękować mojej Kochanej Mamie Cecylii,
za trud wychowania oraz za wszelkie poświęcenie,
dzięki któremu mogłem zdobyć wykształcenie
oraz oddać się w pełni pracy naukowej.
Za wsparcie i ciągłą motywację.
Dziękuję.*

Opole, wrzesień 2018

Spis treści

1. Wprowadzenie	7
2. Cel i zakres pracy	11
2.1. Zakres pracy	11
2.2. Teza pracy	12
3. Metody stosowane w cyfrowym przetwarzaniu obrazów	13
3.1. Akwizycja obrazów	13
3.2. Wady odwzorowania obiektów	14
3.3. Cyfrowe przetwarzanie obrazu	17
3.4. Detekcja krawędzi	19
3.5. Rejestracja obrazów cyfrowych	21
3.6. Metody tworzenia modeli 3D obiektów	23
3.7. Metody detekcji obiektów w obrazach 2D i ich cech	29
3.8. Podsumowanie rozdziału	30
4. Metoda zdjęć wirtualnych	32
4.1. Proponowany algorytm	32
4.2. Wykonanie modelu wzorcowego oraz zdjęć rzeczywistych	34
4.3. Preprocesing zdjęć rzeczywistych	36
4.4. Określenie pozycji kamery	41
4.5. Generowanie zdjęcia wirtualnego	50
4.6. Rejestracja zdjęcia rzeczywistego i wirtualnego	51
4.7. Korekta zarejestrowanych zdjęć	55
4.8. Analiza obiektu	57
4.9. Podsumowanie rozdziału	58
5. Proponowana metoda selekcji wybranych cech	59
5.1. Ocena procesu rejestracji	59
5.2. Detekcja wystąpienia braków w konstrukcji	73
5.3. Podsumowanie rozdziału	79
6. Przyjęte reguły oceny stanu obiektów	81
6.1. Badanie przesiewowe	81
6.2. Implementacja w pracy	82
6.3. Badania laboratoryjne	83
6.4. Badania obiektu rzeczywistego	93
6.5. Podsumowanie rozdziału	103
7. Analiza wyników działania opracowanej metody	104

7.1. Analiza doboru wartości parametrów metody	104
7.2. Omówienie skuteczności metody dla obiektu laboratoryjnego	105
7.3. Omówienie skuteczności metody dla obiektu rzeczywistego	112
7.4. Podsumowanie rozdziału	121
8. Podsumowanie i wnioski	122
9. Kierunki dalszych badań	126
Bibliografia	128
Streszczenie	139
Abstract	140
Spis rysunków	141
Spis tabel	145

Wykaz oznaczeń i skrótów

- A – macierz opisująca orientację współrzędnych tłowych i terenowych
 - c – stała kamery
 - f – ogniskowa [m]
 - $f(x,y)$ – funkcja dyskretna opisująca obraz cyfrowy
 - $f_B(x,y)$ – obraz cyfrowy po procesie binaryzacji
 - $f_{RGB}(x,y)$ – obraz cyfrowy zapisany w formacie RGB
 - E – element strukturalny
 - k – dystorsja radialna
 - M – model 3D obiektu
 - O – punkt główny zdjęcia [px]
 - P – współrzędne pozycji kamery [m]
 - r – odległość punktu od początku układu współrzędnych w układzie tłowym [px]
 - R – odległość punktu od początku układu współrzędnych w układzie terenowym [m]
 - RGB – modeli przestrzeni barw
 - T – translacja
 - Q – pozycja kamery [px]
 - x, y, z – współrzędne tłowe [px]
 - X, Y, Z – współrzędne terenowe [m]
 - λ – długość [m]
 - ω – kąt nachylenia [rad]
 - κ – kąt skręcenia [rad]
 - φ – kąt zwrotu [rad]
-
- Acc – Accuracy
 - CAD – Computer Aided Design
 - CP – control points
 - DSM – Dense Surface Modeling
 - FDR – False Discovery Rate
 - IoU – Intersection over Union
 - MZW – Metoda zdjęć wirtualnych

1. Wprowadzenie

W ostatnich latach można zaobserwować wzrost systemów wykorzystujących metody wizyjne do analizy ruchu, trójwymiarowego pomiaru geometrii obiektów oraz automatycznego generowania obiektów trójwymiarowych na podstawie zdjęć. Znaczący rozwój dziedzin wspomagających systemy wizyjne sprawia, że systemy te są wykorzystywane jako narzędzie łatwe w użyciu, dokładne oraz uniwersalne. Niejednokrotnie obraz jest ważnym, a często także jedynym źródłem informacji o stanie badanego obiektu [KaP10, TaR97].

Z pośród systemów wizyjnych dużą grupę stanowią systemy pomiarowe oparte o optyczne techniki pomiarowe. Systemy te znajdują zastosowanie w badaniach materiałowych, wytrzymałościowych, zwłaszcza w pomiarach odkształceń i naprężeń oraz w pomiarach parametrów kinematycznych obiektów. Często analizę obrazów wykorzystuje się także w diagnostyce przemysłowej, medycznej, kontroli jakości, monitoringu, w tym monitoringu środowiska [SzJ10].

Szybko rozwijaną dziedziną nauki z zakresu systemów wizyjnych jest widzenie komputerowe. U jego podstaw leży dążenie do stworzenia systemów z możliwością rozpoznawania i przetwarzania informacji zawartej w obrazach w stopniu zbliżonym do poziomu rozpoznawania, którymi dysponują organizmy żywe wyposażone w zdolność widzenia [KaPK10, TaR97]. W tych systemach zazwyczaj stosowane są algorytmy sztucznej inteligencji, które mają uzyskać zdolność samodzielnego posługiwania się własnymi czujnikami do pozyskiwania informacji o otaczającej przestrzeni.

Przetwarzanie obrazów polega na zastosowaniu szeregu przekształceń zmieniających obraz źródłowy, w tym poprawiających jego jakość w dalszej analizie i służącym podniesieniu skuteczności rozpoznawania wybranych i wyszukiwanych cech. Proces przetwarzania polegać może także na doprowadzeniu obrazu do postaci wygodnej do kodowania [TaR97].

Poprawa jakości obrazu nie prowadzi do zwiększenia jego zawartości, ale zwiększa zakres dynamiczny wybranych cech umożliwiając ich łatwiejszą detekcję [KaPK10, TaR97]. Jest wiele operacji poprawy jakości jak na przykład zmiana układu poziomów szarości i kontrastu, redukcji poziomu szumu, wyostrenie krawędzi, poprawa ostrości, różnego rodzaju filtracje. Dużo metod przetwarzania obrazów zaczerpniętych jest z dziedzin jak: geometria, obróbka sygnałów, analiza funkcjonalna itp.

Obecnie systemy wizyjne znajdują zastosowanie w dziedzinach takich jak: robotyka, mikroskopia, medycyna, systemy bezpieczeństwa, telekomunikacji,

w nadzorze produkcji, astronomii, radiologii, w zastosowaniach związanych z zagadnieniami wojskowymi, bezpieczeństwa itd. Największe zastosowanie metody wizyjnej, a szczególnie różnego rodzaju algorytmów z zakresu przetwarzania obrazów, znalazło zastosowanie w automatyce i robotyce, medycynie oraz inżynierii produkcji. Znaczący rozwój zarówno możliwości technicznych samych urządzeń obrazujących (aparaty fotograficzne, kamery) jak i rozwój algorytmów z zakresu przetwarzania obrazu, spowodowały, że metody wizyjne odgrywają aktualnie ważną rolę w automatyzacji procesów produkcyjnych [SzJ10] oraz w szeroko pojętych zastosowaniach diagnostycznych.

W realizacji zadań identyfikacji obiektów przestrzennych na obrazach najważniejszymi funkcjami zastosowań systemów wizyjnych oraz metod przetwarzania obrazu są [SzJ10]:

- rozpoznawanie obiektów – oznaczającą identyfikację obiektów na podstawie cech charakterystycznych takich jak: kształt (geometria), wymiary, kolor, struktura (topologia),
- określanie pozycji – oznaczającą określanie pozycji (współrzędnych) oraz orientacji obiektu lub konkretnego punktu tego obiektu, we wcześniej zdefiniowanym układzie współrzędnych, korzystając z określonych cech obiektu oraz metod dopasowywania,
- kontrola powierzchni – która może być podzielona na dwie grupy: ilościową – mającą na celu określenie cech topograficznych takich jak chropowatość lub jakościową – mającą na celu rozpoznawanie defektów powierzchni takich jak wgniecenia, zadrapania, zanieczyszczenia, czy odchylenia od pożądaných właściwości powierzchni,
- sprawdzenie kształtu i wymiarów – oznaczającą określenie geometrycznych wielkości z naciskiem położonym na precyzję i dokładność pomiarów.

Głównym zadaniem systemu wizyjnego jest poznawanie otoczenia, w sposób zbliżony do ludzkiego zmysłu wzroku. W połączeniu z innymi zmysłami wzrok umożliwia rozpoznawanie otoczenia i obiektów. Sam komputerowy system wizyjny jest silnie ograniczony i przystosowany do rozwiązywania ściśle określonego zadania. Możliwości algorytmów przetwarzania obrazów obecnie nie pozwalają wprost na analizę całościową złożonych sytuacji. Rozwój współczesnych urządzeń rejestrujących jest duży co sprawia, że parametry sprzętowe mogą być zbliżone a często przewyższają parametry ich biologicznego odpowiednika - oka. Ograniczeniem w tej sferze pozostają nadal możliwości algorytmów, które nie dają dobrych rezultatów w porównaniu z możliwościami mózgu człowieka. Jednakże widzenie komputerowe ma dużą przewagę nad zmysłem ludzkiego wzroku – analiza materiału fotograficznego może trwać w sposób ciągły, co nie jest możliwe do realizacji przez człowieka, który po pewnym okresie analizowania materiału odczuwa zmęczenie.

Problemy mogą stanowić być także same obiekty, które będą poddawane ocenie przez system wizyjny, w szczególności ich budowa, umiejscowienie oraz rozmiar. Obiektami, które będą analizowane w niniejszej pracy są konstrukcje wsporcze linii elektroenergetycznej. Wybór ten został dokonany w związku z działalnością jednostki, w której realizowane były zadania a także tematyką badań naukowych zespołu w skład

którego wchodzi doktorant. Sam problem badawczy został przedstawiony zespołowi przez przedstawicieli sektora elektroenergetycznego, którzy wykonując planowane inspekcje linii, wykonują zdjęcia bądź nagrania wideo jej elementów, które w kolejnej fazie analizują wyspecjalizowani technicy, których zadaniem jest odnalezienie na zdjęciach wad w konstrukcji wsporczej oraz wytypowanie obiektów do dalszej pogłębionej diagnostyki. Obecnie nie istnieje narzędzie, które w sposób kompleksowy mogłoby zastąpić doświadczony naziemny personel. Dlatego też informacja, pozyskana metodami wizyjnymi, jest pierwszym etapem procesu diagnostycznego. Dodatkowo, specyfika każdego elementu linii napowietrznej wymaga odmiennego podejścia oraz zastosowania dedykowanego sensora. Zadanie to niestety jest dość męczące i mało skuteczne, dlatego autor podjął się zadania zautomatyzowania procesu wyszukiwania konstrukcji potencjalnie wadliwych i wskazywania ich do dalszej analizy przez wyspecjalizowany personel.

Stan linii elektroenergetycznej ocenia się przez wykonywanie planowych oględzin, które wykonywane są nie rzadziej niż 1 raz w roku [Ene]. Podczas inspekcji sprawdzany jest stan konstrukcji wsporczych – ich fundamentów i osprzętu, oceniany jest także stan izolatorów, łączników, ochrony przeciwporażeniowej i przeciwprzepięciowej. Ostatnim, bardzo istotnym elementem, jest ocena odległości zarośli, gałęzi drzew i obiektów znajdujących się w otoczeniu linii. Inspekcję tą przeprowadza zespół wyspecjalizowanych pracowników. Planowe inspekcje kończą się raportem, na podstawie którego operator podejmuje decyzje o konserwacji, remoncie, etc. Inną formą inspekcji są oględziny doraźne, które mają na celu zlokalizowanie uszkodzenia występującego na linii. Na podstawie wyniku oględzin, przeglądów, pomiarów eksploatacyjnych, wieku linii oraz wymagań lokalnych oraz warunków eksploatacji, sporządzana jest ocena stanu technicznego linii. Ocena taka powinna być realizowana nie rzadziej niż raz na 5 lat [Ene].

Najbardziej ogólnym podziałem konstrukcji, ze względu na ich funkcję, jest podział na przelotowe i mocne [MaZS12]. Słupy przelotowe [KoZ80, KiK73] cechuje lekka konstrukcja oraz niska wytrzymałość na duży naciąg przewodów, spowodowane jest to tym, że słup przelotowy ma za zadanie podtrzymanie przewodu oraz wytrzymanie obciążeń spowodowanych oddziaływaniem wiatru i śniegu. Słupy mocne [MaZS12, KoZ80] charakteryzują się wzmocnioną konstrukcją dostosowaną do działania sił wywołanych naciągiem przewodów. Do słupów mocnych zalicza się słupy: odporowe, odporowo-naróżne i krańcowe.

Konstrukcje wsporcze zostały wybrane jako element silnie narażony na wszelkiego rodzaju uszkodzenia – te powstałe wskutek eksploatacji linii jak i te będące celowym działaniem człowieka. Najczęstszymi uszkodzeniami w przypadku konstrukcji kratowych są braki elementów, które spowodowane są aktami wandalizmu oraz uszkodzeniami mechanicznymi i korozją [KuI10]. Poza omówionymi rodzajami uszkodzeń wyróżnić można także uszkodzenia konstrukcji w wyniku prac rolnych lub skręcenia konstrukcji, co powoduje obniżenie wytrzymałości całej konstrukcji [MaZS12]. Kolejnym czynnikiem jest osuwanie się fundamentów, co w konsekwencji prowadzi do odchylenia osi słupa [KuI10]. Najczęściej narażone na tego typu uszkodzenia są konstrukcje występujące na terenach eksploatacji górniczej. Ostatnią

grupą uszkodzeń są uszkodzenia powstałe w wyniku działań atmosferycznych, takich jak burze oraz silne podmuchy wiatru [KeW09]. Niebezpieczną konsekwencją przyjętych założeń projektowych jest także możliwość zniszczenia słupa przelotowego, przy silnie nie zrównoważonym naciągu przewodów lub wystąpienie zniszczenia kaskadowego grupy słupów (na zasadzie efektu domina) na prostych odcinkach linii [PaTP09].

Najpopularniejszą, a jednocześnie najmniej kosztowną wizyjną metodą diagnostyczną w przypadku linii napowietrznych, jest rejestracja obiektów przy pomocy aparatów rejestrujących obraz w świetle widzialnym, czyli w zakresie długości fal 380-780 nm. Używane aparaty muszą cechować się optyką pozwalającą uzyskać duże zbliżenia, co spowodowane jest tym, że w przypadku inspekcji prowadzonej z ziemi, odległość do elementów, takich jak izolatory, złączki czy górne partie kratownic jest znaczna (punkt obserwacji od obiektu niejednokrotnie oddalony jest o ok. 100 m). Obrazowanie w zakresie światła widzialnego wykorzystywane jest do identyfikacji wszelkiego rodzaju uszkodzeń kratownicy, izolatorów oraz złączy. Obecnie, w zadaniach inspekcji, wykorzystuje się również helikoptery lub bezzałogowe statki powietrzne (drony) z podwieszonymi aparatami oraz systemem stabilizacji. Ciekawym rozwiązaniem wydają się być autonomiczne roboty, które poruszają się po liniach, i często służą jako baza do zamontowania różnych czujników, w tym także wizyjnych [MoSP03, ZhLR10, DaMO16]. Poza zwykłymi kamerami do robotów, montuje się również kamery termowizyjne. W diagnostyce linii wykorzystuje się je głównie w celu wyszukiwania hot spotów, czyli miejsc nadmiernie się przegrzewających.

Niezależnie od sposobu wykonania zdjęć (z ziemi, z powietrza) oraz rodzaju posiadanego zdjęcia (RGB, podczerwień, ultrafiolet) pojawiają się podobne problemy do rozwiązania. Stawiane są pytania: w jaki sposób dokonać sposobu oceny stanu obiektu (konstrukcji wsporczej), w odniesieniu do czego i w jaki sposób odnieść posiadaną dokumentację fotograficzną? W niniejszej rozprawie autor przedstawia propozycje rozwiązania wcześniej wspomnianych problemów badawczych. Wykorzystując wiedzę z zakresu analizy obrazów 2D autor opracował metodę do identyfikacji obiektów przestrzennych na zdjęciach oraz oceny ich stanu, korzystając z posiadanej dokumentacji technicznej (projektów wykonawczych) linii elektroenergetycznej.

2. Cel i zakres pracy

Celem niniejszej pracy jest opracowanie metody do wstępnej półautomatycznej diagnostyki obiektów przestrzennych na przykładzie elementów linii elektroenergetycznej.

Celami pomocniczymi są:

- opracowanie metody identyfikacji wybranych elementów obiektu na zdjęciach metrycznych dysponując wcześniej ich modelem 3D,
- implementacja metody wcięcia wstecz do określenia współrzędnych przestrzennych kamery,
- porównanie dokładności dopasowania obrazów w procesie rejestracji,
- opracowanie metody określenia niezgodności obiektu z wzorcem poprzez brak elementów lub ich nadmiar.

2.1. Zakres pracy

Niniejsza rozprawa została podzielona na 9 rozdziałów, które obejmują przegląd literatury, możliwości wykorzystania danych do zastosowań praktycznych, propozycję wykorzystania metod przetwarzania obrazów 2D do oceny kompletności obiektów przestrzennych na przykładzie konstrukcji kratowej oraz badania i przykłady dotyczące wykorzystania opracowanej metody.

W **rozdziale 3** przeprowadzono analizę literatury obejmującą aktualny stan wiedzy dotyczący metod stosowanych w cyfrowym przetwarzaniu obrazów. Omówiono kwestie dotyczące akwizycji obrazów cyfrowych z uwzględnieniem wad jakimi obrazy mogą być obciążone w związku z budową obiektywów. Omówione zostały metody przetwarzania obrazów cyfrowych, rejestracji obrazów oraz detekcji określonych cech w analizowanych obrazach.

Rozdział 4 stanowi przedstawienie autorskiej metody zdjęć wirtualnych, którą autor proponuje jak i sposób rozwiązania rozważanego problemu, wytypowania zdjęć z grupy obrazów, na których występują kratownice z widocznymi wadami konstrukcji.

W **rozdziale 5** opisana została proponowana metoda selekcji wybranych cech obrazów, które będą uważane, z niezgodne z przedstawionym wzorcem obiektu. Opisany

został także dokładnie sam proces rejestracji obrazów, gdyż w trakcie badań okazał się on jednym z istotniejszych etapów działania zaproponowanej metody.

Kolejny **rozdział 6** zawiera opis przyjętych reguł oceny stanu badanych obiektów. Opisano w nim implementacje w pracy mechanizmów badań przesiewowych, których użyto jako w niniejszej pracy. Omówione zostały uzyskiwane wyniki działania metody z wykorzystaniem materiału fotograficznego zebranego w warunkach laboratoryjnych i rzeczywistych.

W **rozdziale 7** opisano analizę wyników działania metody, opisano dobór wartości konkretnych zmiennych na kolejnych etapach działania metody, w celu uzyskania jak najlepszych wyników analizy.

Rozdział 8 stanowi podsumowanie, zawiera on konkluzje i wnioski autora na temat możliwości oraz ograniczeń związanych z działaniem opracowanej metody oraz narzędzia do wstępnej półautomatycznej analizy zebranego materiału fotograficznego.

W **rozdziale 9** przedstawiono kierunki dalszych badań w zakresie rozwoju funkcjonalnego opracowanej metody oraz jej potencjalnie nowe zastosowania.

2.2. Teza pracy

Praca zmierza do wykazania prawdziwości następującej tezy:

Istnieje możliwość wykorzystania metod cyfrowego przetwarzania obrazów, aby wykorzystując model 3D badanego obiektu oraz jego zdjęcie metryczne, zrealizować algorytm wyznaczania niezgodności wybranych parametrów obiektu z modelem.

Powyższą tezę można przedstawić w postaci tez pośrednich:

Istnieje możliwość wykorzystania metod cyfrowego przetwarzania obrazów 2D do zadań analizy obiektów przestrzennych,


Wykonując porównanie obiektu wzorcowego ze zdjęciem metrycznym istnieje możliwość wykrycia niezgodności.

3. Metody stosowane w cyfrowym przetwarzaniu obrazów

3.1. Akwizycja obrazów

Przetwarzanie obrazów jest to proces składający się z pozyskania (akwizycji) obrazu i przetworzeniu go do postaci cyfrowej [TaR97, WoJ96]. Kolejno następuje wstępne przetworzenie obrazu, jego filtracja i wyostrzenie, a także jego binaryzacja. W kolejnym kroku następuje segmentacja obrazu i wydzielenie poszczególnych obiektów oraz ich fragmentów (np. krawędzi i innych linii). Po tych operacjach następuje analiza obrazu i wyznaczenie cech obiektów oraz informacji o ich lokalizacji oraz rozpoznanie i analiza obrazu (identyfikacja klasy).

Jako obraz cyfrowy [TaR97, WoJ96] rozumiana jest dwuwymiarowa funkcja dyskretna $f(x,y)$ taka, że jej argumentami są dyskretne piksele, a wartościami kolory w przestrzeni RGB, czyli trójki liczb z przedziału $[0;255]$. Początek układu współrzędnych przyjmuje się w lewym górnym rogu obrazu. Przykładowy zakres zmienności kolorów 0-255 nie oznacza, że prezentowane dalej algorytmy dotyczące obrazów kolorowych nie będą działać na obrazach o większej skali liczby kolorów. Przez akwizycję obrazu rozumiany jest proces przetworzenia obrazu obiektu fizycznego ($f(x,y)$) do postaci zbioru danych dyskretnych (obraz cyfrowy) nadających się do dalszego przetwarzania. Proces ten polega na zamianie sygnału analogowego do postaci dyskretniej (skwantowanej). Proces ten wykonywany jest z użyciem np. aparatu fotograficznego, którego schemat działania przedstawiono na rys. 3.1.



Rys. 3.1. Schemat działania aparatu, a) podczas kadrowania, b) w momencie wykonania zdjęcia
1. Obiektyw, 2. Ruchome lustro, 3. Matówka, 4. Pryzmat pentagonalny,
5. Wizjer, 6. Kurtyna migawki, 7. Matryca [BISpi18]

Jednym z ważniejszych elementów aparatów są obiektywy, które są układem optycznym, tworzącym na światłoczułej matrycy CCD lub CMOS odwzorowany obraz fotografowanych obiektów [SoA77, ToR07]. Podstawową rolą obiektywu jest zogniskowanie promieni światła w płaszczyźnie matrycy lub błony światłoczułej, tak aby otrzymany obraz był ostry. Aby było to możliwe, konieczne jest ustawienie obiektywu w odpowiedniej odległości od tej płaszczyzny. Podstawowym parametrem każdego obiektywu jest jego ogniskowa, odległość pomiędzy punktem głównym obiektywu, płaszczyzną przysłony lub środkiem soczewki, do punktu, w którym skupione zostaną promienie świetlne, które przed przejściem przez obiektyw biegną równolegle.

3.2. Wady odwzorowania obiektywów

Wybór właściwego obiektywu, w zależności od zadania, do jakiego będzie wykorzystywany jest ważnym fragmentem procesu decyzyjnego, jaki należy podjąć, dobierając obiektyw należy zwrócić uwagę na następujące parametry: ogniskowa, jasność, minimalna odległość przedmiotowa, pole obrazowe, zdolność rozdzielcza, przesłona krytyczna, zakresy przesłon, winietowanie.


Wyróżnić można dwie główne grupy obiektywów [SoA77]. Obiektywy zmienneogniskowe – można w nich w pewnym zakresie zmieniać ogniskową. Drugą grupę tworzą obiektywy stałoogniskowe. Są one mniej uniwersalne od zmienneogniskowych, ale za to są mniejsze i lżejsze. Mają też lepszą jakość optyczną (stosuje się w nich odpowiednią ilość soczewek, mających na celu eliminację wad optycznych). Ze względu na wielkość ogniskowej, a co za tym idzie kąt widzenia można obiektywy podzielić na:

- standardowe, w których długość ogniskowej jest zbliżona do przekątnej matrycy lub błony rejestrującej obraz;
- szerokokątne, w których długość ogniskowej jest znacząco mniejsza od przekątnej matrycy lub błony, a kąt widzenia jest większy od kąta widzenia ludzkiego oka;
- wąskokątne, w których długość ogniskowej jest znacząco większa od przekątnej matrycy lub błony, a kąt widzenia jest mniejszy od kąta widzenia ludzkiego oka.

Wykorzystując obrazy w procesie diagnostycznym należy mieć na uwadze, że mogą one zawierać błędy odwzorowania. Błędy te mogą być spowodowane złym doborem sprzętu, brakiem odpowiedniej wiedzy, ale także wadami optycznymi stosowanych obiektywów. Te ostatnie należy skorygować przed przystąpieniem do dalszego przetwarzania, zanim będą podejmowane decyzje na podstawie otrzymanego materiału fotograficznego.

Jest kilka podstawowych wad obiektywów, które obniżają jakość otrzymanych zdjęć [SoA77, SiZ84]. Jedną z nich jest astygmatyzm – to zjawisko polegające na tym, że promienie wychodzące z tego samego punktu, a przebiegające w dwóch prostopadłych płaszczyznach są ogniskowane w różnych punktach. Obiektywy ze skorygowanym astygmatyzmem noszą nazwę anastygmatów. Innym zniekształceniem jest koma, która

polega na tym, że wiązka promieni świetlnych wychodząca z punktu położonego poza osią optyczną tworzy obraz w kształcie przecinka. Często występującym w układach zniekształceniem optycznych, które ma najbardziej negatywny wpływ na ich przydatność do celów pomiarowych, jest dystorsja. Wyróżnia się dwa jej typy [SoA77]: dystorsję beczkową oraz poduszkową.



Rys. 3.2. Obraz: a) z widoczną dystorsją poduszkową, b) z widoczną dystorsją beczkową, c) prawidłowy


Dystorsja jest wadą optyczną, która polega na różnym stopniu powiększenia obrazu w zależności od odległości od osi optycznej soczewki. Zjawisko to powoduje zachwianie proporcji i zniekształcenia kształtów na obrazie. Ta wada optyczna najczęściej występuje w obiektywach zmiennoogniskowych. Im większy jest zakres zmian ogniskowej, tym wyraźniejsze są zniekształcenia. Dystorsja nie występuje w obiektywach typu ZOOM. Stałoogniskowe układy optyczne nie są pod tym względem idealne. Dystorsja także w nich występuje, jednakże wady te są zdecydowanie mniejsze.

Dystorsja beczkowa, przedstawiona na rys. 3.2 b, objawia się zaokrągleniem obrazu w większym stopniu z zewnątrz, co tworzy charakterystyczny beczkowy kształt obrazu siatki. Wada ta występuje w obiektywach szerokokątnych o krótkich ogniskowych. Dystorsja poduszkowa (rys. 3.2 c) jest natomiast odwrotnością beczkowej. Występuje w tym przypadku zaokrąglenie obrazu do środka kadru, co przypomina kształtem poduszkę. Wada ta jest charakterystyczna dla teleobiektywów, czyli obiektywów o długich ogniskowych.


Często w obiektywach aparatów ma się do czynienia z aberracją. Występują jej dwa typy: aberracja sferyczna i aberracja chromatyczna [SiZ84]. W przeciwieństwie do dystorsji, aberracja nie powoduje zmiany kształtu fotografowanych obiektów. Aberracja, zarówno sferyczna jak i chromatyczna mają wpływ, w mniejszym lub większym stopniu, na czytelność zdjęcia przez zmianę ostrości pewnych fragmentów obrazu. Występowanie aberracji jest powodem np. niemożliwości wskazania przez obserwatora,

homologicznych punktów kontrolnych na zdjęciach. Na takim zdjęciu obserwator może wskazać ich pozycje nieprecyzyjnie, co niekorzystnie wpłynie na jakość pomiarów.

W aberracji sferycznej (rys. 3.3) problem polega na tym, że obiektyw różnie ogniskuje promienie świetlne w zależności od ich położenia między środkiem a brzegiem układu optycznego. Im bardziej punkt przejścia światła zbliża się ku brzegowi urządzenia, czyli oddala się od jego osi optycznej, tym bardziej uginają się promienie świetlne. W modelu nieskończenie cienkiej soczewki pomija się jej grubość. W takim wypadku wszystkie padające na nią promienie, niezależnie od ich odległości od osi optycznej, skupiają się w jednym punkcie. W przypadku soczewki rozpraszającej mają one ognisko pozorne w jednym punkcie. Natomiast każda rzeczywista soczewka, której powierzchnie są sferami, ma skończoną grubość, dlatego występuje w niej aberracja sferyczna, zależna od rozmiarów soczewki i materiału, z którego jest wykonana. Efektem tego rodzaju aberracji jest spadek ostrości obrazu w całym polu widzenia.



Rys. 3.3. Aberracja sferyczna [Prwy19]



Rys. 3.4. Aberracja chromatyczna [Prwy18]

Aberracja chromatyczna [SiZ84] jest zjawiskiem podobnym do aberracji sferycznej, ponieważ problem dotyczy ogniskowania przez obiektyw. Główna różnica pomiędzy tymi dwiema aberracjami polega na tym, że nie chodzi o ogniskowanie

w zależności od miejsca na soczewce, ale od długości fali świetlnej. Zjawisko to przypomina rozszczepienie światła w pryzmacie. Światło o różnej barwie jest załamywane w obiektywie pod różnym kątem, najbardziej światło niebieskie, a najmniej czerwone.

3.3. Cyfrowe przetwarzanie obrazu

Klasyczne metody cyfrowego przetwarzania obrazu można podzielić na następujące grupy [TaR97]:

- przekształcenia geometryczne,
- przekształcenia punktowe (bezkontekstowe),
- przekształcenia kontekstowe,
- przekształcenia widmowe,
- przekształcenia morfologiczne.

Przekształcenia geometryczne polegają na transformacji geometrii obrazu, czyli na wykonaniu: obrotu, odbicia lub przesunięcia. Wykorzystywane są najczęściej do korygowania błędów powodowanych ograniczeniami optyki urządzenia rejestrującego takich jak dystorsje poduszkowe lub beczkowate. Mogą występować jako samodzielne transformacje, ale mogą także być wykorzystywane do wspomagania innych rodzajów przekształceń i analiz. Ich cechą charakterystyczną jest to, że nie zaburzają struktury punktów sąsiadujących w obrazie.

Przekształcenia punktowe realizowane są na pojedynczych punktach obrazu źródłowego niezależnie od stanu elementów sąsiadujących, w efekcie czego uzyskuje się również pojedyncze punkty obrazu wynikowego. Dzięki takiej regule operacje jednopunktowe (inaczej zwane anamorficznymi) mogą być wykonywane stosunkowo łatwo i szybko nawet na bardzo dużych obrazach. Operacje te mają za zadanie uwidocznienie pewnych elementów w obrazie nie wprowadzając żadnych nowych informacji do obrazu, ani nie zmieniając jego geometrii. Do najprostszych operacji punktowych można zaliczyć: utworzenie negatywu, rozjaśnienie lub zaciemnienie wybranych punktów. Bezpośrednio widocznym efektem przekształceń punktowych jest zawsze zmiana skali jasności obrazu bez zmiany geometrii widocznych na obrazie obiektów. Pomimo prostego charakteru przekształcenia punktowe bardzo radykalnie modyfikują subiektywne wrażenie, jakie uzyskuje się oglądając obraz, czasem prowadzi to do krańcowego zniekształcenia obrazu, jednak pozwala to wykryć lub uwypuklić pewne cechy obrazu praktycznie niewidoczne, gdy się ogląda obraz oryginalny. Operacje punktowe można też wykonać bezpośrednio na dwóch obrazach – jako ich dodanie, odjęcie, przemnożenie lub kombinacje liniową. Operacją punktową jest także operacja binaryzacji, która polega na zamianie obrazu mającego wiele poziomów szarości na obraz, którego piksele mają wyłącznie wartości 0 i 1.

Przekształcenia widmowe są podobne do filtracji kontekstowych, z tym że kontekstem używanym w operacjach jest cały obraz. W pierwszym etapie wyznacza się dwuwymiarowe widmo obrazu (najczęściej wykorzystując transformację Fouriera),

następnie wykonywana jest modyfikacja widma np. usunięcie określonych składowych obrazu. W kolejnym kroku wykonuje się rekonstrukcję obrazu z użyciem odwrotnej transformaty Fouriera. Metoda jest dosyć złożona obliczeniowo jednak pozwala na precyzyjne kontrolowanie skutków dokonywanych transformacji. Z punktu widzenia, jakości obrazów nie wnosi istotnie nowej jakości.

Przekształcenia morfologiczne różnią się od pozostałych tym, że element obrazu modyfikuje się w przypadku, gdy spełniony jest określony warunek logiczny. Przekształcenia morfologiczne są jednymi z najważniejszych operacji w cyfrowej analizie obrazu, ponieważ można je łączyć w zestawy pozwalające na bardziej złożone operacje związane z analizą kształtu elementów obrazu i ich wzajemnego rozmieszczenia. Głównym elementem stosowanym w przekształceniach morfologicznych jest element strukturalny obrazu. Jest to wycinek obrazu z wyróżnionym jednym punktem tzw. punktem centralnym. Każde przekształcenie morfologiczne można wykonać przy pomocy algorytmu składającego się z 3 etapów [TaR97]:

- element strukturalny jest przemieszczany po całym obrazie i dla każdego punktu obrazu wykonywana jest analiza koincydencji punktów obrazu i elementu strukturalnego, przy założeniu, że badany punkt obrazu jest punktem centralnym elementu strukturalnego,
- w każdym punkcie obrazu następuje sprawdzenie, czy rzeczywista konfiguracja pikseli obrazu w otoczeniu tego punktu zgodna jest z wzorcowym elementem strukturalnym,
- w przypadku wykrycia zgodności wzorca pikseli obrazu i szablonu elementu strukturalnego następuje wykonanie pewnej, ustalonej operacji na badanym punkcie; zazwyczaj jest to prosta zmiana koloru lub nasycenia jasności tego punktu, chociaż w ogólnym przypadku można założyć wykonanie dowolnej operacji.

Do dwóch najpopularniejszych operacji morfologicznych można zaliczyć erozję i dylatację. Operacja erozji polega na usunięciu wszystkich punktów obrazu o wartości 1, które posiadają choć jednego sąsiada o wartości 0. Erozję można także interpretować matematycznie jako tzw. filtr minimalny, to znaczy taki operator, w którym każdemu punktowi przypisuje się minimum z wartości jego sąsiadów. Dylatacja natomiast jest przeciwieństwem erozji. Do innych operacji morfologicznych można zaliczyć: otwarcie i zamknięcie, automedianę, detekcja ekstremów, ścienianie, szkieletyzację, obcinanie gałęzi, wyznaczanie centroidów, pogrubianie, wypukłe otoczenie oraz złożenia przekształceń morfologicznych.

Jedną z najważniejszych operacji przetwarzania obrazu jest jego filtracja. Zdarza się, że odbierany przez system wizyjny obraz jest zniekształcony, czego powodem jest zazwyczaj złe oświetlenie, wadliwie wyregulowana ostrość lub dodatkowe szумы. Odpowiednie przeprowadzenie filtracji daje możliwość wyodrębnienia istotnych cech, informacji z obrazu, do których nie było dostępu przed procesem filtracji. Filtry używane do analizy obrazów zakładają, że operacje na obrazie będą kontekstowe. Ogólnie filtracja polega na wykorzystaniu informacji z otoczenia danego piksela. Posiadając informację o bezpośrednim sąsiedztwie można z pewnym prawdopodobieństwem stwierdzić czy

dany piksel jest rzeczywistym odwzorowaniem obiektu, czy też powstał w wyniku działania szumu. Promień badania sąsiedztwa piksela może być różnych rozmiarów i związany jest z definicją maski. Gdy rozważany jest np. filtr, którego promień przetwarzania jest równy jeden powstanie macierz (tzw. maska) o wymiarze 3×3 .

Filtry wykorzystuje się do stłumienia w obrazie niepożądanego szumu, wzmocnieniu pewnych istotnych elementów zgodnych z określonym wzorcem. Podstawową klasyfikacją filtrów [TaR97, WoJ96] jest podział na filtry liniowe gdzie operacja filtracji wykonywana jest w oparciu o liniową kombinację wybranych pikseli oraz nieliniowe gdzie funkcja wybranych pikseli obrazu wejściowego jest nieliniowa. Przykładowe filtry liniowe to: spłot funkcji (konwolucja), spłot dyskretny, dolnoprzepustowy, górnoprzepustowy. Przykładem najprostszej funkcji nieliniowej są filtry logiczne polegające na badaniu wartości wyrażenia logicznego, które opisuje związki między punktami z dowolnie wybranego sąsiedztwa w zależności od potrzeb. Innym przykładem filtrów nieliniowych są filtry medianowe gdzie wartość wynikowa punktu jest medianą (wartością środkową) zbioru punktów z sąsiedztwa branych pod uwagę do filtracji. Filtr medianowy w przeciwieństwie do filtrów konwolucyjnych nie powoduje utraty informacji o krawędziach obiektów poprzez ich rozmywanie. Zaletą filtra jest to, że wszystkie wartości znacznie odbiegające od średniej są zupełnie pomijane przy wyznaczaniu nowej wartości punktu. Filtry medianowe bardzo często wykorzystuje się do usuwania szumu impulsowego [TaR97, PrW01], który jest zakłóceniem pojedynczych próbek sygnału. Przykładowym źródłem powstania takiego szumu jest matryca CCD aparatu cyfrowego, która może generować szum przy długich czasach ekspozycji.

3.4. Detekcja krawędzi

Detekcja krawędzi jest to technika segmentacji obrazu [TaR97, WoJ96, PrW01], która polega na znajdowaniu pikseli krawędziowych przez sprawdzanie ich sąsiedztwa. Jest ona istotnym elementem procesu przetwarzania i analizy obrazów. Jej celem jest zaznaczenie punktów cyfrowego obrazu, w których gwałtownie zmienia się luminancja. Ostre krawędzie na obrazie zazwyczaj odzwierciedlają ważne zdarzenia i zmiany w przedmiotach przedstawionych na zdjęciach. Zmiany luminancji mogą być wywołane: zmianą głębokości, zmianą orientacji powierzchni, zmianą właściwości materiału lub mogą być spowodowane różnorodnością oświetlenia scen. Otrzymywanie obrazu w postaci wyróżnionych krawędzi jest często wystarczające, a jednocześnie wygodne do przeprowadzenia logicznej interpretacji obrazu. Techniki detekcji krawędzi mają na celu znalezienie lokalnych nieciągłości w pewnych atrybutach obrazu, które odzwierciedlają granice obiektów znajdujących się na scenie. Nieciągłości, a więc i krawędzie, powstają w wyniku wystąpienia zmian właściwości i powierzchni obiektów, zmian w oświetleniu, cieni itp.

Krawędzie w głównej mierze zależą od punktu widzenia – czyli krawędzie, które mogą się zmieniać wraz ze zmianą punktu obserwacji, typowo odzwierciedlające geometrię scen np. otaczanie obiektów przez inne lub mogą być niezależne od punktu

patrzenia – odzwierciedlają one właściwości oglądanych obiektów takie jak znaki na powierzchni oraz kształty powierzchni. W przypadku dwu i więcej wymiarów powinno się wziąć pod uwagę rodzaj perspektywy. Typowymi krawędziami mogą być np. granicą pomiędzy dwoma kolorami lub też linia. W takim przypadku będzie po jednej krawędzi po każdej stronie linii. Detekcja krawędzi odgrywa ogromną rolę w wielu aplikacjach przetwarzania obrazu.

W ostatnich latach zostały przeprowadzone znaczące badania [DoM03, PrW01, WaLZ18, BiSH10, AkCT17] nad postrzeganiem świata przez maszyny, które to nie do końca polegają na detekcji krawędzi, jako pierwszym kroku przetwarzania. Krawędzie na obrazach cyfrowych przedstawiających świat rzeczywisty nie są przykładem idealnym. Przeważnie są one obciążone jednym bądź większą liczbą dalej wymienionych defektów [DoM03]: optycznym rozmazaniem spowodowanym skończoną głębokością obrazu, półcieniowym rozmazaniem spowodowanym przez cień powstały od źródła światła o niezerowym promieniu, cieniowaniem na obiektach o łagodnych krawędziach lub lokalnych odbiciach lub wewnętrznych odbiciach w krawędzi obiektu.

Doskonała, jednowymiarowa krawędź może więc być zdefiniowana jako nieciągła, skokowa zmiana pewnych atrybutów obrazu. Najczęściej stosowanymi metodami detekcji krawędzi są metody wykorzystujące operatory gradientowe aproksymujące pierwszą i drugą pochodną funkcji jasności obrazu. Działają na zasadzie splotu kilku sąsiednich pikseli z daną maską w wyniku czego wykrywana jest krawędź. Po wyliczeniu pochodnych, następnym krokiem jest zastosowanie progu, aby określić miejsca które rzeczywiście są krawędziami a nie szumem. Im niższy próg, tym więcej linii zostanie wskazanych i wynik będzie w dużej mierze zależał od szumu oraz wykrywane będą nieistotne szczegóły znajdujące się w obrazie. W przypadku zbyt wysokiego progu może dojść do przecoczenia niewyraźnych lub podzielonych linii. Obecnie wykorzystywanymi operatorami w detekcji krawędzi są dla:

- pierwszego rodzaju : krzyż Robertsa, Prewitt, Sobel, Canny, Scharr,
- drugiego rodzaju : Marr-Hildreth, detekcja przejścia przez zero drugiej pochodnej zmiany luminancji obrazu.

Obecnie operator Canny'ego lub wariacje tego operatora są najczęściej używaną metodą detekcji krawędzi. Opublikowana została duża liczba funkcji wykrywania krawędzi, ale – jak dotychczas – żadna z nich nie ukazała znaczącej przewagi nad operatorem Canny'ego w ogólnych sytuacjach. Podczas tworzenia algorytmu Canny zajmował się problemem stworzenia optymalnego filtra wygładzającego przed detekcją krawędzi. Wykazał on, że takim filtrem o dużej dokładności może być funkcja bazująca na pierwszej pochodnej funkcji Gaussa [DoM03, PrW01]. Metoda Canny optymalizuje trzy podstawowe kryteria [DiHG17]:

- minimalizuje liczbę błędnych detekcji – przy czym błędem detekcji jest zarówno detekcja krawędzi fałszywych (błędna odpowiedź pozytywna, false-positive detection), jak i pomijanie rzeczywistych krawędzi w obrazie (błędna odpowiedź negatywna, false-negative detection),
- zapewnia dokładną lokalizację krawędzi – punkt sklasyfikowany jako punkt krawędzi powinien być jak najbliższy środkowemu punktowi rzeczywistej krawędzi,

- generuje pojedynczą odpowiedź dla każdej rzeczywistej krawędzi w obrazie – jest to równoważne generowaniu krawędzi o grubości jednego piksela.

3.5. Rejestracja obrazów cyfrowych

Rejestracja jest procesem przekształcania różnych zestawów danych w jeden układ współrzędnych [ZiBF03]. Dane użyte w procesie rejestracji mogą być: wieloma zdjęciami (np. zdjęciami wykonanymi z różnymi głębokościami lub punktami widzenia), danymi z różnych czujników lub danymi pozyskanymi w różnym czasie. Rejestracja używana jest w: wizji komputerowej, obrazowaniu medycznym, w systemach wojskowych (np. w systemach automatycznego rozpoznawania celu), w analizowaniu obrazów i danych z satelitów [ZiBF03, VeBY03].

Metody rejestracji można podzielić według różnych kryteriów [ZiBF03, VeBY03, RoYT16, LaLC17, TaSC18] w zależności od sposobu wykonania zdjęć, które będą poddane procesowi rejestracji oraz rodzaju przekształceń, którym będą poddane w tym procesie.

W zależności od sposobu pozyskiwania obrazów można wyróżnić 4 ich grupy. Do pierwszej grupy zalicza się obrazy tej samej sceny, które są pozyskiwane z różnych punktów widzenia. Celem takiego działania jest uzyskanie szerszego widoku 2D lub uzyskanie reprezentacji 3D modelu zeskanowanej sceny. Przykładem zastosowania tej metody jest teledetekcja – mozaika obrazów z badanego obszaru.

Drugą grupę stanowią obrazy wykonane w różnym czasie (analiza wielostronna). Zdjęcia tej samej sceny są wykonywane w różnym czasie, często regularnie w tych samych lub w podobnych warunkach. Ich celem jest znalezienie i ocena zmian w scenie, które się pojawią pomiędzy kolejnymi momentami akwizycjami obrazów. Przykładami zastosowania mogą być monitorowanie globalnego użytkowania gruntów czy planowanie krajobrazu. Dzięki takiej metodzie rejestracji istnieje możliwość automatycznego wykrycia zmian w obrazach pozwalających monitorować bezpieczeństwo, śledzić ruch lub monitorować obrazowanie medyczne na potrzeby terapii leczniczej [VeBY03], np. ewolucję guza nowotworowego.

W trzeciej grupie stosuje się analizę multimodalną wykorzystując różne typy czujników lub aparatów. Celem takiego działania jest integracja informacji uzyskanych z różnych źródeł, w celu uzyskania bardziej złożonej i szczegółowej reprezentacji sceny. Takiego typu zdjęcia wykonuje się na potrzeby teledetekcji, obrazowania panchromatycznego, obrazowania medycznego.

W ostatniej czwartej grupie łączy się informację o modelu uzyskiwaną metodami klasycznymi (zdjęcia) z modelami komputerowymi, np. zdjęcia satelitarne z mapami komputerowymi. Tego typu rejestracji używa się także do teledetekcji danych lotniczych lub satelitarnych w mapach lub warstwach baz GIS, dopasowania szablonu w wizualizacji komputerowej w czasie rzeczywistym, automatycznej kontroli jakości produktów czy obrazowaniu medycznym do porównania obrazu pacjenta z cyfrową anatomią (klasyfikacja wzorów).

Ze względu na różnorodność rejestrowanych obrazów oraz ze względu na różne rodzaje ich degradacji niemożliwe jest zaprojektowanie metody uniwersalnej, którą można byłoby zastosować w wszystkich zadaniach rejestracyjnych [VeBY03]. Każdorazowo rejestracja powinna uwzględniać nie tylko założony typ geometrycznej deformacji pomiędzy obrazami, ale także odkształcenia np. radiometryczne, zniekształcenia, szum, dokładność rejestracji i dane zależne od cechy aplikacji.

Innym kryterium, jakie można zastosować może być podział metod rejestracji ze względu na rodzaj zastosowanej transformacji geometrycznej. Podczas poszukiwania optymalnego dopasowania można wyróżnić dwie grupy metod rejestracji [ZiBF03]:

- globalne – zachowujące wzajemne położenie poszczególnych pikseli względem siebie, które pozwalają na zastosowanie liniowych przekształceń, zwanych również przekształceniami sztywnymi, do których można zaliczyć operacje obracania, skalowania, itp.
- lokalne – umożliwiające deformację obrazu nakładanego, po to aby umożliwić lepsze dopasowanie poszczególnych obiektów, lecz nie przemieszczają pikseli względem siebie, przez co działają szybciej i zalecane są tam, gdzie położenie poszczególnych obiektów względem siebie nie uległo zmianie, a jedynie zmienia się punkt obserwacji tych obiektów.

Użycie algorytmów globalnych zazwyczaj ma miejsce, gdy akwizycja obiektów odbywała się z użyciem różnych urządzeń lub obiekt był obserwowany z różnych miejsc lub zmienił się kąt widzenia (np. zmiana obiektywu). Natomiast algorytmy lokalne najlepiej jest używać, jeśli dodatkowo zmianie uległ kształt lub forma badanego obiektu. Niezależnie od tego, jak algorytm będzie nakładał obrazy, to stosując podejście globalne należy przygotować jego implementację tak, aby można było bazować na wcześniej wyznaczonych cechach charakterystycznych obrazu lub też na wartościach intensywności wszystkich pikseli. Wśród cech charakterystycznych pomocnych podczas nakładania obrazów można wyróżnić punkty i linie zaznaczone przez użytkownika lub naniesione automatycznie przez dodatkowo skonstruowany algorytm. Przydatny może być również wynik detekcji krawędzi lub wstępna detekcja obiektów na obu obrazach. Natomiast w podejściu opierającym się na intensywności pikseli korzysta się z pełnej informacji o obrazie. W tym podejściu możliwe jest uzyskanie większej dokładności nałożenia obrazów, ale wymaga ona większej mocy obliczeniowej [GoA05].

Metody rejestracji mogą być także klasyfikowane w oparciu o poziom automatyzacji, który zapewniają. Opracowano metody interaktywne, półautomatyczne i automatyczne. Metody interaktywne udostępniają narzędzia do ręcznego ustawiania obrazów, zmniejszając subiektywizm użytkowników, wykonując pewne kluczowe operacje automatycznie, jednocześnie dając użytkownikowi możliwość kierowania rejestracją. Metody półautomatyczne wykonują więcej kroków, ale zależą od użytkownika, który weryfikuje poprawność rejestracji. Automatyczne metody nie pozwalają na interakcję z użytkownikiem i automatycznie wykonują wszystkie kroki rejestracji.

Ważnym etapem procesu rejestracji jest ocena miary podobieństwa do rejestracji obrazu. Podobieństwa obrazu są szeroko stosowane w obrazowaniu medycznym. Miara podobieństwa obrazu określa stopień podobieństwa wzorców intensywności na dwóch

obrazach [GoA05]. Wybór miary podobieństwa obrazu zależy od modalności rejestrowanych obrazów. Typowe przykłady pomiarów podobieństwa obrazu obejmują korelację krzyżową, wzajemne informacje, sumę kwadratowych różnic natężenia oraz jednorodność obrazu proporcji. Wzajemne informacje i znormalizowane wzajemne informacje są najpopularniejszymi miarami podobieństwa obrazów do rejestracji obrazów multimodalnych. Korelacja krzyżowa, suma kwadratowych różnic natężenia i jednorodność obrazu współczynnika są powszechnie stosowane do rejestracji obrazów w tej samej modalności.

Jedną z głównych metod rejestracji jest metoda punktowa. Używany w niej deskryptor wykorzystany jest do wyszukiwania korespondencji na obrazach [VeBY03]. Sposób dopasowania w tej metodzie jest bardzo szybki i wydajny. Główną wadą tego algorytmu jest proces obliczenia punktów odpowiadających sobie, zwłaszcza w przypadku, gdy nie są widoczne charakterystyczne elementy w obrazach.


3.6. Metody tworzenia modeli 3D obiektów

Model obiektu 3D można uzyskać na kilka sposobów, w zależności od zastosowanych narzędzi i sytuacji, w jakiej model ten należy pozyskać. Powszechnie znanym sposobem jest wykonanie modelu obiektu na podstawie dokumentacji technicznej w środowisku do komputerowego wspomaganie projektowania (CAD). Sposób ten jest tani i dokładny, gdyż w pełni osoba przygotowująca model panuje nad wykonaniem jego wszystkich elementów. Wadą tego rozwiązania jest czas potrzebny na wykonanie skomplikowanych obiektów. Każda konstrukcja, maszyna itd. posiada plany konstrukcyjne (zazwyczaj w dokumentacji papierowej) na ich podstawie można z 100% dokładnością przygotować wymagany model. Obecnie panuje także trend do przenoszenia dokumentacji z wersji papierowej na cyfrową, co ułatwia ich potencjalną modyfikację. Dzięki planom dokumentacji cyfrowej można swobodnie wykorzystywać takie modele do różnych zastosowań jak np. wizualizacje, dzięki zastosowaniu wymiany i kompatybilności plików między środowiskami CAD. W przypadku braku dokumentacji technicznej możliwe jest pomiarowe określenie wymiarów obiektu i sporządzenie modelu, co w przypadku skomplikowanych i dużych konstrukcji może być zadaniem czasochłonnym i skomplikowanym.

Często spotykanym i najtańszym rozwiązaniem jest użycie metod fotogrametrycznych, bazujących na co najmniej dwóch zdjęciach metrycznych lub niemetrycznych, pozyskiwanych z kamer fotograficznych [BeJM07, SiZ84]. Dzięki tej metodzie nie jest konieczne posiadanie dokumentacji wykonywanych obiektów, ale wadą tego podejścia jest fakt otrzymania informacji o stanie aktualnym obiektu, który to stan może się różnić od stanu projektowego. Fotogrametryczne podejście pozwala na zarejestrowanie całych scen, w których każdy z pikseli odpowiadać będzie określonemu fragmentowi przestrzeni. Celem metod fotogrametrycznych jest uzyskanie informacji przestrzennej drogą pomiarów, przetwarzania oraz interpretacji obrazów fotogrametrycznych. Istnieje wiele kryteriów podziału fotogrametrii np. ze względu na miejsce wykonywania pomiaru: naziemną, lotniczą, satelitarną [BeLF80]. By odtworzyć


wzajemne położenie obiektów na podstawie zdjęć konieczna jest wiedza pozwalająca określić orientację wewnętrzną aparatu.

Elementy orientacji zewnętrznej zdjęć można podzielić na dwie grupy [SwA77]. Najczęściej wykorzystuje się informacje o określeniu położenia osi kamery oraz płaszczyzny rzutów w przestrzeni przy pomocy trzech kątów (rys. 3.5): kąta nachylenia ω , skręcenia κ oraz zwrotu φ .



Rys. 3.5. Elementy orientacji zewnętrznej, kąty nachylenia ω , zwrotu φ i skręcenia κ

W celu określenia orientacji zewnętrznej wykorzystać można wzorce o znanych wymiarach umieszczone w fotografowanej scenie. Do wyznaczenia pozycji poszczególnych wzorców wykorzystuje się metodę równań kolinearności. Jest to metoda często stosowana w fotogrametrii lotniczej pozwalająca na obliczenie współrzędnych terenowych sfotografowanych punktów oraz określenie orientacji zewnętrznej zdjęcia. Graficzną prezentację metody kolinearności wektorów obrazuje rys. 3.6.



Rys. 3.6. Graficzna prezentacja zagadnienia kolinearności wektorów

Na rys. 3.6 obowiązują zależności geometryczne opisane równaniami 3.1 oraz 3.2. Współrzędne wektora r w układzie tłowym na zdjęciach opisuje się równaniem 3.1, zaś w układzie terenowym, wektor R ma współrzędne opisane równaniem 3.2 [BeJM07].

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

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

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

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

Układy współrzędnych – tłowy i terenowy są różnie zorientowane w przestrzeni, ich orientacja jest najczęściej opisywana w formie uwikłanej postaci macierzy A .

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

Warunek kolinearności wektorów R i r można zapisać równaniem 3.6.

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

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

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

$$\begin{aligned} x &= \frac{1}{\lambda} * \{a_{11} * (X - X_0) + a_{21} * (Y - Y_0) + a_{31} * (Z - Z_0)\} \\ y &= \frac{1}{\lambda} * \{a_{12} * (X - X_0) + a_{22} * (Y - Y_0) + a_{32} * (Z - Z_0)\} \\ -c_k &= \frac{1}{\lambda} * \{a_{13} * (X - X_0) + a_{23} * (Y - Y_0) + a_{33} * (Z - Z_0)\} \end{aligned} \quad (3.7)$$

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

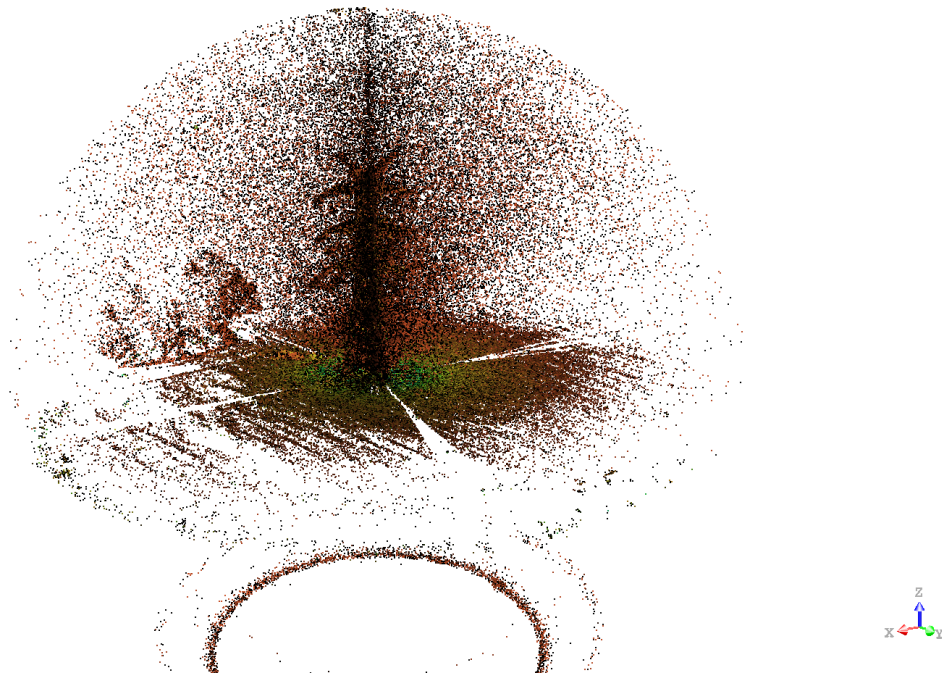
Opisane mechanizmy wykorzystuje komercyjne oprogramowanie do automatycznego tworzenia modeli. Tego typu oprogramowanie daje także możliwość tworzenia modeli 3D na podstawie zebranego materiału fotograficznego. W celu wykonania takiego modelu, konieczne jest przeprowadzenie zadań mających na celu eliminację opisanych wcześniej wad optycznych. Należy także posiadać zdjęcia wykonane w odpowiedni sposób, kolejne zdjęcia muszą być wykonane z zachowaniem przesunięcia kąтового nie większego niż 30° . Oprogramowaniem tego typu są: Photomodeller Scanner, Autodesk Recap, Photosynth lub ProFORMA. Każdy z programów daje inne możliwości generowania modeli, jednakże każdy wykorzystuje wykonane zdjęcia, na podstawie których wylicza pozycje aparatu, podczas wykonywania zdjęć i próbuje odwzorować fotografowany obiekt. Wynikiem działania tych programów jest obiekt typu mesh lub chmura punktów, którą można danej analizować w innych środowiskach.

Kolejnym sposobem uzyskania modelu 3D jest skaning laserowy. Zaletą tej metody pomiaru jest to, że przy pomiarze uzyskuje się reprezentację przestrzeni opisujących obiekty znajdujące się w zasięgu skanera. Głównym ograniczeniem tej metody jest problem pomiaru odległości do powierzchni, które nadmiernie odbijają czy też pochłaniają laserową wiązkę pomiarową. W takich miejscach punkty pomiarowe zostają

pominięte lub cechują się wyższym błędem pomiaru [BoN10]. Pomimo swoich ograniczeń i wysokiej ceny sprzętu skaning laserowy jest techniką pomiarową, która bardzo szybko pozyskujące nowe obszary potencjalnych zastosowań. Skaning laserowy najogólniej można podzielić na naziemny i lotniczy.

Skaning lotniczy jest metodą pozyskiwania danych 3D na bardzo dużych obszarach [BoN10, HeBB08]. Samo skanowanie wykonywane jest z samolotu. System lotniczy często wykorzystywany jest do weryfikacji położenia rozległych obiektów, dlatego też często wykorzystuje się go do weryfikacji położenia np. linii energetycznej w terenie leśnym i zurbanizowanym [BoN10].

Naziemny skaning laserowy cechuje się tym, że pomiar wykonywany jest z jednego punktu, a do skanera przypisany wcześniej lokalny układ współrzędnych XYZ, w którym zorientowane zostają dane z pomiaru. Skanery takie są w stanie pozyskać współrzędne milionów punktów oraz parametr w postaci intensywności odbicia wiązki, która zależna jest od odległości do punktu obiektu i współczynnika jego odbicia. Jednakże zdarza się, że dane ze skanera zawierają przytłaczającą liczbę punktów wywołanych szumem (rys. 3.7).




Rys. 3.7. Przykładowy skan konstrukcji wspacezej, zawierający ok 107 mln punktów

Metody triangulacyjne w skanerach polegają na bardzo precyzyjnym pomiarze kątów pomiędzy wszystkimi sąsiednimi punktami, a także długości co najmniej jednego boku w sieci, która składa się z trójkątów [MiS13]. Po obliczeniu i wyrównaniu wyników pomiarów, uzyskany pomiar służy do określenia współrzędnych wszystkich punktów, które wchodzi w skład sieci triangulacyjnej. Triangulację historycznie wykorzystywano do określenia współrzędnych wybranych punktów w terenie. Pomiar triangulacyjny wykorzystuje tę szczególną właściwość trójkąta, że znajomość jednego boku i dwóch kątów jest wystarczająca, aby stworzyć całą konstrukcję trójkąta. Ważny jest także fakt, że pomiar terenowy kątów jest znacznie prostszy niż pomiar odległości. Triangulację stosowano przede wszystkim do bardzo dokładnego pomiaru kraju, przy konstrukcji map


topograficznych. Aktualnie w triangulacji wykorzystywane są najnowsze techniki tj. satelitarne (GPS).

Metody triangulacyjne można podzielić na kilka grup, pierwszą z nich są systemy z zastosowaniem wiązki laserowej. System składa się z lasera, który oświetla obiekt linią pomiarową oraz detektora, który rejestruje jej położenie, zasadę działania takiego systemu przedstawiono na rys. 3.8.



Rys. 3.8. Zasada działania systemu z zastosowaniem wiązki laserowej [ToR07]


Istnieje również grupa metod wykorzystująca wzorce świetlne, które rzutowane są na badaną powierzchnię. Znając kierunek promieni – od źródła wzorca i od kamery do punktu obrazu wzorca rzutowanego na powierzchnię ciała pozwalały drogą triangulacji na wyznaczenie przestrzennych współrzędnych [ToR07]. Metody te znalazły szerokie zastosowanie w medycynie, pozwalając ocenić stan zdrowia pacjenta czy też zastosowanie w badaniach dotyczących budowy anatomicznej [ToR07, NeI88]. Szeroko rozpowszechnioną metodą jest metoda prążków Moire'a. Polega ona na projekcji prążków jasnych i ciemnych na przemian na obiekcie (rys. 3.9).



Rys. 3.9. Zasada działania systemu z wykorzystaniem wzorca świetlnego [ToR07]

Możliwe jest także zastosowanie dwóch lub większej ilości kamer śledzących punkty kluczowe w scenie. Dla przyspieszenia identyfikacji punktów kluczowych na obiekcie

najczęściej oświetla się go rastrem. Zasadę działania takiego systemu przedstawiono na rys. 3.10.



Rys. 3.10. Zasada działania systemu z wykorzystaniem wzorca świetlnego oraz dwóch kamer [ToR07]

3.7. Metody detekcji obiektów w obrazach 2D i ich cech

Głównym problemem detekcji obiektów w obrazach cyfrowych jest zastosowanie metody, która dopasuje szukany element do zdefiniowanego wzorca. Jedną z metod detekcji kształtów w obrazie poprzez stopniowe kumulowanie wiarygodności jest transformata Hougha. Na jej wejściu podawany jest obraz z wykrytymi punktami konturów poprzez zastosowanie funkcji detekcji krawędzi, następnie obraz poddawany jest transformacji. Oryginalna metoda Hougha służy do wykrywania prostych, jednakże metodę tę później uogólniono na wykrywanie kształtów dających się opisać analitycznie np. okręgów lub dowolnych kształtów [DeS81, DuRH72, GoBS12].

Metody rozpoznawania kształtów, inaczej zwane metodami obiektów konturowych, dzielą się na trzy grupy:

- identyfikację – która polega na rozpoznawaniu dokładnie tego samego obiektu pobranego z bazy danych na podstawie znanych przykładów;
- wyszukiwaniu podobieństw, metoda ta polega na wyszukaniu w bazie danych podobnego obiektu lub kilku obiektów bez przypisywania ich do konkretnej kategorii;
- klasyfikacji, a inaczej mówiąc nazywaniu - metoda ta polega na dopasowaniu do klasy obiektów o podobnych cechach, ale bez przyporządkowania ich konkretnego egzemplarza w klasie.

Najbardziej popularna metoda klasyfikacji bazuje na deskryptorach kształtu (reprezentacji odpornej na wiele zniekształceń, głównie geometrycznych i afinicznych). W tych analizach konieczne jest posiadanie dużej bazy danych wzorców, z której wynik sortowany jest wg. współczynnika podobieństwa.

W przypadku ogólnej analizy kształtu proces rozpoznawania zachodzi na wyższym poziomie abstrakcji niż ma to miejsce w przypadku rozpoznawania kształtów. W przypadku tej analizy obiekt nie należy do jednej klasy, a może być do niej jedynie podobny. Odpowiedź jaką uzyskuje się przy użyciu tej metody jest jedna lub kilka klas, które są podobne do badanego obiektu. Stosuje się ją w przypadkach, gdy granice klas nie są wyraźnie określone lub w przypadku rozmytych problemów rozpoznawania. Klasyfikacja obiektów ze względu na kształt odbywa się na podstawie szeregu cech, będących inwariantami skali, rotacji i translacji. Istnieją następujące klasyfikatory kształtu: krągłość, kwadratura, współczynnik proporcji, rozciągłość. Inne cechy (eliptyczność, wariancja cyrkulacji, wariancja eliptyczna, trójkątność, minimalna figura otaczająca) wykorzystują inwarianty (niezmienniki) momentu drugiego rzędu.

Do najpopularniejszych deskryptorów złożonych można zaliczyć [FrDN10]:

- sygnaturę kształtu (Shape Signature),
- deskryptor Fouriera (Fourier Descriptor),
- momenty Zernike'a (Zernike Moments),
- kontekst kształtu (Shape Context),
- przestrzeń wieloskalową krzywizn (Curvature Scale Space).

Przykładowo algorytm na sygnaturę kształtu przedstawia się następująco:

- wykrycie zewnętrznego konturu,
- obliczenie środka ciężkości (centroidu),
- obliczenie odległości punktów na konturze od środka ciężkości – zapisanie w wektorze,
- sortowanie względem rosnącego kąta względem osi OX,
- znalezienie maksimum odległości i cykliczne przesunięcie wartości, tak aby znalazło się na pierwszej pozycji w wektorze,
- normalizacja względem maksimum,
- opcjonalna interpolacja do wymaganej długości.

Większość algorytmów rozpoznawania/klasyfikacji kształtu operuje w wielowymiarowej przestrzeni cech i wykorzystuje uproszczoną charakterystykę obiektów. Istotne wtedy jest, aby zebrać zróżnicowane charakterystyki kształtu, np. zewnętrzny kontur i wewnętrzną strukturę w pojedynczym deskrytorze o niskiej wymiarowości.

3.8. Podsumowanie rozdziału

Rozdział prezentuje aktualne możliwości z zakresu akwizycji i przetwarzania obrazów cyfrowych. Scharakteryzowane zostały problemy związane z akwizycją obrazów, z szczególnym uwzględnieniem błędów optyki urządzeń rejestrujących. Szczegółowo opisano możliwości oraz techniki związane z akwizycją danych na podstawie, których można utworzyć trójwymiarowy model obiektu. Przedstawiono ich wady i zalety. Dokonano także syntetycznej analizy metod detekcji wybranych cech w obrazach cyfrowych.

Rozdział ten miał na celu przedstawienie obecnego stanu wiedzy z zakresu pozyskiwania i analizowania obrazów cyfrowych, ze szczególnym uwzględnieniem metod, które zostały wykorzystane w pracy badawczej.

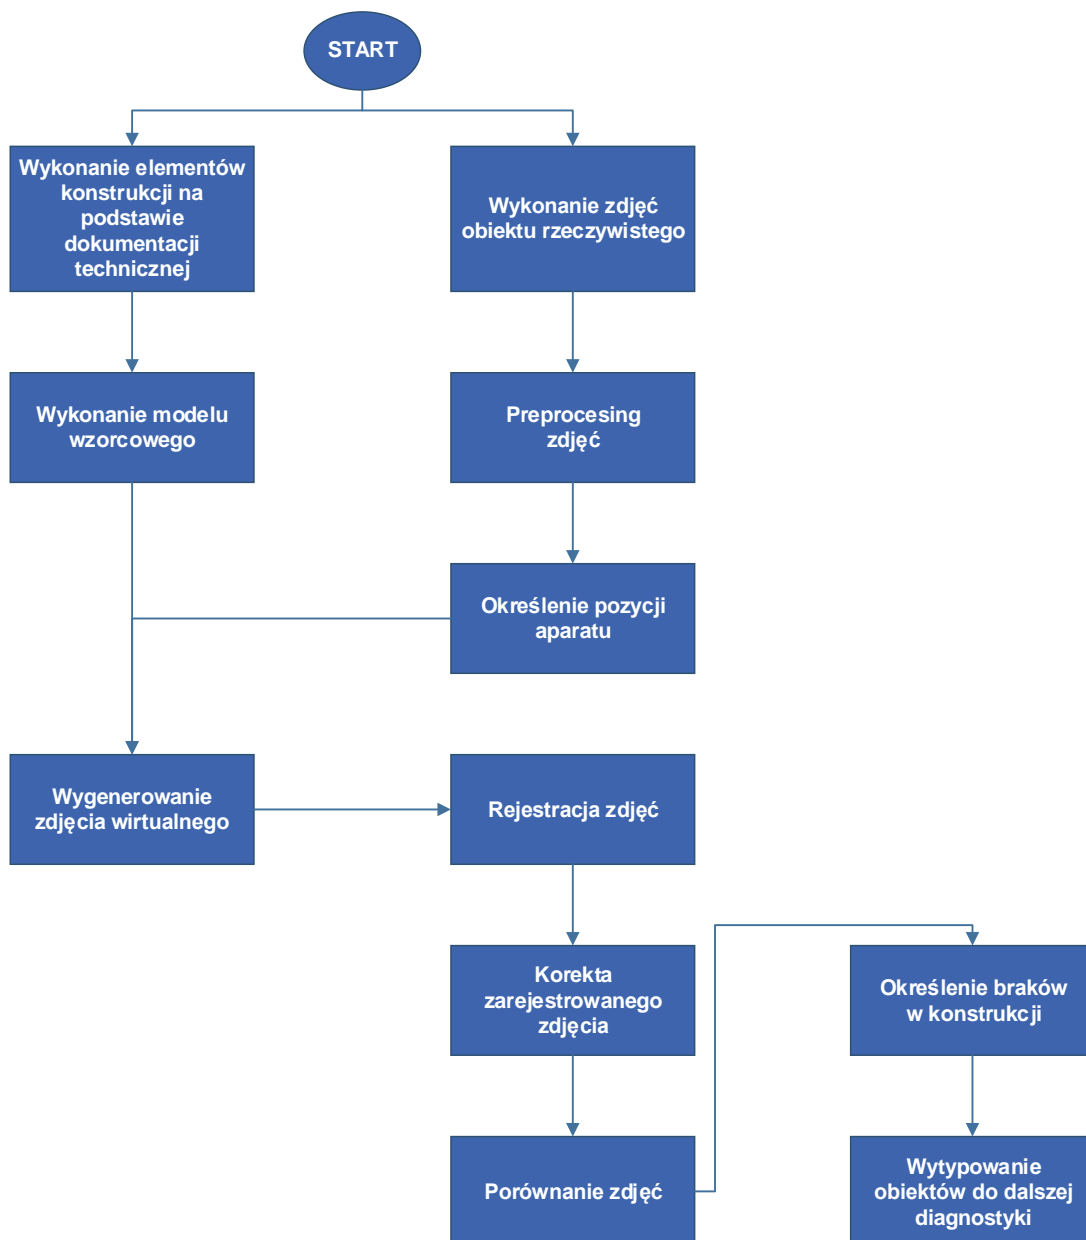
4. Metoda zdjęć wirtualnych

4.1. Proponowany algorytm

Głównym celem opracowanej metody, której algorytm przedstawiono na rys. 4.1 jest identyfikacja wybranych elementów obiektu na zdjęciach metrycznych, dysponując jego modelem 3D. Jak wspomniano we wprowadzeniu, badanymi obiektami są konstrukcje wsporcze linii elektroenergetycznej. Aby było możliwe analizowanie zdjęć pod kątem stwierdzenia braków w konstrukcji, potrzebna jest baza reguł oraz informacji o ich projektowym (wzorcowym) stanie, z którą będzie porównywany zebrany materiał fotograficzny.

Taką bazę można w łatwy sposób wykonać. Budowa poszczególnych konstrukcji jest znana, dlatego na podstawie dokumentacji technicznej można wykonać modele wzorcowe kratownic. Finalnym efektem działania opracowanego algorytmu jest wytypowanie słupów (obrazów z uszkodzoną konstrukcją), które wymagają dalszej uwagi w procesie diagnostyki.

Po wykonaniu zdjęć obiektu rzeczywistego konieczne jest odpowiednie ustawienie widoku kamery w środowisku CAD, aby móc dokonać porównania budowy badanego obiektu. W tym celu na podstawie zdjęcia rzeczywistego z wykorzystaniem metod fotogrametrycznych można wyznaczyć współrzędne punktu, z którego wykonano zdjęcie. Na tym etapie wyliczyć można także elementy orientacji wewnętrznej urządzenia rejestrującego. Następnie w środowisku CAD wirtualna kamera jest umieszczana w przestrzeni w odpowiednim punkcie, dzięki czemu otrzymuje się widok wzorcowego słupa z ustawieniem takim jak na zdjęciu rzeczywistym.




Rys. 4.1. Algorytm metody zdjęć wirtualnych

Następnym etapem analizy takich zdjęć jest wykonanie operacji ich różnicy (zdjęcia rzeczywistego i wirtualnego). W przypadku istniejących braków w rzeczywistym obiekcie otrzymamy obszar pikseli, składający się na brakujące fragmenty słupa. W przypadku braku uszkodzeń w rzeczywistej kratownicy, po sprawdzeniu kompletności, algorytm podaje informacje o właściwym stanie słupa. Jeżeli wykryte zostaną jakieś braki pojawi się informacja o błędzie w konstrukcji, dodatkowo zostanie na zdjęcie rzeczywiste naniesiona informacja, która część kratownicy wymaga dalszej uwagi w procesie diagnostycznym.

4.2. Wykonanie modelu wzorcowego oraz zdjęć rzeczywistych

Każda kratownica konstrukcji wsporczej jest obiektem wykonanym na podstawie dokumentacji technicznej. Konstrukcje te są obiektami powtarzanymi w ujęciu całej linii, dlatego w celu zbudowania całej bazy słupów należy wykonać kilkadziesiąt ich modeli. Modele proponuje się wykonać w środowisku Autodesk Inwrtor lub AutoCAD.


Autor swoje badania skupił na analizie najczęściej występującej konstrukcji słupów linii 220 kV. Jako obiekt do badań przyjęto słup odporowo-narożny serii H52.



Rys. 4.2. Słup odporowo-narożny H52 – rysunek techniczny [DTech07]

Model przedstawionego na rys. 4.2 słupa zamodelowano w środowisku Autodesk Inventor. Modelowaniu poddano wszystkie kątowniki składające się na konstrukcję wsporczą (z pominięciem śrub mocujących). Kompletny model konstrukcji składa się

z 706 elementów. Tak przygotowany model importowano do środowiska AutoCAD w celu generowania zdjęć wirtualnym. Alternatywą może także być wygenerowanie zdjęć w środowisku Matlab (w tym celu należy zaimportować obiekt z formacie .stl).



Rys. 4.3. Wykonany model konstrukcji w środowisku CAD

Wykonany model (w opisie matematycznym M_I), który przedstawiono na rys. 4.2 został przygotowany w ramach realizacji pracy magisterskiej pt. *Budowa i wydruk modelu geometrycznego słupa linii elektroenergetycznej w programie Autodesk Inventor* [KuD16]. Wydrukowany model posłużył także jako obiekt, do wykonania zdjęć rzeczywistych (4.1).

$$f_{RGB}^{11} = f(x, y) \quad (4.1)$$



Rys. 4.4. Przykładowe zdjęcia badanego obiektu laboratoryjnego

Zdjęcia rzeczywiste wykonano aparatami fotograficznymi marki Canon EOS 30D z obiektywem zmiennoogniskowym o $f=24\div 60$ oraz Fujifilm X20 z obiektywem stałoogniskowym o $f=18$. Zdjęcia z obydwu aparatów różniły się ogniskową obiektywu oraz uzyskaną rozdzielczością. Przykładowe zdjęcie przedstawiono na rys. 4.4.

4.3. Preprocessing zdjęć rzeczywistych


Przed poddaniem dalszej analizie zdjęcia rzeczywiste obiektów należy poddać preprocessingowi. W omawianych badaniach przez preprocessing rozumie się usunięcie dystorsji, którą każde zdjęcie jest obciążone. Proces ten jest istotny zwłaszcza dla zdjęć, na których obiekt zajmuje większość powierzchni zdjęcia oraz fragmenty obiektu znajdują się blisko krawędzi obrazu (obszary szczególnie narażone na zniekształcenia).

Aby prawidłowo wykonać operację usunięcia zniekształceń obiektywu, należy w pierwszym kroku przeprowadzić operację kalibracji urządzenia, którym wykonywano zdjęcia. W trakcie procesu kalibracji określa się elementy orientacji wewnętrznej, które są niezbędne do poprawnej rekonstrukcji wiązki promieni. Są nimi [BeJ08]:

- stała kamery (c_k);
- współrzędne punktu głównego w układzie znaczków tłowych (x_0, y_0 lub x_0, z_0);
- parametry dystorsji;
- współrzędne znaczków tłowych.

Dane te uzyskuje się porównując terenowe współrzędne punktów (lub znane kierunki) z ich współrzędnymi w płaszczyźnie tłowej. Punktami znanymi są zazwyczaj punkty pola testowego, albo punkty rzutowane przez laboratoryjny kalibrator kamer.

W przeprowadzonych badaniach używano planszy kalibracyjnej, którą była szachownica składająca się z 70 czarnych i białych kwadratów o boku równym 31 mm. Zależności pomiędzy znanymi kierunkami i współzrędnymi tłowymi (rys. 4.5) – pozwalają obliczyć elementy orientacji wewnętrznej.



Rys. 4.5. Wyznaczanie elementów orientacji wewnętrznej kamery naziemnej z użyciem planszy kalibracyjnej [BeJ08]

$$\operatorname{tg} \alpha = \frac{a + x_o}{c_k} \quad (4.2)$$

$$\operatorname{tg} \alpha_2 = \frac{\Delta x_{1-2} - a - x_o}{c_k} \quad (4.3)$$

$$\operatorname{tg} \alpha_3 = \frac{\Delta x_{1-3} - a - x_o}{c_k} \quad (4.4)$$

Porównanie znanych kątów poziomych (α_i) z pomierzonymi różnicami pomiędzy współzrędnymi tłowymi (Δx_i) pozwala określić c_k oraz x_o . Jeśli punkty są rozmieszczone w pionie, to podobnie – znając kąty pionowe β_i można wyznaczyć z_o . Pole testowe złożone z wielu punktów rozmieszczonych w całym kadrze pozwala określić nie tylko x_o , z_o i c_k , ale także odchyłki – spowodowane dystorsją obiektywu.

Do opisu modelu matematycznego kamery stosowane są równania 4.5 opisujące rzut środkowy:

$$\begin{aligned} x &= c_k \frac{X}{Y} \\ y &= c_k \frac{Y}{Z} \end{aligned} \quad (4.5)$$

Dystorsja uwzględniana jest jako poprawki do równań rzutu środkowego. Istnieje kilka opisów matematycznych dystorsji – najbardziej ogólny przedstawia układ równań (4.6).

$$\begin{aligned}
x_u &= x_0 + (x_d - x_0)(1 + k_1 r_d^2 + k_2 r_d^4 + \dots) + \\
&+ p_1 [2(x_d - x_0) + r_d^2] + 2p_2 (x_d - x_0)(y_d - y_0) \\
y_u &= y_0 + (y_d - y_0)(1 + k_1 r_d^2 + k_2 r_d^4 + \dots) + \\
&+ p_2 [2(y_d - y_0) + r_d^2] + 2p_1 (x_d - x_0)(y_d - y_0)
\end{aligned}
\tag{4.6}$$

Parametry k_1, k_2, \dots określają dystorsję radialną, natomiast parametry p_1 i p_2 odpowiadają za tzw. dystorsję tangencjalną, która w pracy zostaje pominięta, w związku z czym otrzymujemy nieskończone ciągi:

$$\begin{aligned}
x_u &= x_d(1 + k_1 r_d^2 + k_2 r_d^4 + \dots) \\
y_u &= y_d(1 + k_1 r_d^2 + k_2 r_d^4 + \dots)
\end{aligned}
\tag{4.7}$$

lub


$$r_u = r_d(1 + k_1 r_d^2 + k_2 r_d^4 + \dots) \tag{4.8}$$

W praktyce uwzględnienie tylko pierwszego współczynnika koryguje 90% zniekształceń dystorsji [BeJ08]. Tak więc przy założeniu, że początek układu jest umieszczony w punkcie najlepszej symetrii, równania te zapisywane są w postaci:

$$\begin{aligned}
x_u &= x_d + \Delta x \\
y_u &= y_d + \Delta y
\end{aligned}
\tag{4.9}$$

gdzie


$$\begin{aligned}
\Delta x &= x_d(k_1 r_d^2) \\
\Delta y &= y_d(k_1 r_d^2)
\end{aligned}
\tag{4.10}$$



Rys. 4.6. Błąd odwzorowania punktu (Δr) spowodowany dystorsją radialną obiektywu: a) w płaszczyźnie osi kamery, b) w płaszczyźnie obrazu [BeJ08]

Przy ścisłej prostopadłości płaszczyzny tłowej do osi optycznej obiektywu, występuje dystorsja radialna – symetryczna względem punktu głównego O' . Oznacza to, że wszystkie punkty odwzorowane w takiej samej odległości (r) od O' są przesunięte radialnie o taką samą wielkość – Δr (rys. 4.6). Kątowa wartość dystorsji radialnej $\Delta\alpha$, będąca różnicą między kątem α – odchylenia promienia wchodzącego do obiektywu od osi optycznej i kątem α' – odchylenia promienia wychodzącego, jest wielkością stałą dla

danego obiektywu i danego kąta α (rys. 4.6 a). W płaszczyźnie tłowej można zaobserwować liniową wielkość dystorsji Δr (rys. 4.6 b).



Rys. 4.7. Rozkład wektora dystorsji na składowe: radialną (Δr) i tangencjalną (Δt) [BeJ08]

Z powodu niecentrycznego usytuowania soczewek i nieprostotpadłości płaszczyzny tłowej względem osi optycznej – kierunek wektora dystorsji nie przechodzi przez O' (rys. 4.7). Błąd dystorsji określają wtedy dwie składowe: radialna (Δr) – w kierunku radialnym i tangencjalna (Δt) – w kierunku prostopadłym do radialnego. Wobec zaburzenia symetrii dystorsji, punkt główny O' przestaje być punktem centralnym (radialnym). Do szczegółowych analiz przyjmuje się wtedy punkt najlepszej symetrii dystorsji S' – względem którego symetria składników dystorsji jest najlepsza. We współczesnych obiektywach fotogrametrycznych odległość $O'S'$ jest mniejsza od 0,01 mm, a wielkość składnika tangencjalnego nie przekracza $2 \mu\text{m}$ [BeJ08].

Dystorsji obiektywu kamery pomiarowej rozpatruje się w odniesieniu do stałej kamery, ponieważ obie wielkości są wzajemnie powiązane funkcyjnie, dlatego też wartość c_k i poprawki dystorsji wyznacza się w procesie kalibracji kamery równocześnie korzystając z równania (4.11).

$$\Delta r = r - c_k \operatorname{tga} \quad (4.11)$$

Poprawienie współrzędnych tłowych punktu na zdjęciu ze względu na błąd dystorsji można przeprowadzić różnymi sposobami [BeJ08, PoP04]:

- metodą interpolacyjną;
- metodą tabelaryczną;
- metodą wielomianową.


Metoda interpolacyjna jest często stosowana do korygowania dystorsji radialnej. Tworzy się w niej tabelę wartości promieni radialnych i odpowiadających im wartości dystorsji. Dla danej wielkości promienia radialnego (r) wartość dystorsji Δr jest interpolowana z dwóch pól tabeli, pomiędzy którymi mieści się wartość r .

Metoda tabelaryczna zakłada, że w pewnych elementarnych fragmentach obrazu (np. w kwadratach o wymiarach 31x31 mm) wartość dystorsji jest stała. Poprawienie współrzędnych punktu o błąd dystorsji polega na odszukaniu odpowiedniego pola tabeli (stosownie do współrzędnych tłowych punktu) i znalezieniu właściwych poprawek do współrzędnych tłowych.

Ostatnia metoda (wielomianowa) jest najdokładniejsza. Z różnych postaci, które może przyjmować wielomian przybliżający rozkład dystorsji, najpopularniejsza jest postać wielomianu [PoP04]:

$$\Delta x = \frac{x}{r} \{ (k_1 r^3 + k_2 r^5 + k_3 r^7 + \dots) + [(r^2 + 2x^2) p_1 + 2xz p_2] (1 + p_3 r^2 + \dots) \} \quad (4.12)$$

$$\Delta z = \frac{z}{r} \{ (k_1 r^3 + k_2 r^5 + k_3 r^7 + \dots) + [2xz p_1 + (r^2 + 2z^2) p_2] (1 + p_3 r^2 + \dots) \} \quad (4.13)$$



Rys. 4.8. Przykładowe zdjęcie po usunięciu dystorsji



Rys. 4.9. Nałożenie zdjęcia przed i po procesie usunięcia dystorsji


W przeprowadzonych badaniach zastosowano funkcje programu Matlab *cameraCalibrator* w celu wykonania kalibracji kamery. Dystorsję z wykonanych zdjęć (przykładowe przedstawiono na rys. 4.4) usunięto przy pomocy funkcji *undistortImage*, która używa metody tabelarycznej w procesie usuwania dystorsji. Przykładowy efekt przedstawiono na rys. 4.8, w wyniku usunięcia dystorsji przy krawędziach pojawiły się charakterystyczne czarne obszary, które stanowią dopełnienie zdjęcia. W modelu obraz po operacji usunięcia dystorsji oznaczono jako (4.14).

$$f_{RGB}^{21} = f(x, y) \quad (4.14)$$

Na rys. 4.9 przedstawiono nałożone obrazy przed i po wykonaniu operacji usunięcia dystorsji. Można zaobserwować zmiany jakie nastąpiły w umiejscowieniu elementów kratownicy, zwłaszcza w obszarach przy krawędzi obrazu.

4.4. Określenie pozycji kamery

Istotnym elementem prawidłowego działania metody jest określenie pozycji z jakiej zostały wykonane zdjęcia obiektu rzeczywistego (P_1).




Rys. 4.10. Geometria epipolarna – idea działania [MaGA04]

Parametry wewnętrzne kamery są charakterystyczne dla danego urządzenia, a ich wartości nie zależą od obserwowanej sceny. Kamera charakteryzowana jest przez macierz A parametrów wewnętrznych (4.15). Parametry te są związane z wymiarami czujnika oraz ogniskową obiektywu. Najczęściej zakłada się, że układ jest symetryczny, czyli $f_x \approx f_y$, a punkt centralny c pokrywa się ze środkiem matrycy.

$$A = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (4.15)$$

Do parametrów wewnętrznych zalicza się także współczynniki zniekształceń radialnych r_1, r_2, r_3 oraz tangensoidalnych p_1, p_2 .

Parametry zewnętrzne kamery wyznaczają układ współrzędnych związany z obserwowaną sceną. Jego dobór jest bezpośrednio powiązany z układem współrzędnych kamery poprzez macierz rotacji R oraz wektor translacji T . Projektacja obrazu punktu z przestrzeni 3D na matrycę czujnika kamery opisana jest najczęściej przez tzw. model punktowej kamery perspektywicznej (ang. pin hole camera), który przedstawiono na rys. 4.11 [JaM11, MaGA04]. Czynniki z^{-1} powoduje zniekształcenia wymiarów wzdłuż osi optycznej kamery oraz opisuje przesłanie obiektów.



Rys. 4.11. Model punktowej kamery perspektywicznej [MaGA04]

$$\begin{bmatrix} x' \\ y' \\ 1 \end{bmatrix} = z^{-1} \begin{bmatrix} x \\ y \\ z \end{bmatrix} = R \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} + T = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{33} \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} + \begin{bmatrix} t_1 \\ t_2 \\ t_3 \end{bmatrix} \quad (4.16)$$

$$\begin{bmatrix} x'' \\ y'' \\ 1 \end{bmatrix} = \begin{bmatrix} x'(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) + 2p_1 x' y' + p_2 (r^2 + 2x'^2) \\ y'(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) + 2p_2 x' y' + p_1 (r^2 + 2y'^2) \\ 1 \end{bmatrix} \quad (4.17)$$

$$r^2 = x'^2 + y'^2 \quad (4.18)$$


$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = A \begin{bmatrix} x'' \\ y'' \\ 1 \end{bmatrix} \quad (4.19)$$

Wpływ obiektywu o skończonych rozmiarach, wprowadzającego zniekształcenia geometryczne opisują równania 4.17, 4.18. W przypadku pominięcia tego efektu należy przyjąć $x'' = x'$ oraz $y'' = y'$.

Ważnym krokiem w procesie wyznaczania parametrów kamery jest proces konfiguracji sceny. Polega on na automatycznej lub ręcznej (dokonanej przez operatora) identyfikacji punktów charakterystycznych istotnych elementów sceny. Elementy te muszą się charakteryzować znanymi wymiarami. Ułatwia to proces konfiguracji sceny. Punkty płaskich obszarów widoczne w obrazie kamery można jednoznacznie określić w układzie współrzędnych związanych ze sceną pod warunkiem znajomości A , R i T . Do niwelacji perspektywy wystarczy znajomość macierzy homografii H [Zaz00]. Zastosowanie transformacji odwrotnej z udziałem macierzy H pozwala zniwelować zniekształcenia wynikające z projekcji perspektywicznej (4.20) płaszczyzny elementu

sceny na powierzchnię czujnika kamery z dokładnością współczynnika skalującego z^{-1} . Punktem $[u,v]$ w układzie kamery można przyporządkować współrzędne w układzie związanym z wybraną płaszczyzną sceny $[X,Y]$ i odwrotnie [JaM11].

$$s \begin{bmatrix} u \\ v \\ 1 \end{bmatrix} = \frac{1}{z} A \begin{bmatrix} x \\ y \\ z \end{bmatrix} = H \begin{bmatrix} X \\ Y \\ 1 \end{bmatrix} = A \begin{bmatrix} r_1 & r_2 & T \end{bmatrix} \begin{bmatrix} X \\ Y \\ 1 \end{bmatrix} \quad (4.20)$$




Rys. 4.12. Podstawowe elementy dla punktowej kamery perspektywicznej [MaGA04]

Opisany model matematyczny został zaimplementowany do środowiska Matlab, po czym zostały przeprowadzone testy na wykonanych w warunkach laboratoryjnych zdjęciach.

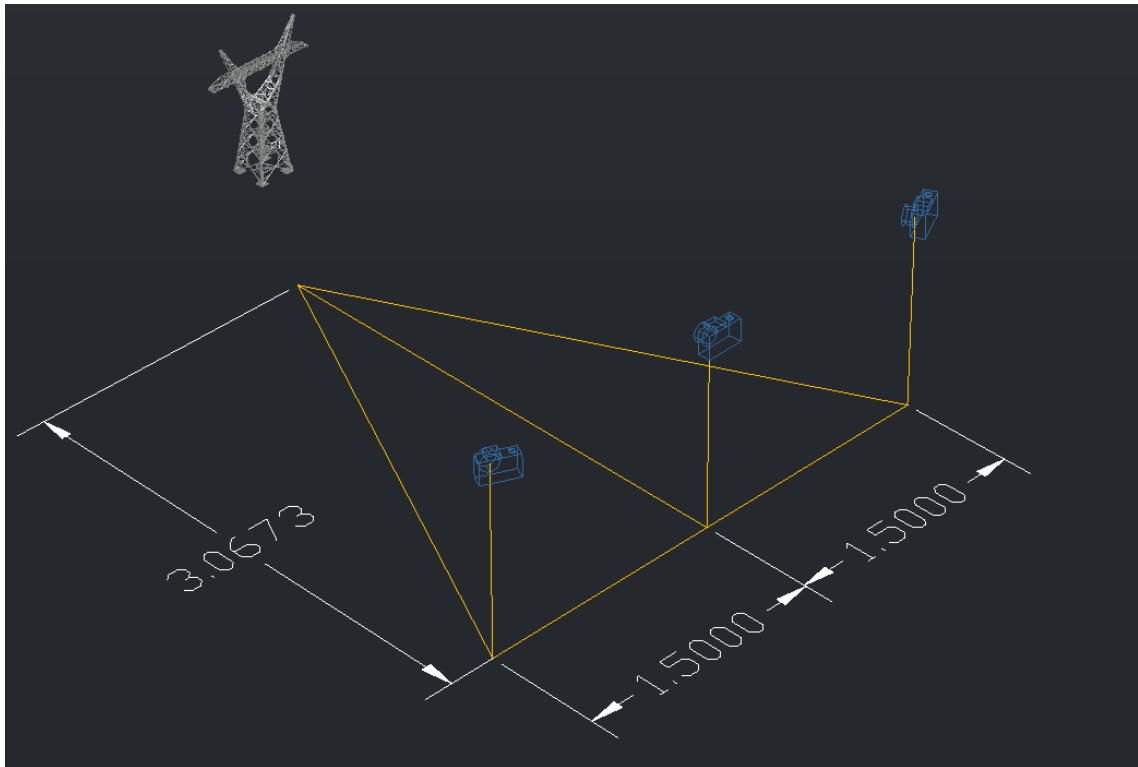
Obiektem analiz był wydrukowany na drukarce 3D model konstrukcji słupa (rys. 4.13). Zdjęcia zostały wykonane w ściśle określonych warunkach – przy znanych parametrach kamery oraz określonych odległościach kamery od obiektu w przestrzeni sceny (rys. 4.14). Kamera została umieszczona tak, aby oś obiektywu znajdowała się w miejscu blachy łączącej ramiona konstrukcji (czerwony punkt na rys. 4.13). Kamera znajdowała się w odległości 3,0673 m od obiektu. Kolejne zdjęcia wykonane zostały w różnych pozycjach (przedstawionych na rys. 4.16). Pozycje znajdują się na linii bazowej w odległości 1,5 m od siebie, przy jednoczesnym zachowaniu tej samej odległości od obiektu i tym samym punkcie w osi obiektywu. Zdjęcia zostały wykonane aparatem Canon z obiektywem o $f=24$.




Rys. 4.13. Badany obiekt – wydrukowany model słupa



Rys. 4.14. Określone odległości kamery od obiektu, celem zachowania powtarzalności wykonywanych zdjęć (czarne znaczniki oznaczają umiejscowienie nóg statywu)



Rys. 4.15. Schemat analizowanej sceny




Rys. 4.16. Wykonane zdjęcia z pozycji frontalnej oraz z boku

Po wykonaniu zdjęć przystąpiono do wyliczenia parametrów kamery. Zadanie to było wykonane dla sprawdzenia działania przygotowanego programu, ponieważ wszystkie parametry były znane. W pierwszym kroku działania algorytmu wyznaczania parametrów kamery, wykonane zdjęcia zostały pobrane oraz przeprowadzono operacje usunięcia zniekształceń obiektywu.




Rys. 4.17. Zdjęcia obiektu laboratoryjnego po usunięciu dystorsji



Rys. 4.18. Wyznaczenie 150 punktów charakterystycznych




Rys. 4.19. Skorelowanie ze sobą charakterystycznych punktów z obydwu zdjęć

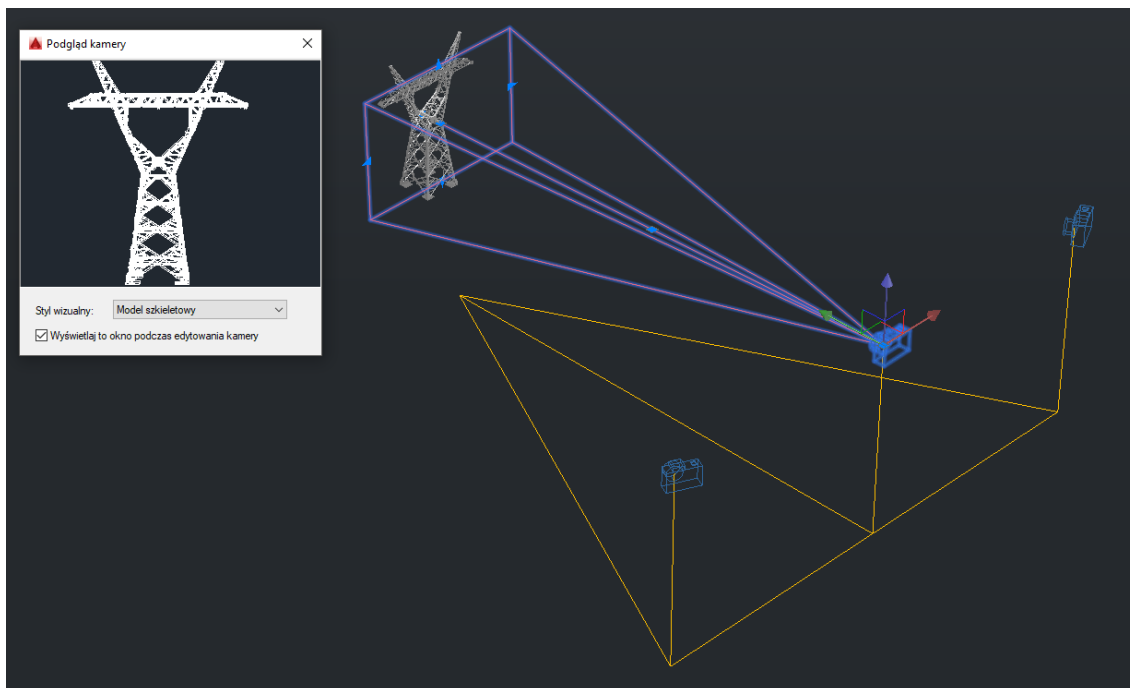


Rys. 4.20. Wyznaczenie linii epipolarnych

Po usunięciu zniekształceń należało zdefiniować znany wymiar fragmentu obiektu. W związku z faktem, że algorytm działa w sposób półautomatyczny operator podaje znaną odległość określonego fragmentu kratownicy. Należało przy tym wskazać w odpowiednie 2 punkty i podać w mm odległość pomiędzy nimi. Jako wymiar do badań podano rozpiętość ramion słupa, która wynosiła 540 mm. Następową analizą obydwu obrazów w celu wyznaczenia najbardziej charakterystycznych punktów. Następnie punkty te były ze sobą łączone oraz wyliczana była tzw. linia epipolarna. W kolejnym kroku, korzystając z równań 4.14÷4.17 wyliczane były współrzędne przestrzenne umiejscowienia kamery oraz jej macierz parametrów wewnętrznych.



Rys. 4.21. Wygenerowanie sceny z wynikiem określającym umiejscowienie kamer



Rys. 4.22. Podgląd zdjęcia wirtualnego po ustaleniu wszystkich parametrów kamery

Wyliczone parametry są zapisywane w pliku .txt i przesyłane do kolejnego etapu algorytmu. Dodatkowo w celu poglądowym na rys. 4.21 przedstawiono odwzorowanie sceny na podstawie zdjęć z rys. 4.16. Jak wynika z otrzymanych wyników, stwierdzono, że mechanizm określania współrzędnych oraz parametrów wewnętrznych kamery działa poprawnie. Przykładowe wyniki współrzędnych zmierzone i wyliczone (dla zestawów 1÷4) przedstawiono w tab. 4.1.

Tab. 4.1. Wyniki wyznaczania współrzędnych kamery

zestaw	współrzędna kamery	wartość zmierzona [m]	wartość wyliczona [m]
1	x	0,1116	0,1121
	y	3,068	3,07
	z	1,178	1,175
2	x	1,6116	1,6115
	y	3,4144	3,4149
	z	1,178	1,181
3	x	2,1116	2,11
	y	1,932	1,941
	z	1,178	1,175
4	x	3,6116	3,6102
	y	1,932	1,941
	z	1,178	1,181


Otrzymano wyniki zbliżone z wynikami pomiarów odległości między poszczególnymi punktami badanej sceny w laboratorium.

4.5. Generowanie zdjęcia wirtualnego


Po określeniu pozycji i parametrów wewnętrznych kamery, dane te należy wpisać (jako dane wejściowe zapisane w pliku .txt) do środowiska, w którym będzie generowane zdjęcie wirtualne. Zdjęcie wirtualne jest renderem sceny, na której znajduje się jedynie badany obiekt. Dodatkowym parametrem jaki należy wprowadzić jest rozdzielczość zdjęć rzeczywistych. Jest to parametr istotny aby uzyskać zdjęcie, które będzie zdjęciem wzorcowym o jak najlepszej dokładności (najlepiej odzwierciedlającym obiekt z jak największą dokładnością).

Po ustaleniu wszystkich parametrów (co poglądowo przedstawia rys. 4.22) następuje wygenerowanie zdjęcia. Zdjęcie to generowane jest w modelu perspektywicznym, dzięki czemu nie zostaje utracona informacja o głębi sceny. Przykładowe wygenerowane zdjęcie przedstawiono na rys. 4.23 - rys. 4.25, a jego zapis matematyczny w (4.21).


$$f_{RGB}^{13} = f(x, y) \quad (4.21)$$




Rys. 4.23. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne (b) – widok frontalny



Rys. 4.24. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne (b) – widok pod kątek 30°



Rys. 4.25. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne w programie Matlab (b) – widok frontalny



Rys. 4.26. Zdjęcia przygotowane do nałożenia – a) zdjęcie rzeczywiste z usuniętą dystorsją, b) zdjęcie wirtualne

4.6. Rejestracja zdjęcia rzeczywistego i wirtualnego

W początkowej fazie badań nie przewidziano etapu rejestracji zdjęć. Zakładano, że opisane w rozdziale 4.5 wygenerowane zdjęcia wirtualne pokryją się dokładnie z zdjęciem rzeczywistym. Niestety w trakcie badań pomimo zachowania tych samych parametrów, umiejscowienia obiektu oraz rozdzielczości zdjęć, nie można ich było do siebie dopasować tak, aby elementy kratownic znajdowały się w tych samych miejscach. Taki przypadek przedstawiono na rys. 4.27, na którym wyraźnie widać niedopasowanie zdjęć. Odpowiednie umiejscowienie zdjęć jest kluczowe z punktu widzenia dalszej analizy i prawidłowego działania metody.



Rys. 4.27. Wynik projekcji zdjęć rzeczywistego i wirtualnego

W związku z powstałymi rozbieżnościami, zdecydowano się wykonać proces rejestracji, który wspomniane problemy powinien zniwelować. W przeprowadzonych badaniach używano w procesie rejestracji 3 metody transformacji: Nonreflective similarity (nie odwzorowana transformacja podobieństwa), Affine (afiniczna) i Projective.

Transformacja Nonreflective similarity może obejmować obrót, skalowanie i mapowanie. Po jej wykonaniu kształty i kąty obiektów są zachowane, linie równoległe pozostają równoległe. Zachowane są także proste w obiekcie. Transformacja ta jest podzbiorem transformacji podobieństwa. Ma ona cztery stopnie swobody i wymaga dwóch par punktów skorelowanych na obrazach [KaFD10].

Transformacja afiniczna to metoda odwzorowania liniowego, która zachowuje punkty, linie proste i płaszczyzny. Po transformacji zestawy równoległych linii pozostają równoległe. Technika transformacji afinicznej jest zazwyczaj stosowana do korekcji zniekształceń geometrycznych lub deformacji, które występują przy nieidealnych kątach kamery. Na przykład zdjęcia satelitarne wykorzystują transformacje afiniczne do korekcji zniekształcenia obiektu szerokokątnego. Przekształcanie i łączenie obrazów z dużym, płaskim układem współrzędnych jest pożądane, aby wyeliminować zniekształcenia [ChCS05, GoA88]. Umożliwiają one na łatwiejsze interakcje i obliczenia, które nie wymagają uwzględnienia zniekształceń obrazu.

Transformacja Projective wyświetla trójwymiarowy obiekt geometryczny na płaszczyźnie 2D [ChCS05] i może być postrzegana jako powszechny przykład transformacji rzutowej. Ściśle mówiąc, daje ona transformację z jednej płaszczyzny na drugą, ale jeśli zidentyfikujemy te dwie płaszczyzny przez np. ustalenie układu kartezjańskiego w każdym z nich, to otrzymamy rzutową transformację z płaszczyzny do samej siebie.

W początkowej fazie badań rejestrację wykonywano w sposób automatyczny z wykorzystaniem znaczników.



Rys. 4.28. Zdjęcia przygotowane do procesu rejestracji automatycznej

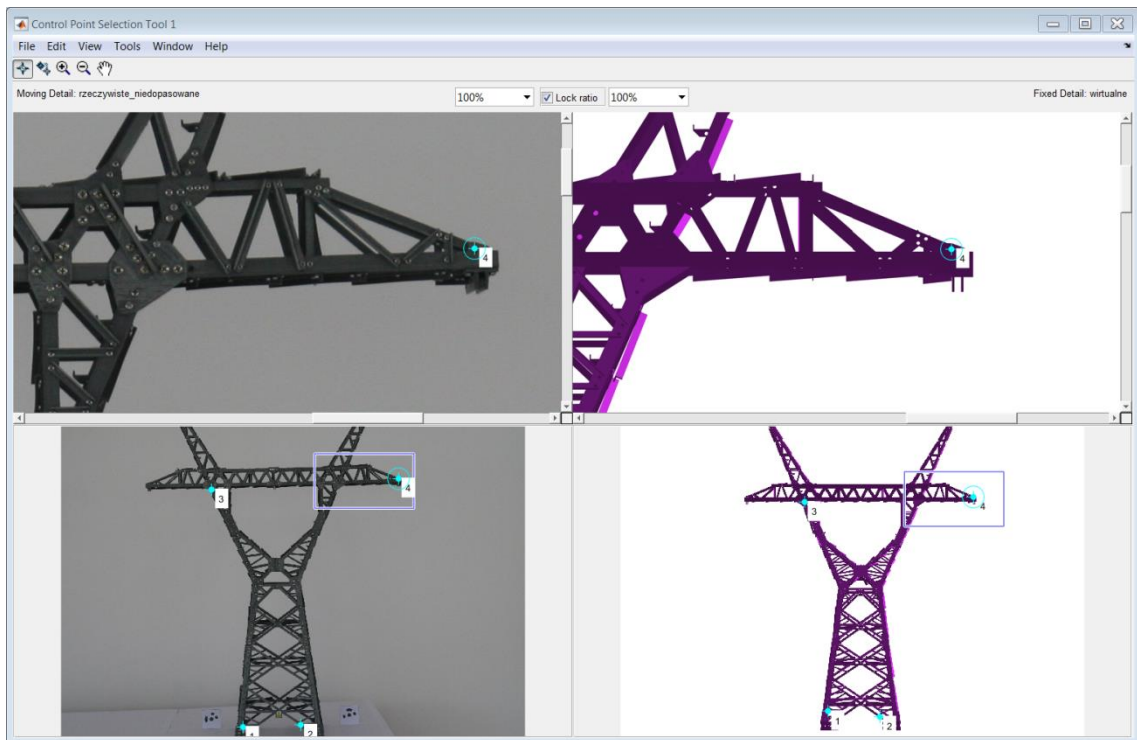


Rys. 4.29. Wynik rejestracji automatycznej


W automatycznym dopasowaniu obrazów jako elementy względem których obrazy były rejestrowane przyjęto charakterystyczne znaczniki, które zostały ustawione przy podstawie obiektu. W scenie wirtualnej znaczniki te także zostały dodane, aby zawierały się na zdjęciu wirtualnym. Przygotowane zdjęcia przedstawiono na rys. 4.28.

Na rys. 4.29 przedstawiono wynik rejestracji. Jak można zauważyć znaczniki dobrze zostały dopasowane (pokryły się w 100%), niestety interesujące szczegóły obiektu zostały dopasowane w stopniu niezadowalającym, w którym nie mogą być one wykorzystane w procesie oceny obiektu. Największe rozbieżności można było zauważyć przy poprzecznych ramionach słupa oraz przy belkach znajdujących się wewnątrz konstrukcji. Po kilkunastu seriach prób z różnymi znacznikami oraz ustawieniami sceny zdecydowano się na ręczne wskazywanie tzw. punktów kontrolnych (CP – control points) – P_2 . Punkty te są tymi samymi pikselami na 2 różnych obrazach, względem których dokonywana będzie rejestracja. Punkty kontrolne zdecydowano się umieścić przy


podstawie obiektu oraz na jego ramionach (w miejscach gdzie w procesie rejestracji automatycznej obrazy zostały dopasowane w małym stopniu). Wybrane punkty przedstawiono na rys. 4.30.



Rys. 4.30. Wyznaczone ręcznie punkty CP



Rys. 4.31. Wyliczone punkty korelacyjne obrazów



Rys. 4.32. Wynik rejestracji z ręcznie wskazanymi punktami

Pierwszym etapem po wskazaniu odpowiadających sobie pikseli na obydwu obrazach, jaki wykonuje algorytm jest wyliczenie innych odpowiadających sobie punktów (rys. 4.31) oraz linii względem którym będą dokonywane przekształcenia w celu dopasowanie obrazów. Na rys. 4.32 przedstawiono efekt działania rejestracji. Obraz po procesie rejestracji określono jako f_{RGB}^{31} .

$$f^{21} z f^{31} i P_1, P_2 \rightarrow f_{RGB}^{31}(x, y) \quad (4.22)$$

Można zauważyć, że obrazy zostały dopasowane z dużą dokładnością (poprawę zwłaszcza widać w obszarach, w których rejestracja automatyczna napotkała problemy). Tak przygotowany obraz możliwy jest do przekazania go dalszym analizom.

4.7. Korekta zarejestrowanych zdjęć

Obraz uzyskany po wykonaniu rejestracji i porównaniu zdjęcia rzeczywistego obiektu oraz obrazu wygenerowany z wirtualnego modelu 3D zawiera wiele pojedynczych pikseli, będącymi między innymi efektem niedoskonałości wykonanej rejestracji. W celu ich usunięcia (i pozostawienia tylko większych, zwartych bloków pikseli – poszukiwanych ubytków w konstrukcji) przeprowadzana jest korekta obrazu powstałego po porównaniu obrazów wejściowych. Jest ona wykonywana za pomocą dwóch naprzemiennych operacji morfologicznych – erozji i dylatacji – z wykorzystaniem kwadratowej maczy przekształceń.

W dylatacji obiektem nazywane są białe elementy obrazu, oznacza się je przez 1. Natomiast tłem są elementy czarne i oznacza się je 0 [TaR97]. Dylatację można uzyskać


na kilka sposobów. W klasycznej formie element strukturalny jest przykładany w każdym punkcie należącym do zbioru i wykonywana jest operacja sumy binarnej ($1+0=0+1=1$, $1+1=1$, $0+0=0$). W konsekwencji dylację obrazu binarnego f z elementem strukturalnym E możemy zapisać jako 4.23.

$$f \oplus E = \{(x,y) + (i,j) : (i,j) \in Q_f, (x,y) \in Q_E\} \quad (4.23)$$

Powstały obraz jest rozumiany jako zbiór pikseli, które teraz należą do zbioru (białe piksele). W dylacji można użyć różnych elementów strukturalnych. Najprostszy z nich to kwadratowy element strukturalny, czyli macierz wypełniona 1. Na przykład element strukturalny o wymiarze 5×5 .

Erozja jest techniką pomniejszania obiektów poprzez usunięcie pikseli granicznych. Tą operację można rozumieć jako odwrócenie operacji dylacji [TaR97] i zapisać jako 4.24.

$$I \ominus E = \{(x,y) : ((x,y) + (i,j)) \in Q_f, \text{ dla wszystkich } (i,j) \in Q_E\} \quad (4.24)$$



Rys. 4.33. Otrzymany wynik: a) przed korektą, b) po korekcie


Jak można wywnioskować z rys. 4.33 zastosowanie korekt eliminuje z obrazów piksele, które nie zawierają się w większych zbiorach. Dzięki takim operacjom nie zostaje utracona informacja o ewentualnych brakach w konstrukcji, a zyskuje się obraz posiadający mniej pikseli, które mogłyby jedynie powodować obniżenie skuteczności omawianej metody.

4.8. Analiza obiektu

Ostatnim krokiem jest analiza zdjęcia rzeczywistego przy użyciu wzorca (zdjęcia wirtualnego) w celu stwierdzenia ewentualnych braków w konstrukcji. Do analizy posłużono się obrazem kratownicy z rys. 4.28, z którego usunięto 3 kątowniki – równanie 4.25.

$$f_{RGB}^{12} = f(x, y) \quad (4.25)$$

Zdecydowano się analizować braki w dolnej części konstrukcji, ponieważ w warunkach rzeczywistych właśnie takich występuje najwięcej. Usunięte elementy, które na rys. 4.33 są oznaczone czerwonymi elipsami, stanowią bardzo mały fragment całości konstrukcji. Elementy te usunięto celowo, w wiadomych miejscach, aby móc sprawdzić poprawność działania metody.



Rys. 4.34. Fragment kratownicy przygotowany do analizy, a) całość, b) z brakami

Przed przystąpieniem do analizy obrazów, w celu eliminacji refleksów świetlnych oraz cieni powstałych na obrazach wirtualnym poddano go procesowi binaryzacji. BINARYZACJI poddano także zdjęcie rzeczywiste, dzięki czemu uzyskano usunięcie tła z obrazu.

$$f_{RGB}^{21}(x, y) \rightarrow f_B^{41}(x, y) \quad (4.26)$$


$$f_{RGB}^{13}(x, y) \rightarrow f_B^{43}(x, y) \quad (4.27)$$

Zdjęcie rzeczywiste, zawierające ubytki w konstrukcji poddano analizie z zdjęciem wirtualnym. Po odpowiednim wykonaniu procesu binaryzacji, dokonano operacji różnicy tych obrazów w wyniku czego otrzymano obraz z widocznymi brakami oraz małymi grupami pikseli, stanowiącymi pewnego rodzaju szum (4.28).

$$f_B^{41}(x, y) - f_B^{43}(x, y) \rightarrow f_B^{61}(x, y) \quad (4.28)$$

By go zniwelować wynikowe zdjęcie dodatkowo poddano kolejnemu procesowi erozji, dzięki czemu szumy zostały zniwelowane i otrzymano obraz wynikowy jak na rys. 4.35 i opisano równaniem (4.29).

$$f_B^{61}(x, y) \rightarrow f_B^{71}(x, y) \quad (4.29)$$



Rys. 4.35. Obraz wynikowy metody zdjęć wirtualnych – a) widoczne braki, b) braki nałożone na obraz wejściowy, w celu wizualizacji uszkodzeń

W dalszej części działania metody operatorowi zostaje zwrócona informacja o ewentualnych brakach występujących w konstrukcji przedstawionej na określonym zdjęciu. Taki obraz powinien zostać poddany dokładniejszej analizie przez wyspecjalizowany personel. W przypadku analizy zdjęcia bez braków w konstrukcji na obrazie wynikowym pojawić powinny się jedynie piksele stanowiące szum, które w procesie erozji zostałyby usunięte.

4.9. Podsumowanie rozdziału

W rozdziale tym przedstawiono algorytm oraz opisano działanie zaproponowanej przez autora metody zdjęć wirtualnych, którą można wykorzystać w procesie wstępnej oceny materiału fotograficznego linii elektroenergetycznej. Główną cechą działania algorytmu jest wykrywanie braków w konstrukcji oraz informowanie o zaistnieniu takiej sytuacji. W metodzie dopuszcza się błędy w działaniu, polegające na informowaniu o wadzie w słupie nieposiadającym braków. Jednak nie może zaistnieć sytuacja o niewykryciu istniejących błędów i braków konstrukcji.

Rozdział ten miał na celu przedstawienie rozwiązania, jakie autor opracował, aby rozwiązać postawione we wstępie zadanie.

5. Proponowana metoda selekcji wybranych cech

5.1. Ocena procesu rejestracji

Po przeprowadzonych próbach działania metody zauważono, że następują pewne błędy w jej działaniu. Po pogłębionej analizie działania zaproponowanego algorytmu autor stwierdził, że błędy w działaniu powodowane są na poziomie wykonywania procesu rejestracji, filtracji tła oraz metodzie zliczania pikseli, które składają się na ewentualne braki w konstrukcji.

W celu przeprowadzenia badań oceny wykonania rejestracji przygotowano odpowiednie zestawy obrazów. Każdy zestaw zawierał parę obrazów, wykonanych z 2 pozycji kamery – frontальной oraz pod kątem (30^0). Różniły się one także rozdzielczością oraz ogniskową obiektywu. Dokładny opis analizowanych zestawów przedstawiono w tab. 5.1.

Tab. 5.1. Dane analizowanych zdjęć


nr zestawu	rozdzielczość zdjęcia	ogniskowa f
1	3504 x 2336	24
2		
3	4869 x 3264	18
4		
5	3504 x 2336	24
6		
7		60
8		

Tak przygotowane pary obrazów zostały poddane procesowi rejestracji przy użyciu wybranych metod. W efekcie uzyskano zarejestrowaną wersję obrazu, która po wykonaniu postprocessingu, na który składała się operacja binaryzacji oraz operacje erozji i dylatacji, została porównywana ze zdjęciem wygenerowanym na podstawie modelu 3D, w celu oceny skuteczności zastosowanej rejestracji.

Do oceny efektów rejestracji obrazów w badaniach wybrano trzy miary: Jaccard Index, Accuracy i False Discovery Rate. Jaccard Index, nazywany często Intersection over Union (IoU), używany jest do porównania stopnia podobieństwa zbiorów [BeMB16] i jest zdefiniowany jako iloraz mocy części wspólnej zbiorów i mocy sumy tych zbiorów.

Miara Accuracy (Acc) jest wyznaczana na podstawie tzw. confusion matrix. Stosuje się ją przy ocenie działania klasyfikatorów. Dane oznaczone etykietami: pozytywną i negatywną poddawane są klasyfikacji, która przypisuje im predyktowaną klasę pozytywną albo predyktowaną klasę negatywną [AIS18]. False Discovery Rate (FDR) to natomiast oczekiwana proporcja błędów do wszystkich wyników [YoB10].

Podczas badań analizowano rejestrację półautomatyczną, podczas której każdorazowo określano punkty wskazujące piksele odwzorowujące te same obiekty na parach obrazów – obrazowi przedstawiającemu konstrukcję wsporczą i obrazowi wirtualnemu (rys. 5.1). Punkty te nazywano w dalszej części Control Points (CP). Na podstawie współrzędnych tych punktów, zgodnie z przyjętą metodą transformacji, obraz poddawany był rejestracji.



Rys. 5.1. Przykładowe zdjęcia rzeczywiste i wirtualne z zaznaczonymi punktami CP reprezentującymi korespondujące piksele

W przeprowadzonych eksperymentach porównano 3 metody transformacji używanych w procesie rejestracji:

- Non-reflective similarity;
- Affine;
- Projective.


Transformacja Non-reflective similarity może obejmować obrót, skalowanie i mapowanie. Po jej wykonaniu kształty i kąty obiektów są zachowane, linie równoległe pozostają równoległe. Zachowane są także proste w obiekcie. Transformacja ta jest podzbiorem transformacji podobieństwa. Ma ona cztery stopnie swobody i wymaga dwóch par punktów skorelowanych na obrazach [KaFD10].

Transformacja afiniczna to metoda odwzorowania liniowego, która zachowuje punkty, linie proste i płaszczyzny. Po transformacji zestawy równoległych linii pozostają równoległe. Technika transformacji afinicznej jest zazwyczaj stosowana do korekcji


zniekształceń geometrycznych lub deformacji, które występują przy nieidealnych kątach kamery. Na przykład zdjęcia satelitarne wykorzystują transformacje afiniczne do korekcji zniekształcenia obiektywu szerokokątnego. Przekształcanie i łączenie obrazów z dużym, płaskim układem współrzędnych jest pożądane, aby wyeliminować zniekształcenia [ChCS05, GoA88]. Umożliwiają one na łatwiejsze interakcje i obliczenia, które nie wymagają uwzględnienia zniekształceń obrazu.

Transformacja Projective wyświetla trójwymiarowy obiekt geometryczny na płaszczyźnie 2D [ChCS05] i może być postrzegana jako powszechny przykład transformacji rzutowej. Ściśle mówiąc, daje ona transformację z jednej płaszczyzny na drugą, ale jeśli zidentyfikujemy te dwie płaszczyzny przez np. ustalenie układu kartezjańskiego w każdym z nich, to otrzymamy rzutową transformację z płaszczyzny do samej siebie.

Analizie poddano 15 zestawów CP na wykonanych zdjęciach. Zestawy te przygotowano z zastosowaniem podziału na 2 grupy. W pierwszej grupie, w skład której weszły zestawy 1–6, używano 4 CP, zmieniając ich lokalizację na obiekcie, co przedstawiono na rys. 5.2. W drugiej grupie (zestawy 6–15) zwiększano kolejno o jeden liczbę punktów CP – odpowiednio w zestawie 6 – cztery CP, a w 15 – dwanaście CP (rys. 5.3).




Rys. 5.2. Obrazy przed rejestracją – różne umiejscowienie punktów CP



Rys. 5.3. Obrazów przed rejestracją – zwiększenie liczby CP


W tab. 5.2 oraz na wykresie na rys. 5.4 przedstawiono wyniki przeprowadzonego eksperymentu. Poszczególne wyniki są wartościami średnimi dla danego zestawu i metody w skali całego eksperymentu. Jak można zauważyć najlepszy wynik dla analizowanych zestawów zdjęć w skali całego eksperymentu otrzymano dla metody Projective dla zestawu pierwszego i jedenastego. Uzyskano parametr Acc na poziomie 0,987. Zestaw jedenasty dla wspomnianej metody uzyskał natomiast najmniejszą wartość parametru FDR, na poziomie 0,189 (tab. 5.4, rys. 5.6). Można na tej podstawie wywnioskować, że właśnie dla tego zestawu punktów CP metoda Projective daje najlepszy wynik.



Rys. 5.4. Porównanie wartości przeciętnej parametru Accuracy dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Tab. 5.2. Przeciętne wartości parametru Accuracy dla 15 wariantów CP


zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,9865	0,9862	0,9869
2	0,9866	0,9861	0,9865
3	0,9860	0,9856	0,9832
4	0,9827	0,9818	0,9828
5	0,9843	0,9851	0,9827
6	0,9819	0,9832	0,9814
7	0,9861	0,9860	0,9843
8	0,9866	0,9861	0,9859
9	0,9867	0,9861	0,9858
10	0,9868	0,9863	0,9868
11	0,9867	0,9863	0,9869
12	0,9867	0,9863	0,9867
13	0,9868	0,9863	0,9867
14	0,9868	0,9863	0,9867
15	0,9868	0,9864	0,9868



Rys. 5.5. Porównanie wartości przeciętnej parametru Intersection over Union dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Tab. 5.3. Przeciętne wartości parametru Intersection over Union dla 15 wariantów CP

zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,5660	0,5607	0,5648
2	0,5523	0,5401	0,5452
3	0,5321	0,5327	0,4330
4	0,4910	0,4695	0,4921
5	0,4881	0,5062	0,4653
6	0,4421	0,4774	0,4119
7	0,5373	0,5336	0,4945
8	0,5507	0,5408	0,5299
9	0,5586	0,5436	0,5426
10	0,5715	0,5556	0,5716
11	0,5727	0,5566	0,5771
12	0,5625	0,5494	0,5608
13	0,5598	0,5469	0,5521
14	0,5594	0,5472	0,5552
15	0,5584	0,5481	0,5570



Rys. 5.6. Porównanie wartości przeciętnej parametru False discovery rate dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Tab. 5.4. Przeciętne wartości parametru False discovery rate dla 15 wariantów CP


zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,1998	0,1972	0,2024
2	0,2138	0,2227	0,2231
3	0,2313	0,2274	0,3413
4	0,2702	0,2955	0,2627
5	0,2771	0,2636	0,3039
6	0,3190	0,2711	0,3896
7	0,2266	0,2209	0,2732
8	0,2143	0,2175	0,2406
9	0,2038	0,2145	0,2215
10	0,1920	0,2039	0,1941
11	0,1909	0,2030	0,1897
12	0,1992	0,2080	0,2026
13	0,2013	0,2094	0,2108
14	0,2017	0,2093	0,2075
15	0,2034	0,2090	0,2066

Po przeprowadzonym eksperymencie zauważono, że zestawy 3-6, w których wyznaczone punkty CP znajdowały się w środkowej części obiektu, uzyskały najniższą dokładność rejestracji. Dla punktów CP dobieranych w niewielkich odległościach od siebie wyniki były najbardziej niezadowolające. Zwiększanie liczby punktów wpływa pozytywnie na skuteczność wykonywanej rejestracji do pewnego progu. Skuteczność zwiększania liczby punktów CP nasycy się (dla wszystkich metod) po liczbie 8 punktów (zestaw 11). Dla zastosowanych 8 punktów uzyskano także najlepszy wynik wykonania operacji rejestracji.


Umieszczenie punktów ma duży wpływ na rejestrację. Najlepsze efekty otrzymano dla CP wyznaczonych na skrajnych punktach obrazów. Nieznacznie lepszymi, na tle innych metod, są wyniki uzyskane z wykorzystaniem metody Affine.

Po zaobserwowaniu dużego wpływu jakości na rejestracje ma umiejscowienie punktów CP autor sprawdził także jaki wpływ na sam proces ma usytuowanie urządzenia rejestrującego obraz względem obiektu na parametry określające jakość dopasowania rejestracji.

Na rys. 5.7 przedstawiono dwie sceny, które powtarzają się w całym prowadzonym eksperymencie: scenę z widokiem frontальnym (ang. front view) i scenę z widokiem pod kątem (ang. side view), dla których wykonano analizę rejestracji. Otrzymane wyniki zaprezentowano w tab. 5.5, tab. 5.6, tab. 5.7. Są to wartości przeciętne uzyskane dla poszczególnych widoków, dla 15 zestawów punktów CP.




Rys. 5.7. Analizowane sceny: a) front view, b) side view



Rys. 5.8. Porównanie Accuracy dla widoków obiektów - front view, side view

Tab. 5.5. Wartości Accuracy dla widoków obiektów


widok	nr pary			
	1	2	3	4
front view	0,9950	0,9956	0,9933	0,9709
side view	0,9844	0,9931	0,9919	0,9625



Rys. 5.9. Porównanie Intersection over Union dla widoków obiektów - front view, side view

Tab. 5.6. Wartości Intersection over Union dla widoków obiektów

widok	nr pary			
	1	2	3	4
front view	0,6566	0,5739	0,5747	0,6140
side view	0,4289	0,4202	0,4955	0,4964




Rys. 5.10. Porównanie False discovery rate dla widoków obiektów - front view, side view

Tab. 5.7. Wartości False discovery rate dla widoków obiektów

widok	nr pary			
	1	2	3	4
front view	0,1410	0,1880	0,2457	0,1854
side view	0,3037	0,3305	0,2379	0,2144

Analizując wpływ widoku sceny, z jakiej wykonywano obraz poddawany jest analizie widać, że położenie kamery ma duży wpływ na końcowy wynik procesu rejestracji, co obrazują wykresy na rys. 5.8, rys. 5.9, rys. 5.10. Lepszy wynik otrzymano dla wykonania rejestracji widoku na wprost obiektu. Utworzenie takiego dopasowania jest zadaniem łatwiejszym, ponieważ wpływ na taki wynik może mieć liczba elementów (kątowników z kratownicy), którą należy dopasować. Na widoku z boku widoczna jest większa liczba elementów, występuje także większa ilość światłocieni jakie rzucają poszczególne elementy. Dodatkowo na większy błąd rejestracji wpływa dokładność ustawienia widoku kamery w scenie wirtualnej.

Obraz uzyskany po wykonaniu rejestracji i porównaniu zdjęcia rzeczywistego obiektu oraz obrazu wygenerowany z wirtualnego modelu 3D zawiera wiele pojedynczych pikseli, będącymi między innymi efektem niedoskonałości wykonanej rejestracji. W celu ich usunięcia i pozostawienia tylko większych, zwartych bloków pikseli – poszukiwanych ubytków w konstrukcji przeprowadzana jest korekta obrazu powstałego po porównaniu obrazów wejściowych. Jest ona wykonywana za pomocą dwóch naprzemiennych operacji erozji i dyatacji, z wykorzystaniem kwadratowej maczyzy przekształceń.




Rys. 5.11. Otrzymany wynik: a) przed korektą, b) po korekcie

Tab. 5.8. Wpływ zastosowania korekty na jakość rejestracji

		Zestaw danych							
		1	2	3	4	5	6	7	8
przed korektą	FDR	0,141	0,304	0,188	0,33	0,246	0,238	0,185	0,214
	PX	12942	43718	21837	40938	23990	20541	84958	83680
po korekcie	FDR	0,062	0,249	0,131	0,267	0,187	0,147	0,155	0,169
	PX	5234	33328	14208	30256	16970	11325	68950	62168

Efekty zastosowania opisanej korekty dla zestawu 1 przedstawiono na rys. 5.11, natomiast otrzymane wyniki dla analizowanych 8 zestawów przedstawiono w tab. 5.9. Zestawiono w niej uzyskane wartości FDR i odpowiadające im liczby pikseli PX przed i po korekcie. Po tej operacji uzyskane obrazy zawierają mniej pojedynczych pikseli, co skutkuje większymi możliwościami klasyfikacji pozostałych, większych grup pikseli, które odpowiadały brakującym elementom konstrukcji kratownicowej.

Zmniejszeniu dla wszystkich zestawów nastąpił także parametr FDR, świadczący o skuteczności zastosowanej korekty. Dokładne wyniki parametrów dla wszystkich zestawów po dokonaniu korekt przedstawiono w tab. 5.9, tab. 5.10, tab. 5.11 oraz na rys. 5.12, rys. 5.13 i rys. 5.14.




Rys. 5.12. Porównanie wartości przeciętnej parametru Accuracji dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Tab. 5.9. Przeciętne wartości parametru Accuracji dla 15 wariantów CP po korekcie

zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,9878	0,9875	0,9882
2	0,9879	0,9874	0,9879
3	0,9873	0,9868	0,9843
4	0,9837	0,9828	0,9839
5	0,9854	0,9863	0,9837
6	0,9830	0,9843	0,9825
7	0,9874	0,9872	0,9855
8	0,9879	0,9874	0,9872
9	0,9880	0,9874	0,9870


10	0,9881	0,9876	0,9881
11	0,9880	0,9875	0,9882
12	0,9880	0,9876	0,9880
13	0,9880	0,9876	0,9879
14	0,9881	0,9876	0,9880
15	0,9881	0,9876	0,9881



Rys. 5.13. Porównanie wartości przeciętnej parametru Intersection over Union dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Tab. 5.10. Przeciętne wartości parametru Intersection over Union dla 15 wariantów CP po korekcie


zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,59802	0,59110	0,59695
2	0,58243	0,56915	0,57651
3	0,56016	0,56039	0,45252
4	0,51450	0,49202	0,51702
5	0,51215	0,53221	0,48670
6	0,46193	0,49910	0,43307
7	0,56620	0,56157	0,51878
8	0,58229	0,57031	0,55864
9	0,58959	0,57204	0,57173
10	0,60362	0,58572	0,60420
11	0,60509	0,58674	0,60971
12	0,59298	0,57771	0,59127
13	0,58846	0,57405	0,58130
14	0,58812	0,57454	0,58448
15	0,58782	0,57605	0,58723




Rys. 5.14. Porównanie wartości przeciętnej parametru False discovery rate dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Tab. 5.11. Przeciętne wartości parametru False discovery rate dla 15 wariantów CP po korekcie


zestaw CP	metoda rejestracji		
	affine	nonreflectivesimilarity	projective
1	0,1344	0,1350	0,1367
2	0,1506	0,1609	0,1569
3	0,1706	0,1679	0,2936
4	0,2167	0,2439	0,2061
5	0,2226	0,2069	0,2541
6	0,2708	0,2190	0,3425
7	0,1651	0,1612	0,2191
8	0,1481	0,1551	0,1797
9	0,1390	0,1540	0,1597
10	0,1258	0,1410	0,1273
11	0,1243	0,1405	0,1232
12	0,1352	0,1475	0,1384
13	0,1408	0,1511	0,1484
14	0,1412	0,1509	0,1452
15	0,1413	0,1494	0,1429



Rys. 5.15. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji Affine



Rys. 5.16. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji o Non-reflective Similarity





Rys. 5.17. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji Projective

Z analizy otrzymanych wyników, pokazanych na rys. 5.11 można wywnioskować, że na wyniki dopasowania podczas rejestracji, pozytywny wpływ ma zastosowana korekta. Jak wynika z rys. 5.15, rys. 5.16, rys. 5.17 wyniki nie zmieniają się co do zasady skuteczności metody czy wyboru kryteriów, ale w znacznym stopniu zwiększają stopień dopasowania, dla poszczególnych zestawów o ok. 0,03.

5.2. Detekcja wystąpienia braków w konstrukcji


W procesie sprawdzenia skuteczności znajdowania odstępstw w budowie konstrukcji, zwłaszcza w brakach konstrukcji wykorzystano zestawy zdjęć laboratoryjnych omówionych w tab. 5.1. Dodatkowo w każdym ze zdjęć dokonano usunięcia konkretnych elementów konstrukcji. Usuwano elementy znajdujące się w dolnej części konstrukcji, gdyż stwierdzono, że te elementy ulegają najczęściej uszkodzeniom lub kradzieży. Usunięte elementy (rys. 5.18), stanowią bardzo mały fragment całości konstrukcji jak i samego obrazu.






Rys. 5.18. Fragmenty obrazów przygotowanych do analizy – zestaw 1 i 2 – a,b – kratownica rzeczywista, c,d – kratownica rzeczywista z brakami, e,f – kratownica wirtualna

Pierwszym etapem analizy było wyliczenie liczby pikseli, które składają się na usunięte fragmenty konstrukcji. Informacja ta posłużyła w dalszej części eksperymentu do określenia skuteczności działania metody. W celu wyliczenia liczby pikseli jaką stanowiły usunięte fragmenty dokonano operacji odjęcia obrazu kratownicy zawierającej braki (rys. 5.18 c) z obrazem kompletnej kratownicy (rys. 5.18 a), wynik przedstawiono na rys. 5.19. Operacja ta, we wstępnej analizie działania metody, miała na celu otrzymanie dokładnej informacji o liczbie szukanych pikseli, które składały się na braki w konstrukcji i stanowiły odstępstwo od wzorca. Zakładano, że wykonanie takiej operacji z obrazem wirtualnym może zawierać błędy wynikające z złego dopasowania omawianych obrazów. Dokładna informacja o wielkości poszukiwanego obszaru braków w konstrukcji posłużyła do wyliczenia skuteczności działania porównania obrazu rzeczywistego z wirtualnym. W celu przedstawienia zasady wyliczania braków w konstrukcji oraz sprawdzenia poprawności tej operacji posłużono się obrazami z zestawu nr 1.



Rys. 5.19. Wynik operacji odjęcia obrazów – uzyskano obszary stanowiące braki w konstrukcji




Rys. 5.20. Obraz kratownicy z nałożonymi brakami

W wyniku przeprowadzonych obliczeń otrzymano informację o liczbie pikseli jakie składają się na obszar braków w konstrukcji – 761 px.

W następnym kroku poddano analizie obraz rzeczywisty z usuniętymi elementami z obrazem wirtualnym. W celu uniknięcia na obrazie wirtualnym występowania


refleksów świetlnych oraz cieni, po procesie rejestracji obrazów wykonano operacje binaryzacji obrazu wirtualnego, który pełnił rolę maski.

Obraz rzeczywisty, w celu eliminacji tła został poddany procesowi binaryzacji (rys. 5.21). Dzięki takiemu rozwiązaniu wyeliminowano tło, które nie ma wpływu na dalsze analizy.



Rys. 5.21. Wynik operacji binaryzacji obrazu rzeczywistego


Po opisanych operacjach wykonano odjęcie obrazu rzeczywistego (z brakami) i obrazu wirtualnego w wyniku czego otrzymano obszary pikseli składające się na braki konstrukcji – rys. 5.22.



Rys. 5.22. Wynik operacji odjęcie obrazu wirtualnego od obrazu rzeczywistego
(w okręgu po lewej stronie po inwersji kolorów)


Jak można zauważyć na rys. 5.22 poza obszarami pikseli składającymi się na braki w konstrukcji pojawiły się piksele stanowiące pewnego rodzaju szum w obrazie. Wynik ten spowodowany jest nieidealnym przeprowadzeniem procesu rejestrowania obrazów. Pomimo wielu prób i analiz związanych z procesem rejestracji nie udało się całkowicie zniwelować występowania na tym etapie działania metody pikseli nie zawierających się w obszarze braków konstrukcji.

Po wykonaniu serii powtórzeń tego etapu metody stwierdzono, że piksele stanowiące braki w konstrukcji zawsze tworzą wspólne duże obszary, natomiast piksele powstałe w wyniku błędów procesu rejestracji są pikselami pojedynczymi. W związku z tym otrzymany obraz poddano naprzemiennym operacją erozji i dylatacji, aby zniwelować występujące na nim szumy złożone z pojedynczych pikseli.



Rys. 5.23. Obraz po przeprowadzeniu operacji erozji i dylatacji
(w okręgu po lewej stronie po inwersji kolorów)

Na rys. 5.23 przedstawiono wynik działania operacji erozji i dylatacji. Kolorem zielonym oznaczony piksele, które w wyniku operacji zostały usunięte z obrazu i nie były brane pod uwagę w dalszych analizach.



Rys. 5.24. Finalny wynik operacji wyliczania pikseli stanowiących braki w konstrukcji
(w okręgu po lewej stronie po inwersji kolorów)

Tab. 5.12. Wyniki powierzchni pikseli stanowiących braki w konstrukcji dla zestawu 1

l.p.	px	% obrazu wirtualnego
1.	268	0.29199
2.	229	0.2495
3.	208	0.22662
4.	79	0.086073
5.	60	0.065372
6.	58	0.063193
7.	25	0.027238
8.	25	0.027238

Na RYS. 5.24 przedstawiono wynik wyliczenia braków w konstrukcji. Wynik poza prezentacją wizualną wykrytych obszarów stanowiących braki przedstawia także komunikat dotyczący kroków pośrednich. Komunikat podświetlony na czerwono: *Wykryto poprawnie 761 z 56575 to jest 1,35% braków* oznacza, że na obrazie poddanym analizie (obraz rzeczywiste) wykryto 761 pikseli, które składają się na potencjalny brak w konstrukcji. Piksele te stanowią 1,35% wszystkich pikseli analizowanego obrazu. Drugi komunikat, podświetlony na zielono: *Wykryto poprawnie 761 z 952 to jest 79,94% wszystkich wykrytych punktów*, oznacza że podczas analizy obrazu rzeczywistego i wirtualnego po zastosowanych operacjach i przekształceniach wykryto także 761 pikseli – informacja ta stanowi, że metoda zadziałała poprawnie, gdyż wykryła dokładnie taką samą ilość co analiza obrazów rzeczywistych. Informacja o procencie 79,94% informuje, że znalezione piksele w tym właśnie procencie określiły obszar potencjalnego braku, resztę stanowi szum. Informacje te wyświetlane są jedynie w celu pokazowym dla ewentualnej dokładnej analizy przez technika dokonującego oględzin materiału wizyjnego badanej linii.

Dokładne informacje o wynikach zapisywane są w pliku, którego przykładowe dane przedstawiono w tab. 5.12. Wyniki te zostały posortowane od największego względem obszarów pikseli. Jak można zauważyć występuje duża różnica pomiędzy wartością 3 i 4. Można wnioskować, że w tym właśnie miejscu znajduje się granica pomiędzy potencjalnym brakiem a szumem. Dodatkowo w 3 kolumnie przedstawiono procent jaki stanowi dany obszar pikseli względem kratownicy wzorcowej z obrazu wirtualnego. Po analizie tego zestawu można stwierdzić, że wystąpienie braku zachodzi w przypadku osiągnięcia tego parametru na poziomie 0,2%.

5.3. Podsumowanie rozdziału

W rozdziale tym omówiono proponowaną przez autora metodę selekcji wybranych cech. Praca poświęcona jest określaniu niezgodności obiektów kratowych, dlatego głównym punktem tego rozdziału było przedstawienie sposobu określania niezgodności analizowanych obrazów. Zaproponowano i omówiono także sposób rozwiązania problemu wykrywania nieistniejących różnic w wynikach, jakie stwierdzono po wstępnej analizie, występujące na poziomie rejestracji obrazów. Dokonano pogłębionej analizy

samego procesu rejestracji, dzięki czemu uzyskano wiedzę, w jaki sposób przygotować punkty CP do procesu rejestracji oraz jakich metod użyć w algorytmie dopasowania obrazów.

Rozdział ten miał na celu przedstawienie sposobu wykonywania procesu rejestracji obrazów oraz znajdowania w obrazach rzeczywistych niezgodności z wzorcem (obraz wirtualny), w celu wytypowania konkretnych obrazów do dalszej pogłębionej analizy.

6. Przyjęte reguły oceny stanu obiektów

6.1. Badanie przesiewowe

Badania przesiewowe lub inaczej analiza przesiewowa (*ang. screening lub skrining*), jest pojęciem zaczerpniętym z medycyny, które definiowane jest jako wstępna identyfikacja nierozpoznanej choroby w pozornie zdrowej, bezobjawowej populacji za pomocą testów, badań lub innych procedur, które można szybko i łatwo zastosować dla docelowej populacji [BeB96].

Badania przesiewowe wykonuje się w całej populacji lub tylko w tzw. grupach wysokiego ryzyka. Zamierzeniem badań przesiewowych jest wykrycie choroby we wczesnej fazie. Badanie to prowadzi do postawienia jedynie wstępnej diagnozy, która musi być zawsze potwierdzona innymi, bardziej dokładnymi badaniami, ukierunkowanymi już na szukanie wskazanej jednostki chorobowej. Wadą badań przesiewowych jest wykrycie wystąpienia choroby u zdrowej osoby. Z tych przyczyn testy używane w medycznych programach przesiewowych muszą wykazywać się dobrą czułością, szczególnie w przypadku chorób o niskiej zapadalności [BeB96].

W celu wytypowania z grupy zdjęć konstrukcji wsporczych linii elektroenergetycznej tych obrazów, na których znajdują się kratownice zawierające uszkodzenia, posłużono się mechanizmem analizy przesiewowej. Zadaniem opracowanej metody jest odciążenie techników sprawdzających zebrany materiał fotograficzny pod kątem znalezienia uszkodzeń na kratownicach. Zadania takie jest męczące, a po pewnym czasie pracy spada efektywność ludzkiego postrzegania, dlatego istotne jest ograniczenie grupy kilku tysięcy zdjęć do mniejszej liczby, zawierających zdjęcia, na których znajdują się kratownice, którym należy się dokładniej przyjrzeć, gdyż nie spełniają określonego kryterium.

Metoda powinna ze zdjęć wykonanych podczas corocznego oblotu linii wskazać te do dalszej analizy, którą wykona wykwalifikowany personel. W przeprowadzonych badaniach wykonano testy działania opracowanej metody na zdjęciach laboratoryjnych (wydrukowanego modelu słupa) oraz z wykorzystaniem zdjęć obiektu rzeczywistego.

Przyjęto, że zadaniem analizy jest wykrycie wszystkich zdjęć konstrukcji, w których występować będą niezgodności z wzorcem. Autor dopuszcza możliwość błędnego wytypowania konstrukcji, przy założeniu, że za błąd uważane jest wskazanie konstrukcji spełniającej wymagania jako obiektu zawierającego uszkodzenie. Jednakże

nie może wystąpić przypadek nie wykrycia konstrukcji zawierającej niezgodność. Matrycę stanów poprawnego działania metody przedstawiono na rys. 6.1.

		badany obiekt	
		występuje niezgodność – konieczność dokładniejszych oględzin	nie występuje niezgodność – obiekt nie wymaga dokładniejszych oględzin / napraw
wskazanie metody	występuje niezgodność – konieczność dokładniejszych oględzin	poprawnie	poprawnie
	nie występuje niezgodność – obiekt nie wymaga dokładniejszych oględzin / napraw	błąd	poprawnie

Rys. 6.1. Matryca przedstawiająca stany działania opracowanej metody

Jak można odczytać z rys. 6.1 istnieje tylko jeden stan, który interpretujemy jako błąd działania metody. Oczywiście autor dąży do poprawy czułości działania metody tak aby ograniczyć ilość występowania wskazań jako błędnych kratownic spełniających wymagania konstrukcyjne.

6.2. Implementacja w pracy

Po wykonaniu opisanych we wcześniejszych rozdziałach przekształceń otrzymuje się jako wynik obraz z zaznaczonymi ewentualnymi brakami i odpowiednim komunikatem (rys. 5.24) oraz plik tekstowy. W pliku tym w 4 kolumnach znajdują się następujące wartości:

- współrzędna x i y znalezionej obszaru pikseli (blob),
- wartość obszarów pikseli, które można uważać za niezgodność z wzorcem,
- wyliczoną wartość procentową jaką stanowią wykryte piksele w stosunku do wszystkich pikseli składających się na obraz wzorcowy (zdjęcie wirtualne).

Jak wspomniano, w każdorazowym przeprowadzeniu analiz, jako wynik otrzymywano informacje o obszarach składających się na brak w konstrukcji, ale także obszary, które powstały w skutek niedokładnego procesu rejestracji, a których nie udało się zniwelować poprzez zastosowanie opisanych przekształceń, nie tracąc informacji o istotnych brakach.

Istotnym z punktu widzenia skuteczności działania opracowanej metody było określenie reguł oceny otrzymanych wyników, tak aby metoda z jak największą dokładnością wskazywała właściwe obrazy. Przez określenie reguł rozumie się

wykazanie jak duży obszar pikseli będzie traktowany jako potencjalny sygnał do postawienia wstępnej diagnozy o konieczności wykonania dokładniejszych oględzin analizowanej kratownicy. Ważnym na tym etapie wnioskowania jest wartość, którą otrzymuje parametr określający procent zdjęcia wirtualnego (wzorca) jaki stanowią wyliczone piksele. Ta miara jest bardziej rzetelna, gdyż nie zależy wprost proporcjonalnie od rozdzielczości obrazu, który jest analizowany.

W związku z tym przeprowadzono serię analiz zestawów zdjęć laboratoryjnych. Przez zestawy laboratoryjne rozumie się wykonane zdjęcia wydrukowanego modelu 3D konstrukcji wsporczej w określonych warunkach oraz wyrenderowanych zdjęć wirtualnych. W celu przyspieszenia analiz, skupiono się jedynie na fragmencie MZW, odpowiedzialnej za analizę obrazu oraz wnioskowanie, pominięto etapy określenia pozycji kamery oraz generowania zdjęć wirtualnych. Użyto danych (zdjęć wirtualnych), które uzyskano we wcześniejszych etapach pracy.

6.3. Badania laboratoryjne

Zdjęcia laboratoryjne wykonano z 2 pozycji kamery, używając różnych sprzętów rejestrujących. Do badań wykorzystano aparat fotograficzny marki Canon EOS 30D z obiektywem zmiennoogniskowym o $f=24$ i o $f=60$ oraz Fujifilm X20 z obiektywem stałoogniskowym o $f=18$. Dodatkowo w celu określenia pozycji z jakiej wykonywane były zdjęcia podłużono się dalmierzem laserowym Leica DISTO D8. Dane techniczne urządzeń przedstawiono odpowiednio w tab. 6.1, tab. 6.2 i 6.3.

Tab. 6.1. Dane techniczne aparatu Canon EOS 30D [Can18]

Liczba pikseli	8,2 Mpix
Dostępne rozdzielczości	(LF) 3504 x 2336, (LN) 3504 x 2336, (MF) 2544 x 1696, (MN) 2544 x 1696, (SF) 1728 x 1152, (SN) 1728 x 1152, (RAW) 3504 x 2336
Rozdzielczość matrycy	22,5 mm x 15,0 mm CMOS (ekw. APS-C)
Procesor obrazu	DIGIC II
Format zapisu	JPEG (zgodny z Exif 2.21 [Exif Print]) / Design rule for Camera File system, jednoczesny zapis w formacie RAW & JPEG, zgodny z Digital Print Order Format [DPOF] Wersja 1.1
Zakres ISO	100-1600(w skoku co 1/3) ISO może być zwiększone do H: 3200 (wybierane w funkcjach użytkownika)
Migawka	30 - 1/8000 s

Tab. 6.2. Dane techniczne aparatu Fujifilm X20 [Fuj18]

Liczba pikseli	12 Mpix
Dostępne rozdzielczości	(4:3) 4000 × 3000 / (3:2) 4000 × 2664 / (16:9) 4000 × 2248 / (1:1) 2992 × 2992
Rozdzielczość matrycy	2/3-calowa, typu X-Trans CMOS II z filtrem barw podstawowych
Format zapisu	JPEG (Exif Ver 2.3) 2, RAW (format RAF), RAW+JPEG (zgodny z DCF - ang. Design rule for Camera File system / zgodny z DPOF)
Zakres ISO	ISO 100- 12800
Migawka	1/4 - 1/4000 s Auto, 30 - 1/4000 s

Tab. 6.3. Dane techniczne dalmierza laserowego Leica DISTO D8 [Dis18]

Zasięg	200 m
Dokładność	1 mm
Pomiar kąta	360°
Odporność	IP54
Waga:	200 g
Klasa lasera	II
Pamięć	30 pomiarów
Celownik	Cyfrowy, 4-krotny
Komunikacja	Bluetooth

W badaniach laboratoryjnych przygotowano do analizy 8 zestawów zdjęć obiektu oraz odpowiadającego mu zdjęcia wirtualnego. Zdjęcia te wykonano w ściśle określonych warunkach, znając dokładnie odległości w jakich znajdowały się od siebie aparat oraz fotografowany obiekt oraz wzajemne umiejscowienie w przestrzeni. Dzięki tym danym było możliwe sprawdzenie poprawności wygenerowania zdjęć wirtualnych, co opisano w rozdziale 4.4. Dane analizowanych zestawów przedstawiono w tab. 6.4. Natomiast na rys. 6.2 przedstawiono dokładnie, które zdjęcia składały się na poszczególne zestawy.

Tab. 6.4. Dane analizowanych zdjęć

nr zestawu	rozdzielczość zdjęcia	ogniskowa f	urządzenie
1	3504 x 2336	24	Canon EOS 30D
2			
3	4869 x 3264	18	Fujifilm X20
4			
5	3504 x 2336	24	Canon EOS 30D
6			
7		60	
8			

a)




b)



c)



d)




e)




f)



g)




h)



Rys. 6.2. Analizowane zestawy zdjęć laboratoryjnych, po lewej zdjęcie rzeczywiste, po prawej wirtualne, odpowiednio: a –zestaw 1, b –zestaw 2, c –zestaw 3, d –zestaw 4, e –zestaw 5, f –zestaw 6, g –zestaw 7, h –zestaw 8

W badanych zestawach celowo zostały usunięte określone elementy kratownicy, jak opisano w rozdziale 5.2. Na każdym zdjęciu usunięte zostały dokładnie te same

elementy. W celu poglądowym na rys. 6.3 przedstawiono wyniki rejestracji dla poszczególnych zestawów.



Rys. 6.3. Wyniki rejestracji obrazów dla poszczególnych zestawów

Badanie przeprowadzono dwuetapowo. W pierwszej części analizie poddano zdjęcia słupa nie zawierającego braków, w drugiej zdjęcia, w których brakowało

elementu. Wyniki dla poszczególnych zestawów przedstawiono w tab. 6.5÷6.20. Przedstawione w tabelach wyniki zawierają informacje o największych skupiskach blobów. Mniejsze wartości zostały pominięte.

Tab. 6.5. Wyniki dla obrazu kompletnego – zestaw 1

L.p.	px	% obrazu wirtualnego
1	79	0,086
2	60	0,065
3	58	0,063
4	25	0,027
5	25	0,027
6	25	0,027
7	24	0,027
8	23	0,027

Tab. 6.6. Wyniki dla obrazu z brakami – zestaw 1

L.p.	px	% obrazu wirtualnego
1	268	0,291
2	229	0,249
3	208	0,226
4	79	0,086
5	60	0,065
6	58	0,063
7	25	0,027
8	25	0,027

Tab. 6.7. Wyniki dla obrazu kompletnego – zestaw 2

L.p.	px	% obrazu wirtualnego
1	1240	0,861
2	1121	0,778
3	875	0,607
4	821	0,570
5	788	0,547
6	780	0,541
7	774	0,537
8	632	0,439
9	604	0,419
10	599	0,416
11	586	0,407
12	560	0,389
13	525	0,364
14	469	0,325
15	409	0,284
16	384	0,266
17	383	0,266
18	331	0,229
19	320	0,222

Tab. 6.8. Wyniki dla obrazu z brakami – zestaw 2

L.p.	px	% obrazu wirtualnego
1	2787	1,936
2	2175	1,510
3	1607	1,116
4	1494	1,037
5	1240	0,861
6	1121	0,778
7	875	0,607
8	821	0,570
9	788	0,547
10	780	0,541
11	774	0,537
12	632	0,439
13	604	0,419
14	599	0,416
15	586	0,407
16	560	0,389
17	525	0,364
18	469	0,325
19	409	0,284

Tab. 6.9. Wyniki dla obrazu kompletnego – zestaw 3

L.p.	px	% obrazu wirtualnego
1	90	0,077
2	86	0,074
3	75	0,065

Tab. 6.10. Wyniki dla obrazu z brakami – zestaw 3

L.p.	px	% obrazu wirtualnego
1	377	0,324
2	316	0,272
3	309	0,266

4	59	0,050
5	57	0,049
6	55	0,047
7	53	0,045
8	50	0,043
9	49	0,042
10	49	0,042
11	47	0,040
12	41	0,035
13	34	0,029
14	33	0,028
15	33	0,028
16	33	0,028
17	33	0,028
18	33	0,028
19	31	0,026
20	28	0,024

Tab. 6.11. Wyniki dla obrazu kompletnego – zestaw 4

L.p.	px	% obrazu wirtualnego
1	940	0,758
2	798	0,644
3	655	0,528
4	646	0,521
5	640	0,516
6	632	0,510
7	612	0,494
8	603	0,486
9	578	0,466
10	563	0,454
11	554	0,447
12	542	0,437
13	534	0,431
14	474	0,382
15	469	0,378
16	458	0,369
17	411	0,331
18	400	0,322
19	398	0,321
20	384	0,309

4	255	0,219
5	90	0,077
6	86	0,074
7	75	0,064
8	59	0,050
9	57	0,049
10	55	0,047
11	53	0,045
12	50	0,043
13	49	0,042
14	49	0,042
15	47	0,040
16	41	0,035
17	34	0,029
18	33	0,028
19	33	0,028
20	33	0,028

Tab. 6.12. Wyniki dla obrazu z brakami – zestaw 4

L.p.	px	% obrazu wirtualnego
1	1730	1,396
2	1611	1,301
3	1013	0,817
4	999	0,806
5	988	0,797
6	940	0,758
7	798	0,644
8	655	0,528
9	646	0,521
10	640	0,516
11	632	0,510
12	612	0,494
13	603	0,486
14	578	0,466
15	563	0,454
16	554	0,447
17	542	0,437
18	534	0,431
19	474	0,382
20	469	0,378

Tab. 6.13. Wyniki dla obrazu kompletnego – zestaw 5

L.p.	px	% obrazu wirtualnego
1	161	0,164
2	126	0,129
3	122	0,124
4	102	0,104
5	90	0,092
6	87	0,089
7	80	0,081
8	79	0,080
9	76	0,077
10	73	0,074
11	72	0,073
12	69	0,070
13	67	0,068
14	64	0,065
15	64	0,065
16	56	0,054
17	48	0,049
18	46	0,045
19	44	0,045
20	44	0,045

Tab. 6.14. Wyniki dla obrazu z brakami – zestaw 5

L.p.	px	% obrazu wirtualnego
1	326	0,333
2	251	0,257
3	241	0,246
4	224	0,229
5	204	0,208
6	161	0,164
7	126	0,129
8	122	0,124
9	102	0,104
10	90	0,092
11	87	0,089
12	80	0,081
13	79	0,080
14	76	0,077
15	73	0,074
16	72	0,073
17	69	0,070
18	67	0,068
19	64	0,065
20	64	0,065

Tab. 6.15. Wyniki dla obrazu kompletnego – zestaw 6

L.p.	px	% obrazu wirtualnego
1	100	0,115
2	97	0,112
3	70	0,081
4	70	0,081
5	66	0,076
6	59	0,068
7	54	0,062
8	42	0,048
9	42	0,048
10	41	0,047
11	39	0,045
12	37	0,042
13	36	0,041
14	35	0,040
15	35	0,040
16	34	0,039
17	31	0,035
18	31	0,035

Tab. 6.16. Wyniki dla obrazu z brakami – zestaw 6

L.p.	px	% obrazu wirtualnego
1	182	0,210
2	179	0,207
3	164	0,189
4	152	0,176
5	138	0,159
6	138	0,159
7	114	0,132
8	100	0,115
9	97	0,112
10	70	0,081
11	70	0,081
12	66	0,076
13	59	0,068
14	54	0,062
15	42	0,048
16	42	0,048
17	41	0,047
18	39	0,045

19	30	0,034
20	30	0,034

Tab. 6.17. Wyniki dla obrazu kompletnego – zestaw 7

L.p.	px	% obrazu wirtualnego
1	986	0,215
2	926	0,202
3	851	0,185
4	792	0,172
5	633	0,138
6	584	0,127
7	576	0,125
8	572	0,124
9	535	0,116
10	526	0,114
11	521	0,113
12	510	0,111
13	507	0,110
14	504	0,109
15	496	0,108
16	480	0,104
17	479	0,104
18	443	0,096
19	427	0,093
20	414	0,090

Tab. 6.19. Wyniki dla obrazu kompletnego – zestaw 8

L.p.	px	% obrazu wirtualnego
1	568	0,145
2	533	0,136
3	529	0,135
4	516	0,132
5	500	0,128
6	486	0,124
7	395	0,101
8	375	0,096
9	367	0,094
10	359	0,091
11	341	0,087
12	320	0,081
13	297	0,076
14	288	0,073
15	281	0,071

19	37	0,042
20	36	0,041

Tab. 6.18. Wyniki dla obrazu z brakami – zestaw 7

L.p.	px	% obrazu wirtualnego
1	2863	0,624
2	1624	0,354
3	1421	0,310
4	1225	0,267
5	986	0,215
6	926	0,202
7	851	0,185
8	792	0,172
9	633	0,138
10	584	0,127
11	576	0,125
12	572	0,124
13	535	0,116
14	526	0,114
15	521	0,113
16	510	0,111
17	507	0,110
18	504	0,109
19	496	0,108
20	480	0,104

Tab. 6.20. Wyniki dla obrazu z brakami – zestaw 8

L.p.	px	% obrazu wirtualnego
1	1088	0,278
2	793	0,203
3	789	0,202
4	610	0,156
5	568	0,145
6	533	0,136
7	529	0,135
8	516	0,132
9	500	0,128
10	486	0,124
11	395	0,101
12	375	0,096
13	367	0,094
14	359	0,091
15	341	0,087

16	275	0,070
17	250	0,064
18	246	0,063
19	243	0,062
20	236	0,060

16	320	0,081
17	297	0,076
18	288	0,073
19	281	0,071
20	275	0,070

Jak wynika z analizy powyższych wyników dla poszczególnych zestawów stwierdzić można, że nawet gdy poddano analizie zdjęcie nie zawierające błędów w budowie kratownicy otrzymano informacje o występowaniu małych obszarów pikseli, jak już wcześniej wspomniano jest to spowodowane jakością wykonania procesu rejestracji. Wniosek taki znajduje poparcie w fakcie, że większe obszary pikseli nie stanowiących informacji o brakach, występują częściej w ujęciach ukazujących obiekt pod kątem.

Analizując wyniki obrazów, które zawierały braki w konstrukcji kratowej stwierdzić można, że w tabelach wyróżniają się dość duże skupiska pikseli składające się na te braki. Zauważyć można, że pojawiły się wręcz dodatkowe komórki na początku tabeli z znaczącymi wartościami. W tych sytuacjach metoda powinna zwrócić informację o potencjalnym występowaniu niezgodności w analizowanym obszarze.

Wyznaczając reguły (tab. 6.21), wg których metoda zdjęć wirtualnych będzie podejmować decyzję czy brak w konstrukcji występuje, czy też nie, nie można się jedynie sugerować samą wartością liczby pikseli. Jest to spowodowane faktem, że wykonane zdjęcia mogą mieć różny rozmiar (rozdzielczość), co zostało pokazane w zestawie 3 i 4, których rozdzielczość była większa o $\frac{1}{4}$ w stosunku do pozostałych. O różnym poziomie występowania braku może także świadczyć odległość, z której wykonano zdjęcie, a tym samym jak dużą powierzchnię stanowił sam brak.

Tab. 6.21. Przedstawienie mechanizmu wnioskowania metody zdjęć wirtualnych

poziom parametru - % wirtualnego	wskazanie metody	dalsze działanie
1,0	z pewnością występuje niezgodność	konieczność dokładniejszej analizy przez technika
0,9		
0,8		
0,7		
0,6		
0,5	być może występuje niezgodność	
0,4		
0,3		
0,2	nie występuje niezgodność	dodatkowa analiza nie jest konieczna
0,1		
0,0		

Mając na uwadze powyższe aspekty wyliczono drugi parametr, który dawał informację bardziej rzetelną, a mianowicie obliczano procent jaki ze zdjęcia wzorcowego

(wirtualnego) stanowią wyliczone piksele. I tak analizując otrzymane wyniki, dla zdjęć laboratoryjnych wykonanych przy opisanych warunkach można stwierdzić, że metoda powinna kwalifikować jako zdjęcia potencjalnie zawierające niezgodność wg parametru procentu wirtualnego wszystkie obrazy z parametrem równym lub powyżej 0,3.

6.4. Badania obiektu rzeczywistego

Po serii analiz materiału laboratoryjnego oraz opracowaniu reguł oceny zebranych danych, autor przystąpił do zebrania i analizy materiału obiektu rzeczywistego. Omawiana konstrukcja wsporcza jest elementem linii biegnącej do stacji transformatorowej Opole Groszowice. Zdjęcia w warunkach rzeczywistych zostały wykonane aparatem Canon EOS 30D z tym samym obiektywem co zdjęcia w laboratorium, przy zachowaniu tej samej metodologii, czyli zdjęcia były wykonywane ze statywu w określonych punktach w terenie. Tak aby uchwycić konstrukcje z widoku frontalnego oraz pod kątem.

Zdjęcia obiektu rzeczywistego różnią się nieznacznie od obiektu laboratoryjnego, gdyż rozmiar konstrukcji oraz jego usytuowanie nie pozwoliły na uzyskanie widoku bezpośrednio wprost, dlatego kamera jest lekko skierowana ku górze. Dodatkowo nadmienić należy, że model CAD do generowania zdjęć wirtualnych został wykonany przez autora ponownie, gdyż obiekt, który był wykorzystywany w laboratorium, choć odpowiadał omawianej konstrukcji, w procesie tworzenia został nieznacznie zmodyfikowany, co uniemożliwiało jego wykorzystanie w analizie obiektu rzeczywistego.



Rys. 6.4. Przykładowe zdjęcie obiektu rzeczywistego z zaznaczonym fragmentem z którego usunięto elementy


Analizie poddano analogicznie jak to miało miejsce w przypadku badań laboratoryjnych 8 przygotowanych zestawów zdjęć, których dane określa

Tab. 6.22. Każdy zestaw po wygenerowaniu zdjęć wirtualnych został odpowiednio przygotowany, przez co rozumie się, że zostały w nich usunięte określone elementy z dolnej części kratownicy, co przedstawiono na rys. 6.4. Przygotowane zestawy przedstawiono poglądowo na rys. 6.5.


Tab. 6.22. Dane analizowanych zdjęć obiektu rzeczywistego

nr zestawu	rozdzielczość zdjęcia	ogniskowa f	urządzenie
9	3504 x 2336	24	Canon EOS 30D
10			
11		60	
12			
13		24	
14			
15		60	
16			


a)




b)




c)




d)




e)




f)



g)



h)



Rys. 6.5. Analizowane zestawy zdjęć obiektu rzeczywistego, po lewej zdjęcie rzeczywiste, po prawej wirtualne, odpowiednio: a –zestaw 9, b –zestaw 10, c –zestaw 11, d –zestaw 12, e –zestaw 13, f –zestaw 14, g –zestaw 15, h –zestaw 16

Podobnie jak to miało miejsce w przypadku analizy zdjęć laboratoryjnych istotnym etapem działania metody był proces rejestracji obrazów, którego wyniki dla poszczególnych zestawów przedstawiono na rys. 6.6.

a)



b)



c)



d)





Rys. 6.6. Wyniki rejestracji obrazów rzeczywistego obiektu dla poszczególnych zestawów

Analogicznie jak dla części laboratoryjnej badanie przeprowadzono dwuetapowo. W pierwszej części analizie poddano zdjęcia nie zawierające uszkodzeń, w drugiej zdjęcia, na których brakowało elementu. Wyniki dla poszczególnych zestawów przedstawiono w tab. 6.23÷6.38. Przedstawione w tabelach wyniki zawierają informacje o największych skupiskach blobów. Niższe wartości zostały pominięte.

Tab. 6.23. Wyniki dla obrazu kompletnego – zestaw 9

L.p.	px	% obrazu wirtualnego
1	507	0,196
2	394	0,152
3	384	0,148
4	378	0,146
5	376	0,145
6	375	0,145
7	362	0,139
8	332	0,128
9	330	0,127
10	317	0,122
11	285	0,110
12	242	0,093
13	226	0,087
14	210	0,081

Tab. 6.24. Wyniki dla obrazu z brakami – zestaw 9

L.p.	px	% obrazu wirtualnego
1	944	0,365
2	812	0,313
3	644	0,249
4	514	0,198
5	507	0,196
6	394	0,152
7	384	0,148
8	378	0,146
9	376	0,145
10	375	0,145
11	362	0,139
12	332	0,128
13	330	0,127
14	317	0,122

15	208	0,080
16	204	0,078
17	201	0,077
18	199	0,076
19	197	0,076
20	191	0,073

Tab. 6.25. Wyniki dla obrazu kompletnego – zestaw 10

L.p.	px	% obrazu wirtualnego
1	597	0,253
2	553	0,234
3	545	0,231
4	545	0,231
5	462	0,196
6	419	0,177
7	412	0,174
8	399	0,169
9	391	0,165
10	389	0,165
11	367	0,155
12	351	0,148
13	317	0,134
14	273	0,115
15	273	0,115
16	225	0,095
17	212	0,089
18	186	0,078
19	312	0,132
20	295	0,125

Tab. 6.27. Wyniki dla obrazu kompletnego – zestaw 11

L.p.	px	% obrazu wirtualnego
1	2292	0,349
2	2121	0,323
3	2107	0,321
4	1981	0,301
5	1948	0,296
6	1836	0,279
7	1827	0,278
8	1779	0,271
9	1743	0,265
10	1734	0,264

15	285	0,110
16	242	0,093
17	226	0,087
18	210	0,081
19	208	0,080
20	204	0,078

Tab. 6.26. Wyniki dla obrazu z brakami – zestaw 10

L.p.	px	% obrazu wirtualnego
1	1806	0,766
2	768	0,325
3	747	0,317
4	632	0,268
5	618	0,262
6	597	0,253
7	553	0,234
8	545	0,231
9	545	0,231
10	462	0,196
11	419	0,177
12	412	0,174
13	399	0,169
14	391	0,165
15	389	0,165
16	367	0,155
17	351	0,148
18	317	0,134
19	312	0,132
20	295	0,125

Tab. 6.28. Wyniki dla obrazu z brakami – zestaw 11

L.p.	px	% obrazu wirtualnego
1	3894	0,593
2	3079	0,469
3	3035	0,462
4	2897	0,441
5	2876	0,438
6	2716	0,413
7	2421	0,368
8	2381	0,362
9	2340	0,356
10	2304	0,351

11	1711	0,260
12	1680	0,256
13	1678	0,255
14	1631	0,248
15	1539	0,234
16	1502	0,228
17	1415	0,215
18	1362	0,207
19	1314	0,200
20	1309	0,199

Tab. 6.29. Wyniki dla obrazu kompletnego – zestaw 12

L.p.	px	% obrazu wirtualnego
1	2673	0,443
2	2376	0,394
3	2341	0,388
4	2242	0,372
5	2061	0,342
6	1992	0,330
7	1928	0,320
8	1901	0,315
9	1850	0,307
10	1797	0,298
11	1749	0,290
12	1670	0,277
13	1655	0,274
14	1534	0,254
15	1504	0,249
16	1496	0,248
17	1477	0,245
18	1357	0,225
19	1293	0,214
20	1534	0,254

Tab. 6.31. Wyniki dla obrazu kompletnego – zestaw 13

L.p.	px	% obrazu wirtualnego
1	435	0,168
2	394	0,152
3	384	0,148
4	378	0,146
5	376	0,145
6	375	0,145
7	362	0,139

11	2292	0,349
12	2121	0,323
13	2107	0,321
14	1981	0,301
15	1948	0,296
16	1836	0,279
17	1827	0,278
18	1779	0,271
19	1743	0,265
20	1734	0,264

Tab. 6.30. Wyniki dla obrazu z brakami – zestaw 12

L.p.	px	% obrazu wirtualnego
1	15459	2,566
2	10215	1,695
3	8309	1,379
4	6356	1,055
5	5410	0,898
6	5225	0,867
7	4938	0,819
8	3515	0,583
9	3208	0,532
10	2754	0,457
11	2730	0,453
12	2729	0,452
13	2673	0,443
14	2376	0,394
15	2341	0,388
16	2242	0,372
17	2061	0,342
18	1992	0,330
19	1928	0,320
20	1901	0,315

Tab. 6.32. Wyniki dla obrazu z brakami – zestaw 13

L.p.	px	% obrazu wirtualnego
1	944	0,365
2	867	0,335
3	655	0,253
4	514	0,198
5	507	0,196
6	435	0,168
7	394	0,152

8	330	0,127
9	317	0,122
10	285	0,110
11	242	0,093
12	227	0,087
13	210	0,081
14	208	0,080
15	204	0,078
16	201	0,077
17	199	0,076
18	197	0,076
19	191	0,073
20	177	0,068

Tab. 6.33. Wyniki dla obrazu kompletnego – zestaw 14

L.p.	px	% obrazu wirtualnego
1	462	0,196
2	412	0,174
3	399	0,169
4	391	0,165
5	389	0,165
6	367	0,155
7	351	0,148
8	317	0,134
9	312	0,132
10	295	0,125
11	273	0,115
12	273	0,115
13	225	0,095
14	212	0,089
15	186	0,078
16	177	0,075
17	165	0,070
18	147	0,062
19	140	0,059
20	130	0,055

Tab. 6.35. Wyniki dla obrazu kompletnego – zestaw 15

L.p.	px	% obrazu wirtualnego
1	1981	0,301
2	1836	0,279
3	1827	0,278

8	384	0,148
9	378	0,146
10	376	0,145
11	375	0,145
12	362	0,139
13	330	0,127
14	317	0,122
15	285	0,110
16	242	0,093
17	227	0,087
18	210	0,081
19	208	0,080
20	204	0,078

Tab. 6.34. Wyniki dla obrazu z brakami – zestaw 14

L.p.	px	% obrazu wirtualnego
1	1806	0,766
2	768	0,325
3	747	0,317
4	632	0,268
5	618	0,262
6	597	0,253
7	553	0,234
8	545	0,231
9	545	0,231
10	499	0,211
11	462	0,196
12	412	0,174
13	399	0,169
14	391	0,165
15	389	0,165
16	367	0,155
17	351	0,148
18	317	0,134
19	312	0,132
20	295	0,125

Tab. 6.36. Wyniki dla obrazu z brakami – zestaw 15

L.p.	px	% obrazu wirtualnego
1	3894	0,593
2	3515	0,535
3	3401	0,518

4	1743	0,265
5	1734	0,264
6	1711	0,260
7	1680	0,256
8	1678	0,255
9	1631	0,248
10	1539	0,234
11	1502	0,228
12	1415	0,215
13	1362	0,207
14	1314	0,200
15	1309	0,199
16	1229	0,187
17	1204	0,183
18	1184	0,180
19	1169	0,178
20	1167	0,177

Tab. 6.37. Wyniki dla obrazu kompletnego – zestaw 16

L.p.	px	% obrazu wirtualnego
1	3135	0,520
2	2730	0,453
3	2729	0,452
4	2673	0,443
5	2376	0,394
6	2341	0,388
7	2242	0,372
8	2061	0,342
9	1992	0,330
10	1901	0,315
11	1850	0,307
12	1749	0,290
13	1670	0,277
14	1655	0,274
15	1637	0,271
16	1555	0,258
17	1534	0,254
18	1504	0,249
19	1496	0,248
20	1477	0,245

4	3079	0,469
5	3035	0,462
6	2897	0,441
7	2876	0,438
8	2716	0,413
9	2421	0,368
10	2381	0,362
11	2340	0,356
12	2304	0,351
13	2219	0,338
14	2121	0,323
15	2107	0,321
16	1981	0,301
17	1836	0,279
18	1827	0,278
19	1743	0,265
20	1734	0,264

Tab. 6.38. Wyniki dla obrazu z brakami – zestaw 16

L.p.	px	% obrazu wirtualnego
1	15459	2,566
2	10215	1,695
3	8743	1,451
4	8309	1,379
5	6356	1,055
6	5410	0,898
7	5225	0,867
8	4938	0,819
9	3515	0,583
10	3208	0,532
11	3135	0,520
12	2730	0,453
13	2729	0,452
14	2673	0,443
15	2376	0,394
16	2341	0,388
17	2242	0,372
18	2061	0,342
19	1992	0,330
20	1901	0,315

Jak wynika z analizy powyższych wyników, podobnie jak miało miejsce w przypadku analizy laboratoryjnej, gdy analizie poddano zdjęcie nie zawierające różnic

w budowie kratownicy otrzymano jednak informacje o występowaniu małych obszarów pikseli. Podobnie jak miało to miejsce wcześniej, takie wyniki spowodowane są niedoskonałym wykonaniem procesu rejestracji. Otrzymane wartości parametrów dla zestawów rzeczywistych są wyższe, niż to miało miejsce w przypadku zdjęć laboratoryjnych, czego powodem jest wielkość usuniętych elementów, które stanowią same w sobie większe obszary. Średnio dla wszystkich zestawów są one wyższe o ok 1500 pikseli. Większy odsetek pikseli, które składają się na niedoskonałość procesu rejestracji spowodowany jest faktem, że w przypadku obiektu rzeczywistego belki są nieco cieńsze na zdjęciach, co utrudnia nieznacznie sam proces, jednakże nie ma negatywnego wpływu na działanie samej metody.

Tab. 6.39. Przedstawienie mechanizmu wnioskowania metody zdjęć rzeczywistych

poziom parametru - % wirtualnego	wskazanie metody	dalsze działanie
1,0	z pewnością występuje niezgodność	konieczność dokładniejszej analizy przez technika
0,9		
0,8		
0,7		
0,6		
0,5		
0,4	być może występuje niezgodność	
0,3		
0,2		
0,1		
0,0		
	nie występuje niezgodność	dodatkowa analiza nie jest konieczna

Analizując wyniki obrazów zawierających braki w konstrukcji stwierdzić można, że opracowany mechanizm wnioskowania dla analizy laboratoryjnej (tab. 6.21) wymaga niewielkiej poprawy. Mianowicie podniesiono poziom parametru % obrazu wirtualnego o 0,1 w stosunku do analizy laboratoryjnej. Aby wnioskować, że zdjęcie obiektu rzeczywistego odbiega od wzorca w znaczny sposób parametr ten musi osiągnąć wartość równą lub wyższą od 0,4.

Zauważyć można także, że część zdjęć nie zawierających braków w konstrukcji, np. z zestawu 12 i 16 zostałyby błędnie zakwalifikowane jako zawierające braki i skierowane do dalszej analizy. Jednakże takie efekty autor uważa za zupełnie poprawne. Ważnym jest fakt, aby przy przyjętych warunkach i parametrach żadne zdjęcie zawierające uszkodzenia nie zostało zakwalifikowane jako poprawne.

Nadmienić należy, że do poprawnego działania opracowanego narzędzia dla większej liczby zdjęć i modeli wymagana będzie jego kalibracja, którą należy przeprowadzić dla określonej partii zdjęć, wykonanych tym samym aparatem, przy zachowaniu podobnych warunków wykonania zdjęć. Przez podobne warunki rozumie się oświetlenie fotografowanych obiektów. W procesie kalibracji, która powinna być wykonana przez technika zostać powinny dobrane odpowiednie wartości zmiennych,

które zostały omówione w tym rozdziale. W dalszym etapie metoda wyboru obrazów z wystąpieniem potencjalnych odstępstw od wzorca następować będzie w sposób automatyczny.

6.5. Podsumowanie rozdziału

W rozdziale tym omówiono przyjęte oceny określania stanu badanych obiektów. Opisano zastosowanie mechanizmów analizy przesiewowej do określania parametru stwierdzenia niezgodności badanego obiektu ze wzorcem. Omówiono także implementację tego mechanizmu w opracowanym narzędziu. Opisane zostały także przeprowadzone badania na obiekcie laboratoryjnym oraz rzeczywistym, opisano problemy, jakie pojawiły się na etapie określenia stanu danego obiektu. Przedstawiono także mechanizm wnioskowania metody zdjęć wirtualnych, który zaproponował autor. Autor wykazał, że zaproponowany sposób oceny stanu konstrukcji działa poprawnie zarówno dla zdjęć laboratoryjnych jak i rzeczywistych.

Rozdział ten miał na celu przedstawienie sposobu wnioskowania z otrzymanych wyników analiz, które zdjęcia kratownic należy poddać dalszej analizie przez wyspecjalizowanego technika.

7. Analiza wyników działania opracowanej metody

7.1. Analiza doboru wartości parametrów metody

Po opracowaniu reguł oceny stanu badanych obiektów, serii analiz materiału obiektu laboratoryjnego i rzeczywistego i zauważeniu, że w procesie analizy występuje możliwość wskazywania jako błędnych, obiektów bez braków i uszkodzeń, autor postanowił sprawdzić czy istniałaby możliwość dostrajania poszczególnych parametrów na kolejnych etapach działania metody, w taki sposób aby wyznaczyć optymalną ścieżkę ustawień parametrów, tak aby metoda zdjęć wirtualnych działała z jak najlepszą skutecznością.

Na poszczególnych etapach działania metody przyjęto, że sprawdzane będą wyniki osiągnięte przy zmianie następujących zmiennych:

- stan dystorsji:
 - występuje,
 - nie występuje – w procesie analizy została usunięta.
- poziom binaryzacji:
 - badany w zakresie od 0,0 do 20,0 z skokiem co 1,0, dla kodowania 8-bitowego
- poziom korekty tła (threshold):
 - badany w zakresie od 0,0 do 20,0 z skokiem co 1,0
- metoda użyta w preprocesingu:
 - none,
 - Histeq,
 - Adaphisteq.
- redukcja rozdzielczości badanego obrazu:
 - 100%, 75%, 50%, 25% obrazu wejściowego
- zastosowana metoda rejestracji:
 - Projective,
 - Non-reflective similarity,
 - Affine,
 - Similarity.


Wszystkie analizy wykonano na przygotowanych wcześniej 16 zestawach – 8 dla zdjęć obiektu laboratoryjnego i 8 dla obiektu rzeczywistego.

Do oceny efektów uzyskiwanych z zmiany wartości zmiennych na poszczególnych etapach działania metody posłużono się używanymi już wcześniej miarami: Intersection over Union (IoU), Accuracy (Acc) oraz False Discovery Rate (FDR). Dodatkowo jako miarę oceny działania metody posłużyła informacja o wyliczonej liczbie pikseli składającej się na potencjalnie występujący brak (Blobs).


Dodatkowo wprowadzono dwie dodatkowe miary: Precision (precyzja metody pomiaru) i Recall (czułość). Przez precyzję rozumie się stopień zgodności między wynikami uzyskanymi w określonych warunkach. Miara czułości wskazuje na dokładność reagowania metody na zmieniające się parametry.

7.2. Omówienie skuteczności metody dla obiektu laboratoryjnego


Na rys. 7.1÷7.36 przedstawiono wyniki otrzymanych analiz. Wyniki te są pogrupowane wg miary, które posłużyły do określenia jak najlepszych wartości zmiennych dla każdego etapu działanie metody zdjęć wirtualnych.




Rys. 7.1. Wyniki uzyskanych blobów dla zmiany stanu dystorsji




Rys. 7.2. Wyniki uzyskanych blobów dla zmiany poziomu binaryzacji




Rys. 7.3. Wyniki uzyskanych blobów dla zmiany metody preprocesingu



Rys. 7.4. Wyniki uzyskanych blobów dla zmiany poziomu korekty



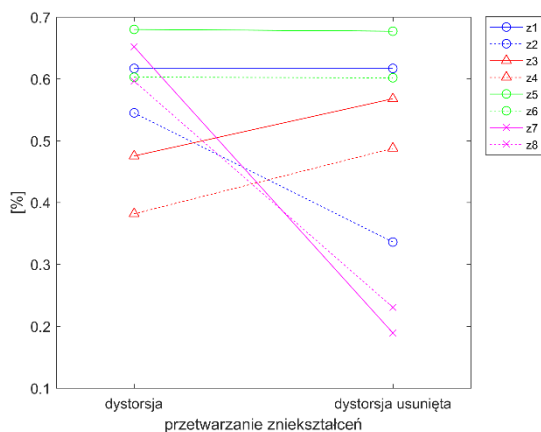
Rys. 7.5. Wyniki uzyskanych blobów dla zmiany rozmiaru rozdzielczości




Rys. 7.6. Wyniki uzyskanych blobów dla zmiany zastosowanej metody rejestracji

Na wykresach pokazanych na rys. 7.1÷7.6 przedstawiono jak zmieniała się liczba uzyskanych pikseli dla poszczególnych zestawów w zależności od określenia odpowiednich wartości poszczególnych zmiennych.

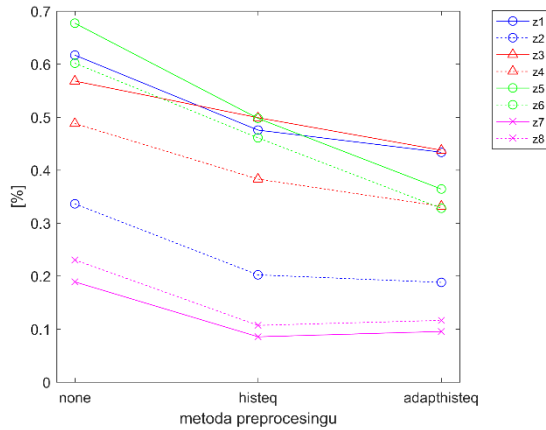
Można wywnioskować, że usunięcie dystorsji powoduje zwiększenie liczby znajdujących pikseli, podobnie jest dla wartości poziomu binaryzacji, zwiększanie tego poziomu działa pozytywnie na znajdowanie większej liczby pikseli. Zastosowane metody preprocesingu, a także poziomu korekty nie mają wpływu na znajdowaną liczbę pikseli. W obydwu przypadkach wartości dla poszczególnych zestawów są na stałym poziomie. Analizując wielkość analizowanego obrazu, stwierdzić można, że najlepsze wyniki uzyskano dla obrazów z rozdzielczością początkową. Z analizy metod rejestracji stwierdzić można, że najlepsze wyniki uzyskuje się używając metody Affine a najgorsze dla metody Non-reflective similarity, wyniki są takie same dla wszystkich zestawów.




Rys. 7.7. Uzyskane wyniki Acc dla zmiany stanu dystorsji




Rys. 7.8. Uzyskane wyniki Acc dla zmiany poziomu binaryzacji




Rys. 7.9. Uzyskane wyniki Acc dla zmiany metody preprocessingu



Rys. 7.10. Uzyskane wyniki Acc dla zmiany poziomu korekty




Rys. 7.11. Uzyskane wyniki Acc dla zmiany rozmiaru obrazu




Rys. 7.12. Uzyskane wyniki Acc dla zmiany metody rejestracji


Analizując kolejne wyniki, przedstawione na rys. 7.7÷7.12, można stwierdzić, że najlepszy stopień zgodności metody występuje dla określenia wartości poszczególnych zmiennych dla następujących wartości. Obraz powinien być poddany usunięciu dystorsji (dla 3 przypadków stopień zgodności po usunięciu dystorsji spadł, jednak uznano, że jest to wynik błędu metody). Poziom binaryzacji nie powinien przekroczyć wartość 5, gdyż poniżej tego poziomu dla wszystkich zestawów stopień zgodności spada poniżej 50%. Najlepszą zgodność uzyskano nie poddając obrazu procedurze preprocessingu. Natomiast co do metod rejestracji najlepiej sprawdziła się metoda Projective i Affine. Dla obydwu metod wartości są na tym samym poziomie.




Rys. 7.13. Uzyskane wyniki IoU dla zmiany stanu dystorsji




Rys. 7.14. Uzyskane wyniki IoU dla zmiany poziomu binaryzacji




Rys. 7.15. Uzyskane wyniki IoU dla zmiany metody preprocesingu



Rys. 7.16. Uzyskane wyniki IoU dla zmiany poziomu korekty




Rys. 7.17. Uzyskane wyniki IoU dla zmiany rozmiaru obrazu




Rys. 7.18. Uzyskane wyniki IoU dla zmiany metody rejestracji


Dla analizy miary IoU, przedstawionych na rys. 7.13÷7.18 stwierdzić można, że uzyskano wyniki zbieżne z analizą miary poziomu blobów.




Rys. 7.19. Uzyskane wyniki FDR dla zmiany stanu dystorsji




Rys. 7.20. Uzyskane wyniki FDR dla zmiany poziomu binaryzacji




Rys. 7.21. Uzyskane wyniki FDR dla zmiany metody preprocesingu



Rys. 7.22. Uzyskane wyniki FDR dla zmiany poziomu korekty




Rys. 7.23. Uzyskane wyniki FDR dla zmiany rozmiaru obrazu




Rys. 7.24. Uzyskane wyniki FDR dla zmiany metody rejestracji


Analizując otrzymane wyniki, pokazane na wykresach przedstawionych na rys. 7.19÷7.24 dla miary FRD, stwierdzono, że metoda daje najlepsze wyniki dla obrazów z usuniętą dystorsją, poziomie binaryzacji nie większym niż 5, dla obrazów z rozmiarem początkowym oraz przy użyciu metody Projective jako metody rejestracji.




Rys. 7.25. Uzyskane wyniki parametru Precision dla zmiany stanu dystorsji




Rys. 7.26. Uzyskane wyniki parametru Precision dla zmiany poziomu binaryzacji




Rys. 7.27. Uzyskane wyniki parametru Precision dla zmiany metody preprocesingu



Rys. 7.28. Uzyskane wyniki parametru Precision dla zmiany poziomu korekty




Rys. 7.29. Uzyskane wyniki parametru Precision dla zmiany rozmiaru obrazu




Rys. 7.30. Uzyskane wyniki parametru Precision dla zmiany metody rejestracji

Poddając analizie stopień zgodności działania MZW (rys. 7.25÷7.30) można wywnioskować, że najlepsze wyniki uzyskano dla obrazów, które poddano procesowi binaryzacji z wartością nie większą niż 5. Niezależnie od użytej metody preprocesingu. Najlepszy wynik uzyskano dla obrazu o 100% wielkości, a w prosicie rejestracji w przypadkach użycia metody Projective i Affine. To która metoda okazywała się lepsza


zależało jedynie od analizowanego zestawu, jednakże średnio wyniki w obu metodach wychodziły na podobnym poziomie.




Rys. 7.31. Uzyskane wyniki parametru Recall dla zmiany stanu dystorsji




Rys. 7.32. Uzyskane wyniki parametru Recall dla zmiany poziomu binaryzacji




Rys. 7.33. Uzyskane wyniki parametru Recall dla zmiany metody preprocesingu



Rys. 7.34. Uzyskane wyniki parametru Recall dla zmiany poziomu korekty



Rys. 7.35. Uzyskane wyniki parametru Recall dla zmiany rozmiaru obrazu



Rys. 7.36. Uzyskane wyniki parametru Recall dla zmiany metody rejestracji

Otrzymane wyniki miary czułości (rys. 7.31÷7.36) działania opracowanej metody, pozwalają wywnioskować, że usunięcie dystorsji działa pozytywnie na otrzymane

wyniki. Podobnie jest dla wartości poziomu binaryzacji, zwiększanie tego poziomu działa pozytywnie na znajdowanie większej liczby pikseli. Zastosowane metody preprocesingu, jak także poziom korekty nie mają wpływu na czułość. Analizując wielkość analizowanego obrazu, stwierdzić można, że najlepsze wyniki uzyskano dla obrazów z wielkością początkową. Z analizy metod rejestracji stwierdzić można, że najlepsze wyniki uzyskuje się używając metody Affine.


Biorąc pod uwagę całościowo otrzymane wyniki przeprowadzonych analiz można stwierdzić, że dla zdjęć obiektu laboratoryjnego wykonanych w określonych warunkach należy przyjąć następujące wartości zmiennych w celu otrzymania jak najlepszej skuteczności:

- zdjęcie poddane analizie powinno być pozbawione wad obiektywu (usunięcie dystorsji);
- w procesie binaryzacji poziom tego przekształcenia powinno się przyjąć na poziomie 5;
- fazę preprocesingu zdjęć można pominąć, zabiera ona czas a jej wyniki się znacząco nie zmieniają;
- poziom korekty jaki się użyje, nie ma wpływu otrzymane wyniki, w związku z czym proponuje się użycie korekty na poziomie 1 w celu ograniczenia czasu działania metody;
- analizie należy poddać obrazy wejściowe, nie zmieniając ich rozmiaru;
- jako metodę rejestracji należy przyjąć metodę Projective lub Affine. Obydwie metody dają takie same wyniki.


Z analizy wykresów można wywnioskować, że metodą uzyskuje się zróżnicowane wyniki dla różnych zestawów zdjęć. Tak jak było to omawiane we wcześniejszych rozdziałach, zdjęcia obiektu należy wykonywać najlepiej w ujęciu frontalnym. Na zdjęciach wykonywanych pod kątem znacznie częściej pojawiają się błędy niedopasowania, które mają wpływ na działanie metody.

7.3. Omówienie skuteczności metody dla obiektu rzeczywistego


Analizy wyników dla zdjęć obiektu rzeczywistego przedstawiono na rys. 7.37÷7.72. Analogicznie jak dla badań laboratoryjnych wyniki pogrupowano wg miary, które posłużyły do określenia jak najlepszych wartości zmiennych dla każdego etapu działania opracowanej metody.




Rys. 7.37. Wyniki uzyskanych blobów dla zmiany stanu dystorsji




Rys. 7.38. Wyniki uzyskanych blobów dla zmiany poziomu binaryzacji




Rys. 7.39. Wyniki uzyskanych blobów dla zmiany metody preprocesingu



Rys. 7.40. Wyniki uzyskanych blobów dla zmiany poziomu korekty



Rys. 7.41. Wyniki uzyskanych blobów dla zmiany rozmiaru obrazu




Rys. 7.42. Wyniki uzyskanych blobów dla zmiany metody rejestracji


Na wykresach pokazanych na rys. 7.37÷7.42 przedstawiono jak zmieniała się liczba uzyskanych pikseli dla poszczególnych zestawów w zależności od określenia odpowiednich wartości poszczególnych zmiennych. Z analizy otrzymanych wyników powierzchni blobów można wywnioskować, że usunięcie dystorsji w tym przypadku dla 4 zestawów daje gorsze wyniki, są to zestawy, w których kratownica obejmowała całą

wysokość analizowanego obrazu. W pozostałych przypadkach usunięcie dystorsji pozytywnie wpłynęło na otrzymane wyniki.


Wartości zmiennych dla procesu korekty i binaryzacji oraz metoda użyta w procesie preprocesingu nie mają wpływu na uzyskany obszar pikseli. Dla wszystkich zmiennych osiągnane wartości pikseli są stałe. Podobnie jak miało to miejsce dla zestawów laboratoryjnych zmniejszenie wielkości analizowanego obrazu zmniejsza ilość wykrytych pikseli. W odróżnieniu natomiast od analizy laboratoryjnej w procesie rejestracji najlepsze wyniki uzyskano dla metody Non-reflective similarity i Similarity, które w analizie laboratoryjnej nie wypadały tak korzystnie, aczkolwiek różnice są niewielkie




Rys. 7.43. Uzyskane wyniki parametru Acc dla zmiany stanu dystorsji




Rys. 7.44. Uzyskane wyniki parametru Acc dla zmiany poziomu binaryzacji




Rys. 7.45. Uzyskane wyniki parametru Acc dla zmiany metody preprocesingu



Rys. 7.46. Uzyskane wyniki parametru Acc dla zmiany poziomu korekty




Rys. 7.47. Uzyskane wyniki parametru Acc dla zmiany rozmiaru obrazu




Rys. 7.48. Uzyskane wyniki parametru Acc dla zmiany metody rejestracji


Analizując kolejne wyniki, przedstawione na rys. 7.43÷7.48, można stwierdzić, że najlepszy stopień zgodności metody występuje po określeniu wartości poszczególnych zmiennych dla następujących wartości. Obraz powinien być poddany usunięciu dystorsji, a metodą preprocesingu jaką powinno się użyć jest Histeq. Zmiana poziomu korekty i poziomu binaryzacji nie ma wpływu na otrzymane wyniki. Największą miarę uzyskano dla najmniejszego obrazu, natomiast jako metodę rejestracji wyliczono, że najlepiej sprawdziła się metoda Affine. Otrzymane wartości Acc są na dobrym poziomie, słabo wypadły głównie na zestawów przedstawiających obiekt z widoku pod kątem.




Rys. 7.49. Uzyskane wyniki parametru IoU dla zmiany stanu dystorsji




Rys. 7.50. Uzyskane wyniki parametru IoU dla zmiany poziomu binaryzacji




Rys. 7.51. Uzyskane wyniki parametru IoU dla zmiany metody preprocesingu



Rys. 7.52. Uzyskane wyniki parametru IoU dla zmiany poziomu korekty




Rys. 7.53. Uzyskane wyniki parametru IoU dla zmiany rozmiaru obrazu




Rys. 7.54. Uzyskane wyniki parametru IoU dla zmiany metody rejestracji


Dla analizy miary IoU, przedstawionych na rys. 7.49÷7.54 stwierdzić można, że obrazy powinny być poddane procesowi usunięcia dystorsji. Metodą preprocesingu jaką powinno się użyć jest Histeq, wyróżnia się ona bardzo mocno na tle innych opcji. Zmiana poziomu korekty i poziomu binaryzacji nie ma wpływu na otrzymane wyniki. Wraz ze zmniejszeniem wielkości obrazów IoU spada. Natomiast w procesie rejestracji średnie najlepsze wyniki daje metoda Affine.




Rys. 7.55. Uzyskane wyniki parametru FDR dla zmiany stanu dystorsji




Rys. 7.56. Uzyskane wyniki parametru FDR dla zmiany poziomu binaryzacji




Rys. 7.57. Uzyskane wyniki parametru FDR dla zmiany metod preprocesingu



Rys. 7.58. Uzyskane wyniki parametru FDR dla zmiany poziomu korekty




Rys. 7.59. Uzyskane wyniki parametru FDR dla zmiany rozmiaru obrazu




Rys. 7.60. Uzyskane wyniki parametru FDR dla zmiany metod rejestracji

Wyniki miary FDR, pokazane na wykresach przedstawionych na rys. 7.55÷7.60, dają możliwość wywnioskowania, że podobnie jak inne parametry wskazują, że najmniejsze błędy metody otrzymano dla obrazów z usuniętą dystorsją i po poddaniu obrazów przekształceniem Histeq w fazie preprocesingu. Wartości parametrów binaryzacji i korekty mają wartości stałe. FDR wykazuje, że metoda lepiej zareagowała


dla zestawów, na których obiekt znajdował się na całej wysokości obrazu. Najlepszą metodą rejestracji wykazano metodę Affine.




Rys. 7.61. Uzyskane wyniki parametru Precision dla zmiany stanu dystorsji




Rys. 7.62. Uzyskane wyniki parametru Precision dla zmiany poziomu binaryzacji




Rys. 7.63. Uzyskane wyniki parametru Precision dla zmiany metody preprocessingu



Rys. 7.64. Uzyskane wyniki parametru Precision dla zmiany poziomu korekty




Rys. 7.65. Uzyskane wyniki parametru Precision dla zmiany rozmiaru obrazu




Rys. 7.66. Uzyskane wyniki parametru Precision dla zmiany metody rejestracji

Po analizie wyników stopnia zgodności, pokazanych na rys. 7.61÷7.66 można stwierdzić, że analizowane obrazy powinny być poddane procesowi usunięcia dystorsji. Metodą preprocessingu jaką powinno się użyć jest Histeq, aczkolwiek dla 2 zestawów – 9


i 13 lepsza okazała się metoda Adaphisteq. Zmiana poziomu korekty i poziomu binaryzacji nie ma wpływu na otrzymane wyniki. Wraz ze zmniejszeniem wielkości obrazów stopień precyzji działania metody spada. W procesie rejestracji średnie najlepsze wyniki daje metoda Projective i Affine.




Rys. 7.67. Uzyskane wyniki parametru Recall dla zmiany stanu dystorsji




Rys. 7.68. Uzyskane wyniki parametru Recall dla zmiany poziomu binaryzacji




Rys. 7.69. Uzyskane wyniki parametru Recall dla zmiany metody preprocessingu



Rys. 7.70. Uzyskane wyniki parametru Recall dla zmiany poziomu korekty



Rys. 7.71. Uzyskane wyniki parametru Recall dla zmiany rozmiaru obrazu



Rys. 7.72. Uzyskane wyniki parametru Recall dla zmiany metody rejestracji

Podobnie jak w przypadku stopnia zgodności tak i stopień czułości badanej metody dały podobne wyniki. Otrzymane wyniki miary czułości (rys. 7.67÷7.72) działania opracowanej metody, pozwalają stwierdzić, że analizowane obrazy powinny być poddane procesowi usunięcia dystorsji. Metodą preprocesingu jaką powinno się użyć jest Histeq. Zmiana poziomu korekty i poziomu binaryzacji nie ma wpływu na otrzymane wyniki. Wraz ze zmniejszeniem wielkości obrazów stopień precyzji działania metody spada. Średnie najlepsze wyniki w procesie rejestracji daje metoda Projective i Affine.

Analizując otrzymane wyniki badań obrazów obiektu rzeczywistego można stwierdzić, że dla zdjęć wykonanych w określonych warunkach pogodowych, tzn. w słoneczny dzień, wykonanych z ziemi, gdy aparat był skierowany względem obiektu pod kątem należy przyjąć następujące wartości zmiennych w celu otrzymania jak najlepszej skuteczności:

- zdjęcie poddane analizie powinno być pozbawione wad obiektywu (usunięcie dystorsji);
- w procesie binaryzacji poziom nie miał znaczenia, jednak biorąc pod uwagę badania laboratoryjne stwierdzono, że można przyjąć także jego wartość na poziomie 5;
- faza preprocesingu obrazów obiektu rzeczywistego ma znaczenie, w odróżnieniu jak miało to miejsce dla analiz laboratoryjnych. Jako metodę należy przyjąć metodę Histeq;
- poziom korekty jaki użyje się, podobnie jak miało to miejsce w analizie laboratoryjnej, nie ma wpływu na otrzymane wyniki, w związku z czym proponuje się użycie korekty na poziomie 1 w celu ograniczenia czasu działania metody;
- analizie należy poddać obrazy wejściowe, nie zmieniając ich rozmiaru;
- jako metodę rejestracji należy przyjąć metodę Affine, pomimo faktu, że przy wyznaczaniu liczby pikseli lepiej wypadła metoda Non-reflective similarity, to właśnie metoda Affine daje lepszy stopień zgodności oraz czułości w działaniu metody.

Z analizy wykresów można wywnioskować, że w metodzie uzyskuje się zróżnicowane wyniki dla różnych zestawów zdjęć, podobnie jak miało to miejsce w analizie laboratoryjnej. Lepsze wyniki dają zestawy ze zdjęciami obiektu wykonanymi w ujęciu frontalnym. Na zdjęciach wykonywanych pod kątem znacznie częściej pojawiają się błędy niedopasowania, które mają wpływ na działanie metody. Zauważono także, że gorsze wyniki dały zestawy, dla których obiekt znajdował się na całym obszarze analizowanego obrazu.

Należy przyjąć, że proponowane ustawienia wartości zmiennych na konkretne wartości odpowiada analizowanemu zestawom zdjęć wykonanym w określonych warunkach z określonym sprzętem fotograficznym. Do prawidłowego działania metody autor zaleca każdorazowe skalibrowanie wykonanej aplikacji przez wykonanie testów z użyciem kilku przykładowych zdjęć, Każdorazowo dla każdej linii lub innych warunków oświetlenia.

7.4. Podsumowanie rozdziału

W rozdziale tym omówiono analizę wyników działania opracowanej metody. Opisano dokładnie zmienne i ich parametry, które można regulować w czasie procesu kalibracji opracowanej metody. Dokonano analizy doboru wartości paramentów dla zestawów zdjęć obiektu laboratoryjnego i rzeczywistego. Opisano dokładnie ścieżkę optymalnych parametrów, dzięki użyciu których metoda daje najlepsze wyniki.

Rozdział ten miał na celu przedstawienie najważniejszych elementów metody, którymi dzięki zmianie parametrów można wpływać na jakość otrzymanych wyników. Wykazano, że w cyklu całej analizy najważniejszymi etapami, mającymi największy wpływ na ostateczny wynik, jest proces usunięcia dystorsji i rejestracji obrazów.

8. Podsumowanie i wnioski

Techniki przetwarzania obrazów cyfrowych są nadal dziedziną bardzo prężnie rozwijającą się, głównie za sprawą postępu w obszarze sprzętu fotograficznego i wizyjnego (zwiększenie rozdzielczości, mniejsze dystorsje) oraz zwiększenia liczby zastosowań analizy obrazów w przemyśle. Dzięki takiemu rozwojowi istnieje duży postęp w obszarach zajmujących się analizą zebranego materiału fotograficznego. Coraz częściej obrazy są wykonywane w różnego rodzaju zadaniach diagnostycznych, często w przemyśle. Diagnostyka z użyciem technik przetwarzania obrazów daje duże możliwości oględzin i analizy stanu badanych obiektów, systemów, itp.

Zbieranie materiału fotograficznego stało się popularną praktyką, także w energetyce. Podczas oblotów lub corocznego przeglądu wykonywane są zdjęcia elementów linii: konstrukcje wsporcze, izolatory, przewody, w celu ich dokładniejszych oględzin przez wykwalifikowany personel oraz odnalezienie odstępstwa w budowie poszczególnych elementów. W związku z tym, że wzrok ludzki szybko się męczy, spada koncentracja oraz możliwość szybkiego rozpoznawania odstępstw w budowie tak skomplikowanych obiektów, jakimi są kratownice konstrukcji wsporczej, pojawiło się pytanie czy istniałby sposób zautomatyzowania wstępnej fazy rozpoznania dużej ilości zdjęć i ich odstępstw od wzorcowego stanu, którym był obiekt po zakończeniu budowy.

Celem niniejszej pracy było opracowanie metody do wstępnej półautomatycznej diagnostyki obiektów przestrzennych na przykładzie kratownic linii elektroenergetycznej. W proponowanej metodzie, której celem było (poprzez analizę całości materiału fotograficznego) wytypowanie tych zdjęć, na których konstrukcja kratowa budzi pewne wątpliwości poprzez zastosowanie mechanizmów zaczerpniętych z analizy przesiewowej. Opracowano metodę oraz narzędzie, które zweryfikowano w oparciu o posiadane zdjęcia obiektu laboratoryjnego i rzeczywistego.

W wyniku realizacji pracy opracowano i zaimplementowano w środowisku programistycznym metodę do wstępnej półautomatycznej diagnostyki konstrukcji kratowych, na przykładzie konstrukcji wsporczej linii elektroenergetycznej. W trakcie prac nad metodą pojawiły się pewne problemy, które nie zostały przewidziane we wstępnych pracach, a których rozwiązanie było kluczowe z punktu widzenia prawidłowego działania metody. Były nimi:

- Błędy powodowane wadami obiektywów.

Istniejące wady geometryczne obiektywów autor niwelował przy pomocy istniejących algorytmów usuwania tych zniekształceń. W związku z faktem, że fotografowane obiekty zajmowały różną część obrazów (nie zawsze znajdowały się przy krawędziach obrazów), gdzie występowanie dystorsji jest najsilniejsze, postanowiono sprawdzić, czy analiza obrazów bez korekty dystorsji, mocno wpłynie na obniżenie skuteczności opracowanej metody. Stwierdzono, że lepsze wyniki uzyskano poddając analizie obrazy po usunięciu dystorsji, pominięcie tego etapu w działaniu metody można byłoby zastosować dla obrazów z obiektem w centrum zdjęcia, jednak w związku z analizą całościową postanowiono, każde zdjęcie skorygować. Nadmienić należy także fakt, że w procesie przygotowania do usunięcia zniekształceń w sposób programowy konieczne było wykonanie jednorazowej kalibracji kamery.

- Generacja zdjęcia wirtualnego.

Zdjęciem wirtualnym nazwano obraz będący renderem modelu 3D badanej kratownicy. Problemem, który pojawił się na tym etapie prac było odpowiednie przygotowanie sceny w środowisku CAD, tak aby uzyskać obraz wzorcowy z takimi samymi parametrami jak obraz analizowany. Pobranie informacji o rozdzielczości obrazu, nie stanowiło problemu. Trudniejszym elementem było ustawienie odpowiedniego widoku kamery w programie, tak aby widok ten odpowiadał widokowi obrazu przygotowanego do analizy. W tej części badań posłużono się metodami zaczerpniętymi z geodezji, a mianowicie geometrią epipolarną. Zaimplementowano programowo wyznaczenie współrzędnych umiejscowienia kamery (z dwóch zdjęć analizowanych) i przesłano te informacje do środowiska CAD, dzięki czemu możliwe było ustawienie w nim kamery w odpowiednim punkcie względem obiektu. Dodatkowo korzystając z mechanizmów geometrii epipolarnej uzyskiwano dane dotyczące kątów obrotu kamery, punktu głównego zdjęcia oraz przybliżenia obiektywu. Dzięki tak pobranym i przygotowanym informacjom, możliwe było wygenerowanie zdjęcia wirtualnego, które odpowiadało zdjęciu analizowanemu.

- Rejestracja obrazów

Proces rejestracji obrazów rzeczywistego i wirtualnego w początkowych fazach pracy nie był rozpatrywany. W trakcie wykonywania testów okazało się, że nie jest możliwe wygenerowanie zdjęcia wirtualnego w taki sposób aby w 100% pokrywało się dokładnością ze zdjęciem rzeczywistym. Dlatego postanowiono zastosować algorytm rejestracji badanych obrazów. Przeanalizowano różne metody rejestracji, jak także rozpatrywano zastosowanie automatycznej metody rejestracji. Niestety w czasie testów metoda ta się nie sprawdziła. Kratownica jest obiektem zbyt skomplikowanym, posiadającym zbyt dużą ilość podobnych elementów, aby algorytmy automatycznej rejestracji działały z zadowalającą dokładnością. Wykazano jednak, że etap ten

w metodzie wpłynął pozytywnie na jej dalsze działanie, a jako punkty korelacji obrazów należy wskazywać krańcowe punkty badanego obiektu. Dokonano także kompletnej analizy jak należy wykonywać zdjęcia badanego obiektu aby polepszyć wyniki działania metody.

- Korekta obrazu przed analizą

Nawet najdokładniej wykonany proces rejestracji pozostawiał drobne błędy, które mogły rzutować na działanie metody. Przez błędy te rozumie się występowanie pikseli w obszarach, w których dopasowanie w pełni się nie udało. Piksele te stanowią szum informacyjny. Jednakże w trakcie analiz zauważono, że takie informacje nie przeszkadzają w aspekcie analizy wystąpienia braku, gdyż wystąpienie takiej sytuacji powoduje, że na rzeczywisty wykrywany brak składa się dużo większy obszar pikseli. W celu oczyszczenia zdjęcia zastosowano naprzemienne wykonanie operacji erozji i dylatacji, dzięki czemu wyeliminowano piksele niezawierające się w większych grupach.

- Opracowanie reguły oceny stanu obiektów

Po przeprowadzeniu analiz opracowano reguły oceny stanu obiektów. Zaproponowano obliczania parametru (% obrazu wirtualnego), który jednoznacznie wskazuje, jak wiele ze znalezionych na analizowanych obrazach pikseli stanowi procent z wzorcowego obrazu. Wyznaczono progi powyżej których wymagana jest interwencja personelu technicznego i dokładniejsza analiza wskazanego zdjęcia. Podczas testów stwierdzono, że prawidłowe działanie metody wymaga odpowiednie skalibrowanie oprogramowania, na kilku przykładowych zdjęciach.

Efektami praktycznymi pracy są:

- wykonanie modelu 3D słupa rzeczywistego,
- opracowanie metody do wstępnej półautomatycznej diagnostyki obiektów kratowych – metoda zdjęć wirtualnych,
- zaimplementowanie opracowanej metody do środowiska obliczeniowego,
- opracowanie zaleceń wykonywania zdjęć diagnostycznych konstrukcji, aby jak najlepiej wykorzystać potencjał opracowanej metody.

Wobec powyżej przedstawionych efektów, na podstawie wyników uzyskanych dzięki oprogramowaniu autorskiej metody oraz jej implementacji, teza pracy: „Istnieje możliwość wykorzystania metod cyfrowego przetwarzania obrazów, aby wykorzystując model 3D badanego obiektu oraz jego zdjęcie metryczne, zrealizować algorytm wyznaczania niezgodności wybranych parametrów obiektu z modelem” została udowodniona.

Weryfikacja postawionych tez oraz przeprowadzone badania zaowocowały wnioskami i wskazówkami w zakresie analizy diagnostycznej obiektów przestrzennych na przykładzie kratownicy:

1. Nie jest możliwym wykonanie zdjęć wielkogabarytowych obiektów przemysłowych w taki sposób, aby ustrzec się wystąpienia zniekształceń geometrycznych obiektu. Usunięcie tych zniekształceń w sposób programowy nie wpływa negatywnie na wyniki.
2. Proces rejestracji ma pozytywny wpływ na poprawę skuteczności działania metody. Nie jest możliwym uzyskanie 100% zgodności zdjęcia obiektu rzeczywistego z jego zdjęciem wirtualnym, uzyskanym z modelu 3D. Autorowi nie udało się znaleźć odpowiedzi dlaczego tak się dzieje. Autor sądzi, że znaczenie mogą mieć operacje przygotowujące tj. usuwanie dystorsji, czy wyliczanie pozycji kamery. Pomimo wykazania, że każdy z tych etapów cechuje się małymi błędami, to jednak stwierdzono, że nawet tak małe błędy wywołują widoczne niedopasowania generowanego zdjęcia wirtualnego do zdjęcia rzeczywistego, który proces rejestracji powinien wyeliminować.
3. Automatyczny proces rejestracji okazał się trudny do zrealizowania. Podejrzewa się, że powodem było skomplikowanie obiektu, jakim jest kratownica, jej szczególna konstrukcja (setki cienkich liniowych detali), a także trudność w znalezieniu odpowiednich, kontrastowych znaczników, które można byłoby automatycznie wykryć w skrajnych punktach obiektu. Można byłoby to uczynić wykorzystując jako wzorce zewnętrzne elementy konstrukcji uzyskane ze zdjęcia wirtualnego. Ten aspekt nie był jednak tematem analizy niniejszej pracy.
4. Opracowana metoda zdjęć wirtualnych działa skutecznie, jednak wymagane jest skalibrowanie tak sprzętu jak i oprogramowania. Dobór odpowiednich wartości zmiennych w metodzie jest kluczowe z punktu widzenia otrzymanych wyników. Proces kalibracji należy przeprowadzić dla określonej partii zdjęć, wykonanych tym samym urządzeniem, przy tych samych lub podobnych warunkach oświetlenia. Kalibrację powinien wykonać technik analizujący zebrany materiał. Jego zadaniem byłoby dobranie właściwych wartości kluczowych zmiennych, takich jak np. metoda preprocesingu, wartość korekty analizowanych obrazów itd.
5. Wykonując porównanie zdjęcia wirtualnego, uzyskanego dla obiektu wzorcowego, ze zdjęciem obiektu rzeczywistego istnieje możliwość wykrycia niezgodności.

9. Kierunki dalszych badań

Opracowana metoda i narzędzie programistyczne ma wiele potencjalnych ścieżek zastosowań, lecz w pracy skupiono się na jej zastosowaniu w analizie konstrukcji kratowych linii elektroenergetycznych. W związku z tym, że głównym elementem działania opracowanej metody jest porównanie zdjęć rzeczywistych z wygenerowanymi zdjęciami wirtualnymi, istnieje możliwość zastosowania tej metody dla analizy diagnostycznej innych obiektów. Jedynym warunkiem koniecznym jest posiadanie modelu 3D badanego obiektu.


Metoda ta posiada także wiele możliwości potencjalnego rozwoju. W kolejnych krokach autor chciałby się skupić na rozbudowaniu bazy posiadanych słupów, aby była możliwość sprawdzenia działania MZW na innym zestawie danych oraz dobudowanie modułu adaptacyjnego doboru kratownicy do określonych zdjęć.

W planach autora jest także pochylenie się nad zagadnieniami związanymi z badaniem samej procedury rejestrowania zdjęć. Szczególnie uwzględniając rejestrację automatyczną na podstawie detekcji cech lokalnych różnymi algorytmami oraz opracowanie znaczników, które umożliwiłyby przeprowadzenie takich badań.

a)



b)



Rys. 9.1. Zdjęcie rzeczywiste konstrukcji wsporzej – a) RGB, b) IR

Jednym z planów rozwoju MZW jest opracowanie metody wykorzystującej obrazy wizyjne i termogramy. W takim rozwiązaniu możliwe byłyby np. dokładniejsze usunięcie tła lub elementów niewchodzących w skład konstrukcji. Jak pokazano na rys. 9.1 zdjęcie wykonane w podczerwieni stanowiłoby doskonałą maskę do usunięcia tła. Istnieją oczywiście pewne uwarunkowania wykonywania zdjęć i termogramów o określonej porze, aby konstrukcja posiadała inną temperaturę niż otoczenie. Nie bez znaczenia jest też fakt, że rozdzielczości jakie obecnie oferują kamery termowizyjne (pomimo dużego rozwoju w ostatnich latach) są nadal niewspółmierne małe (co najmniej o rząd wielkości) do rozdzielczości jakie oferują aparaty fotograficzne, a ponadto dystorsje obiektywów kamer termowizyjnych są znacznie większe od aparatów fotograficznych i kamer.

Bibliografia

- [AkCT17] Akinlar C., Topal C.: *ColorED: Color edge and segment detection by Edge Drawing*, Journal of Visual Communication and Image Representation, Volume 44, pp. 82-94, 2017.
- [AIS18] Alison S.: *Difference Between Accuracy And Precision*, Englishtipsdaily.com. 06.2018.
- [BaGT08] Bartodziej G., Tomaszewski M.: *Polityka energetyczna i bezpieczeństwo energetyczne*, Wydawnictwo Federacji Stowarzyszeń Naukowo-Technicznych Energetyka i Środowisko, Warszawa 2008.
- [BaA07] Bał A.: *Odporna na zmianę orientacji obrazu obszarowa metoda segmentacji obrazów*, Pomiary Automatyka Kontrola, nr 5, s. 12-14, 2007.
- [BeB96] Beaglehole R., Bonita R., Kjellstrom T.: *Podstawy epidemiologii*, Łódź: Instytut Medycyny Pracy, ISBN 83-86052-71-6, 1996.
- [BeJ08] Bernasik J.: *Wykłady z fotogrametrii i teledetekcji*, AGH, Kraków 2008.
- [BeJM07] Bernasik J., Mikrut S.: *Fotogrametria inżynierska*, Akademia Górniczo-Hutnicza w Krakowie, Kraków 2007.
- [BeMB16] Berman M., Blaschko M. B.: *Optimization of the Jaccard index for image segmentation with the Lovász hinge*, Computer Vision, <https://www.groundai.com/>, 2016.
- [BeMR18] Berman M., Rannen A., Blaschko M.: *The Lovasz-Softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks*, CVPR, 9.4.2018.
- [BeLF80] Beard L. F. H., Fee J. E.: *An approach to the introduction of stereophotogrammetry as an alternative to traditional methods of measurement*. IAPRS, pp. 62-68, 1980.

- [BlSpi18] Blog Blisko Technologii Spider'sWEB <https://www.spidersweb.pl/2013/01/czy-drozsza-lustrzanka-robilepsze-zdjecia-czyli-troche-o-cenie-i-mozliwosciach.html> , dostęp: 05.2018.
- [DTech07] Biuro studiów i projektów energetycznych – Energoprojekt: *Dokumentacja techniczna szupa H52 ON 100*, 2007.
- [BiW05] Bieniecki W.: *Nowe algorytmy przetwarzania obrazów w wizyjnych systemach komputerowych wspomagających diagnostykę patomorfologiczną*, Rozprawa doktorska, Wydział Elektrotechniki i Elektroniki, Politechnika Łódzka, Łódź 2005.
- [BiSH10] Biswas S., Hazra R.: *Robust edge detection based on Modified Moore-Neighbor*, *Optik*, 2010.
- [BoN10] Borowiec N.: *Reconstructing building model based on integrating lidar data and cadastral maps*. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, vol. 21, s. 43-52, 2010.
- [BrR81] Brooks R. A.: *Symbolic Reasoning among 3D Models and 2D Images*. *Artificial Intelligence*, vol. 17, Brooks and R.A., pp. 285-348, 1981.
- [ChCS05] Chen C., Stamos I.: *Semi-automatic range to range registration: a feature-based method*, *International Conference on 3-D Digital Imaging and Modeling*, pp. 254–261, 2005.
- [ChR04] Chora's R. S.: *Komputerowa wizja. Metody interpretacji i identyfikacji obiektów*. Akademicka Oficyna Wydawnicza EXIT, 2004.
- [CyB07] Cyganek B.: *An Introduction to 3D Computer Vision Techniques and Algorithms*. John Wiley & Sons, 2007.
- [DaMO16] Dąbrowski M., Olesz M., Giędziński K., Przystalski R.: *Robot do diagnostyki stanu technicznego przewodów linii napowietrznych*, *Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej*, nr 50 XLI Konferencja Naukowo-Techniczna Gdańskie Dni Elektryki 2016, Gdańsk 2016.
- [DeS81] Deans S. R.: *Hough transform from the Radon transform*, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 3, no. 2, 185-188, 1981.
- [DiHG17] Di H., Gao D.: *Gray-level transformation and Canny edge detection for 3D seismic discontinuity enhancement*, *Computers & Geosciences Volume 72*, pp. 192-200, 2014.

- [Can18] Dokumentacja techniczna aparatu Canon EOS 30D: https://www.optyczne.pl/16.1-Test_aparatu-Canon_EOS_30D_Canon_EOS_30D.html , dostęp: 09.2018.
- [Dis18] Dokumentacja techniczna dalmierza Disto: <https://dalmierze.pl/dalmierze-laserowe/dalmierz-laserowy-leica-disto-d8-200-m> , dostęp: 09.2018.
- [Fuj18] Dokumentacja techniczna aparatu Fuji X20: <https://www.fotopolis.pl/newsy-sprzetowe/aparaty-fotograficzne/14085-fujifilm-x20> , dostęp: 09.2018.
- [DoM03] Doros M.: *Przetwarzanie obrazów*, Wyd. Wyższej Szkoły Informatyki i Zarządzania, Warszawa, 2003.
- [DuRH72] Duda R. O., Hart P. E.: *Use of the Hough Transformation to Detect Lines and Curves in Pictures*, Comm. ACM, Vol. 15, pp. 11–15, 1972.
- [DzŁG11] Dzierżanowski Ł., Gasz R.: *Implementacja modelu Reliability-Centered Maintenance do komputerowego wspomaganie podejmowania decyzji*, Konferencja KZZ, Polskie Towarzystwo Zarządzania Produkcją, Zakopane 2011, s. 319-326, 2011.
- [Ene] Enea Operator Grupa Enea – Oddział dystrybucji Poznań zakład zarządzania dystrybucją, Instrukcja eksploatacji linii elektroenergetycznej 110 kV Wałcz-Wałcz Północ.
- [FoJD01] Foley J., Dam A.: *Wprowadzenie do grafiki komputerowej*, Wydawnictwo Naukowo-Techniczne, Warszawa 2001.
- [FrDN10] Frejlichowski D., Nuszkiewicz P.: *Przegląd podstawowych metod reprezentacji kształtów 3D*, Studia I materiały Informatyki Stosowanej, Tom 2, nr 2, Warszawa 2010.
- [GaRR18] Gasz R., Ruszczak B., Tomaszewski M., Zator S.: *The Registration of Digital Images for the Truss Towers Diagnostics*, Information Systems Architecture and Technology: Proceedings of 39th International Conference on Information Systems Architecture and Technology – ISAT 2018, Part I, Edit: Borzemski L., Świątek J., Wilimowska Z., pp. 166-177, 2018.
- [GaRM17] Gasz R., Michalski P., Ruszczak B.: *Możliwości wykorzystania narzędzi computer vision w przedsiębiorstwach*, Technologie informatyczne we współczesnej rzeczywistości gospodarczej pod redakcją Janusza

Wielkiego, Studia i Monografie z. 475, Politechnika Opolska, ISBN 978-83-65235-96-1, s. 45-68, 2017.

- [GaR17] Gasz R.: *Detecting Human Action using the Microsoft Kinect ONE Sensor*, WOFEX 2017, Eds: M. Krátký, J. Dvorský, P. Moravec, VŠB – Technical University of Ostrava, ISBN 978-80-248-4056-7, s. 189-194, 2017.
- [GaR16] Gasz R.: *Detection of Human Silhouette in Depth Maps using HOG Algorithm*, WOFEX 2016, Eds: M. Krátký, J. Dvorský, P. Moravec, VŠB – Technical University of Ostrava, ISBN 978-80-248-3961-5, s. 533-539, 2016.
- [GaRZ14] Gasz R., Zator S.: *Pomiary geometryczne wybranych detali wyrobów odlewniczych z zastosowaniem analizy obrazów*, Pomiary Automatyka Kontrola, nr 04, s. 253-256, 2014.
- [GaR13] Gasz R.: *Identyfikacja elementów linii elektroenergetycznej na podstawie zdjęć*, Prace Doktorantów, Politechnika Opolska, s.23-27, ISBN 978-83-64461-00-2, 2013.
- [GaR132] Gasz R.: *An analysis of an object's parameters by means of image processing*, WOFEX 2013, Eds: M. Krátký, J. Dvorský, P. Moravec, VŠB – Technical University of Ostrava, FEECS, pp. 112–117, ISBN 978-80-248-3073-5, 2013.
- [GaRZ13] Gasz R., Zator S.: *Identyfikacja i pomiar wybranych parametrów wyrobów odlewniczych z wykorzystaniem przetwarzania obrazów*, Prace Komisji Metrologii Oddziału PAN w Katowicach, Seria: Konferencje nr 17, Wyd: Komisja Metrologii Oddziału PAN w Katowicach, ISBN 978-83-930505-6-7, 2013.
- [GaRZ132] Gasz R., Zator S.: *Measurements of casting components using image processing methods*, Electrodynamics and Mechatronic Systems editors: Bronisław Tomczuk, Andrzej Waindok, Jan Zimon, Dawid Wajnert, s. 49-50, ISBN 978-1-4673-5590-2, IEEE Catalog Number: CFP13SLM-ART, 2013.
- [GaRZ133] Gasz R., Zator S.: *Evaluation of selected elements of the power line using CAD environment*, Electrodynamics and Mechatronic Systems editors: Bronisław Tomczuk, Andrzej Waindok, Jan Zimon, Dawid Wajnert, s. 47-48, ISBN 978-1-4673-5590-2, IEEE Catalog Number: CFP13SLM-ART, 2013.
- [GaR133] Gasz R.: *Identification of objects based on metric images as an effective diagnostic tool used in energetics*, Computer applications in electrical

engineering, Poznan University of Technology Academic Journals, issue 74, s.87-94, ISSN 1897-0737, 2013.

- [GaRZ12] Gasz R., Zator S.: *Wykorzystanie zdjęć wirtualnych do diagnostyki elementów linii elektroenergetycznych*, Nowa Energia, Nr 2(26) /2012, s.133-134, 2012.
- [GaR12] Gasz, R.: *Wykorzystywanie technik przetwarzania obrazu do badania uszkodzeń urządzeń linii elektroenergetycznych*, Inżynieria Wytwarzania pod redakcją Mariana Dudziaka i Andrzeja Kołodzieja, Państwowa Wyższa Szkoła Zawodowa w Kaliszu, s.61-68, ISBN 978-83-60137-51-2, 2012.
- [GaR122] Gasz R.: *Image-based 3d modeling of photogrammetric objects*, Zeszyty naukowe Politechniki Opolskiej, Elektryka z.68 nr 347/2012, s. 17-18, ISSN 1429-1533, 2012.
- [GaR123] Gasz R.: *Wizualizacja danych pomiarowych na obiektach 3D jako sposób szybkiej i efektywnej oceny stanu urządzeń*, Pomiar Automatyka Robotyka nr 3, s. 115-118, 2012.
- [GaR124] Gasz R.: *Poprawa zdjęć fotograficznych w celu odwzorowania na ich podstawie chmury punktów*, Prace doktorantów, s. 29-32, ISBN 978-83-63015-10-7, 2012.
- [GaR11] Gasz R.: *Intelligent diagnostics of devices with the use of infrared mapping images*, Electrodynamic and mechatronic systems, editors: Bronisław Tomczuk, Andrzej Waindok, Jan Zimon, Opole 2011, s. 109-113, ISBN 978-1-4244-9692-1, IEEE Catalog Number: CFP1174M-PRT, 2011.
- [GoA88] Goshtasby A.: *Image registration by local approximation methods*, Image and Vision Computing, vol. 6, pp. 255-261, 1988.
- [GoA05] Goshtasby A.: *2-D and 3-D Image Registration for Medical, Remote Sensing, and Industrial Applications*, Wiley Press, 2005.
- [GoBS12] Gorte B., Sithole G.: *Lokup Table Hough Transform for Real Time Rande Image Segmentation and Feature Co-Registration*, Journal of Sensor Technology, Vol 2, pp. 148- 154, 2012.
- [GoRW02] Gonzalez R. C., Woods R.E.: *Digital Image Processing 2nd Edition*, Prentice Hall, New Jersey 2002.
- [GrW90] Grimson W. E. L.: *Object Recognition by Computer: The Role of Geometric Constraints*. MIT Press, Cambridge, MA, 1990.

- [HeBB08] Hejmanowska B., Borowiec N., Badurska M.: *Przetwarzanie lotniczych danych lidarowych dla potrzeb generowania NMT i NMPT*, *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, Vol. 18, s. 151-162, 2008.
- [JaRK95] Jain R., Kasturi R., Schunck B. G.: *Machine Vision*. McGraw-Hill, Inc., New York, 1995.
- [KaFD10] Karsli F., Dihkan M.: *Determination of geometric deformations in image registration using geometric and radiometric measurements*, *Scientific Research and Essays* Vol. 5(3), pp. 260-274, 4 February, 2010.
- [KaK08] Karbowski K.: *Podstawy rekonstrukcji elementów maszyn i innych obiektów w procesach wytwarzania*, Oficyna Wydawnicza Politechniki Krakowskiej, Kraków 2008.
- [KaPK10] Kupidura P., Koza P., Marciniak J.: *Morfologia matematyczna w teledetekcji*, Wydawnictwo Naukowe PWN, Warszawa 2010.
- [KeW09] Kępa W.: *Przyczyny i skutki katastrofy energetycznej w województwie zachodniopomorskim w kwietniu 2008 r. Wnioski na przyszłość*, Lubuskie Towarzystwo na Rzecz Rozwoju Energetyki. Gorzów Wielkopolski, 2009.
- [KiK73] Kinsner K.: *Napowietrzne i kablowe linie elektroenergetyczne*, Państwowe Wydawnictwo Naukowe, Warszawa 1973.
- [KuD16] Kudła D.: *Budowa i wydruk modelu geometrycznego słupa linii elektroenergetycznej w programie Autodesk Inventor*, Praca magisterska, Wydział Elektrotechniki, Automatyki i Informatyki, Politechnika Opolska, Opole 2016.
- [KuI10] Kuczkowska I.: *Wybrane zagadnienia eksploatacji i projektowania linii najwyższych napięć*, *Problemy rozległych awarii sieci elektroenergetycznych* pod red. G. Bartodzieje i M. Tomaszewskiego, Wydawnictwo Nowa Energia, Racibórz 2010.
- [KuZM04] Kujarczyk Z., Mińczuk A.: *Elektroenergetyczne sieci rozdzielcze*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2004.
- [KoJK02] Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W.: *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.

- [KoM10] Kowalczyk M.: *Analiza warunków odtworzenia wzajemnej orientacji obrazów z sekwencji filmowej*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 21, s. 179–189, 2010.
- [KoZ80] Konarzewski Z.: *Napowietrzne linie elektroenergetyczne: konstrukcje i budowa*, Skrypty Wydawnictwa Politechniki Warszawskiej, Warszawa 1980.
- [KoZM14] Kowalczuk Z., Marta T.: *Wizualizacja obrazu stereowizyjnego w systemie VISROBOT*, Pomiary Automatyka Kontrola, nr 10, s. 803-808, 2014.
- [LaLC17] Laaksonen L., Claridge E., Fält P.: *Comparison of image registration methods for composing spectral retinal images*, Biomedical Signal Processing and Control, Volume 36, pp. 234-245, 2017.
- [LiJL10] Li J., Li E., Chen Y., Xu L., Zhang Y.: *Bundled Depth-Map Merging for Multi-View Stereo*. Computer Vision and Pattern Recognition, pp. 2769-2776, 2010.
- [MaKN93] Mańczak K., Nahorski Z.: *Komputerowa identyfikacja obiektów dynamicznych*, Państwowe Wydawnictwo Naukowe, Warszawa 1983.
- [MaPO08] Mazurek P., Okarma K.: *Application of background estimation and removal techniques for the extraction of the power line components on the digital images for the automatic power line inspection systems*, Pomiary Automatyka Kontrola, nr 10, s. 698-699, 2008.
- [MaZS12] Mendera Z., Szojda L., Wandzik G.: *Stalowe konstrukcje wsporcze napowietrznych linii elektro-energetycznych wysokiego napięcia, Projektowanie według norm europejskich*, Warszawa 2012.
- [MiS13] Mikulski S.: *Metody triangulacji laserowej w skanerach trójwymiarowych*, Poznań University of Technology Academic Journals no 75, Poznań 2013.
- [MoSP03] Montambault S., Pouliot N.: *The HQ LineROVer: Contributing to Innovation in Transmission Line Maintenance*, Proceedings of the IEEE 10th International Conference on Transmission and Distribution Construction, Operation and Live-Line Maintenance, p. 33-40, 2003.
- [NeI88] Newton I.: *A photogrammetric method for measuring the change in body volume associated with anaesthesia*, IAPRS, Kyoto, pp. 436-442, 1988.

- [OkKM08] Okarma K., Mazurek P.: *Video-based technique for damaged spacers detections during power line inspections*, *Pomiary Automatyka Kontrola*, nr 10, s. 677-678, 2008.
- [PaTP09] Paczkowska T., Paczkowski W.: *Aspekty budowlane katastrofy energetycznej w rejonie szczecińskim*, XXIV Konferencja Naukowo-Techniczna, Szczecin-Międzyzdroje, 2009.
- [PoP04] Podalski P.: *Wyznaczanie parametrów dystorsji kamery na podstawie zdjęć obiektów naturalnych i korekcja zdjęć*, *Polskie Towarzystwo Fotogrametrii i Teledetekcji*, 2004.
- [Prwy18] Projekt wygasz: <http://www.wygasz.edu.pl/index.php/main-page.html> ,
dostęp: 05.2018.
- [PrW01] Pratt W. K.: *Digital image processing*, John Willey & Sons, Inc, pp. 443-509, 2001.
- [RaER10] Rafajłowicz E., Rafajłowicz W.: *Wstęp do przetwarzania obrazów przemysłowych*, Wrocław, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2010.
- [RoB90] Roy B.: *Wielokryterialne wspomaganie decyzji*, Wydawnictwo Naukowo-Techniczne, Warszawa 1990.
- [RoYT16] Rogério Y., Takimoto A., Marcos G., *3D reconstruction and multiple point cloud registration using a low precision RGB-D sensor*, *Mechatronics* 35, pp. 11–22, 2016.
- [RzD13] Rzeszotarski D: *Procedury rekonstrukcji scen trójwymiarowych ze stereoskopii*, *Pomiary Automatyka Kontrola*, nr 9, s. 977-680, 2013.
- [SkK73] Skinner K.: *Napowietrzne i kablowe linie elektroenergetyczne*, Państwowe Wydawnictwo Naukowe, Warszawa 1973.
- [SiZ84] Sitek Z.: *Elementy fotogrametrii i fotografii technicznej*, Państwowe Wydawnictwo Naukowe, Warszawa 1984.
- [SuQH16] Sun Q., Hou Y., Tanc Q.: *A subpixel edge detection method based on an arctangent edge model*, *Optik - International Journal for Light and Electron Optics*, Volume 127, Issue 14, pp. 5702-5710, 2016.
- [SoA77] Sojecki A.: *Optyka*, WSiP, Warszawa, 1977.
- [SwA77] Świątkiewicz A.: *Fotogrametria*, Państwowe Wydawnictwo Naukowe, Warszawa 1977.

- [SzJ10] Szymonik J.: *Widzenie maszynowe, jako narzędzie zapewniające wysoką jakość wyrobów*, Problemy Techniki Uzbrojenia, Wyd. Wojskowa Akademia Techniczna, s. 67-76, Warszawa 2010.
- [TaR97] Tadeusiewicz R.: *Komputerowa analiza i przetwarzanie obrazów*, Wydawnictwo Fundacji Postępu Telekomunikacji, Kraków 1997.
- [TaRF91] Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*. Państwowe Wydawnictwo Naukowe, Warszawa 1991.
- [TaSC18] Tanga S., Congb W., Yang J.: *Local Statistical Deformation Models for Deformable Image Registration*, Neurocomputing, 2018.
- [ToR05] Tokarczyk R.: *Fotogrametria cyfrowa w zastosowaniach medycznych do pomiaru ciała ludzkiego – przegląd i tendencje rozwojowe systemów pomiarowych*, Geodezja, Kartografija i Aerofotogrametria. Mizbidomczij Naukowo-Technicznij Zbornik., Wipusk 66, pp. 233–241, 2005.
- [ToR07] Tokarczyk R.: *Automatyzacja pomiaru na obrazach cyfrowych w systemie fotometrycznym do badania wad postawy*, Wydawnictwo Akademii Górniczo-Hutniczej, Kraków 2007.
- [UhTK10] Uhl T., Kohut P., Holak K.: *Zastosowanie metod wizyjnych do monitorowania stanu konstrukcji*, Pomiary Automatyka Kontrola, nr 6, s. 569-572, 2010.
- [Vdi08] VDI/VDE 2634 Optical 3D-measuring systems Multiple view systems based on area scanning December 2008.
- [VeBY03] Vemuri B.C., Ye J., Chen Y., Leonard C.M.: *Image registration via level-set motion: applications to atlas-based segmentation*, Medical Image Analysis, 7(1), pp. 1-20, 2003.
- [WaLZ18] Wanga L., Zoua L.: *Edge detection based on subpixel-speckle-shifting ghost imaging*, Optics Communications, Volume 407, pp. 181-185, 2018.
- [WaZ08] Wawerek Z.: *Machine vision, widzenie maszynowe albo ...*, Pomiary Automatyka Robotyka 4/2008, s. 6-7, 2008.
- [WoJ96] Woźnicki J.: *Podstawowe techniki przetwarzania obrazów*, Wydawnictwo Komunikacji i Łączności, Warszawa 1996.
- [WrJ69] Wrotkowski J.: *Gospodarka remontowa - Pojęcia i zasady ogólne*, Wydawnictwo Naukowo-Techniczne, Warszawa 1969.

- [YoB10] Yoav B.: *Simultaneous and selective inference: Current successes and future challenges*, Biometrical Journal, 52 (6), s. 708–721, DOI:10.1002/bimj.200900299, 2010.
- [ZaD12] Zawierska D.: *Automatyczna orientacja obrazów cyfrowych na przykładzie wybranej geometrii sieci zdjęć*, Archiwum Fotogrametrii, Kartografii i Teledetekcji, Vol. 23, s. 509–519, 2012.
- [ZaSM12] Zator S., Michalski P.: *Możliwości wykorzystania skanera laserowego do pomiarów precyzyjnych*, Pomiary Automatyka Kontrola, nr 11/2012, s. 1013-1015, 2012.
- [ZaSG16] Zator, S., Gasz R.: *Ocena stanu konstrukcji wsporczych na podstawie zdjęć*, Pomiary Automatyka Robotyka 4, ISSN 1427-9126, s 23-26, DOI: 10.14313/PAR_222/23, 2016.
- [ZaSG162] Zator, S., Gasz R.: *Wykorzystanie systemu wizyjnego do wstępnej półautomatycznej diagnostyki na potrzeby energetyki*, Diagnostyka procesów inwestycyjnych i eksploatacyjnych wybranych urządzeń energetycznych pod red. Z. Kabzy i S. Zatora, Politechnika Opolska, s. 41-54, ISBN 978-83-65235-39-8, 2016.
- [ZaSG15] Zator S., Gasz R.: *Wykorzystanie metod wizyjnych do analizy odkształceń kompensatora pyłoprzewodów*, Computer applications in electrical engineering 2015, Poznan University of Technology Academic Journals – Electrical Engineering, issue 84, s.201-206, ISSN 1897-0737, 2015.
- [ZaSG152] Zator S., Gasz R.: *Analiza geometrii przęsła linii WN na podstawie zdjęć wysokiej rozdzielczości*, Prace Komisji Metrologii Oddziału PAN w Katowicach, ISBN 978-83-930505-9-8, s. 127-130, 2015.
- [ZaSG14] Zator S., Gasz R.: *Analiza geometryczna przęsła linii elektroenergetycznej na podstawie zdjęć wysokiej rozdzielczości*, Diagnostyka inwestycyjno-eksploatacyjna wybranych urządzeń i sieci energetycznych pod red. Z. Kabzy i S. Zatora, Politechnika Opolska, s. 85-95, ISBN 987-83-64056-56-7, 2014.
- [ZaSG142] Zator S., Gasz R.: *Możliwość wykorzystania metod fotogrametrycznych do analizy przemieszczeń infrastruktury technicznej kotła energetycznego*, Diagnostyka inwestycyjno-eksploatacyjna wybranych urządzeń i sieci energetycznych pod red. Z. Kabzy i S. Zatora, Politechnika Opolska, s. 59-70, ISBN 987-83-64056-56-7, 2014.
- [ZaSG12] Zator S., Gasz R.: *Identyfikacja elementów linii elektroenergetycznych z wykorzystaniem zdjęć wirtualnych*, Wybrane zagadnienia gospodarki

remontowej energetyki pod red. S. Zatora i M. Tomaszewskiego, Nowa Energia, s. 94-112, ISBN 978-83-928582-8-7, 2012.

- [ZaSG122] Zator S., Gasz R.: *Zastosowanie metod fotogrametrycznych na potrzeby monitoringu linii elektroenergetycznej*, Wybrane zagadnienia gospodarki remontowej energetyki pod red. S. Zatora i M. Tomaszewskiego, Nowa Energia, s. 49-66, ISBN 978-83-928582-8-7, 2012.
- [ZaKZ10] Zatwarnicki K., Zatwarnicka A., Gasz R., Grzesik Ł.: *Slow start algorithm influence on effective throughput in the internet*, Information Systems Architecture and Technology. Networks and Networks' Services, s. 161-171, ISBN 978-83-7493-543-2, 2010.
- [ZiBF03] Zitová B., Flusser J.: *Image registration methods: a survey*, Image Vision Comput, 21(11), pp. 977-1000, 2003.
- [ZhLR10] Zheng Li, Ruan Yi.: *Autonomous Inspection Robot for Power Transmission Lines Maintenance While Operating on the Overhead Ground Wires*, International Journal of Advanced Robotic Systems, Vol. 7, No. 4, p. 111-116, 2010.

Wykorzystanie metod wizyjnych do identyfikacji obiektów przestrzennych

Streszczenie

Praca dotyczy możliwości wykorzystania technik cyfrowego przetwarzania obrazów do wstępnej półautomatycznej diagnostyki obiektów przestrzennych na przykładzie kratownic linii elektroenergetycznej. W pracy wykonano analizę literatury dotyczącej diagnostyki, która obejmowała problematykę związaną z identyfikacją obiektów oraz metod detekcji określonych cech badanego obiektu na obrazach cyfrowych. Opisano zasady przeprowadzania diagnostyki linii elektroenergetycznej, omówiono ich zalety i wady. Przedstawiono metody najczęściej opisywane w literaturze oraz ich modyfikacje i implementacje wykorzystane na potrzeby opracowanej autorskiej metody.

Przedstawiono opracowaną przez autora metodę zdjęć wirtualnych jako narzędzia wspomagającego pracę techników w procesie analizy materiału fotograficznego, zebranego podczas corocznych oblotów linii. Omówione zostały poszczególne etapy opracowanej metody oraz ich implementacja programowa. Głównym zadaniem metody zdjęć wirtualnych jest ograniczenie ilości analizowanych zdjęć przez wykwalifikowany personel, do tych zdjęć, które wykazują potencjalną możliwość wystąpienia na sfotografowanym obiekcie niezgodności z wzorcem – braku elementu lub jego odkształcenia. Metoda ta wykorzystuje mechanizmy zaczerpnięte z analizy przesiewowej.

Dla uzyskania prawidłowo działającej metody opisano przyjęte reguły oceny zdjęć, dokonano szeregu analiz dotyczących prawidłowego wyznaczenia nieprawidłowości w budowie konstrukcji. Podczas testów użyto zdjęć wydrukowanego na drukarce 3D modelu słupa, zdjęcia te wykonano w ściśle określonych warunkach laboratoryjnych oraz zdjęć obiektu rzeczywistego. Wypracowane reguły oceny stanu obiektów opracowane na podstawie analizy uzyskanej w warunkach laboratoryjnego sprawdziły się także dla materiału zdjęciowego wykonanego w terenie.

W pracy przedstawiono także analizę wyników działania opracowanej metody dla różnego rodzaju zdjęć, przy zmianie wartości określonych zmiennych, które miały wpływ na uzyskiwane wyniki. W końcowej części pracy przedstawiono proponowane wartości zmiennych, jakie należy użyć w procesie kalibracji metody dla różnych zestawów zdjęć.

Końcowy etap pracy stanowi podsumowanie, zawiera konkluzje i wnioski autora na temat możliwości oraz ograniczeń związanych z użyciem opracowanej metody. Przedstawiono również kierunki dalszych badań w zakresie rozwoju funkcjonalnego opracowanej metody oraz jej potencjalnie nowe zastosowania.

Application of vision methods for the identification of spatial objects

Abstract

The study discusses the possibility of utilizing digital image processing techniques for the purpose of initial, semi-automated spatial object diagnostics on the example of electrical power line latticework. The study involved an analysis of literature related to diagnostics, which encompassed the subject matter associated with the identification of objects and detection methods of specific properties of the studied object on digital images. It describes the principles of conducting electrical power line diagnostics and discusses their strengths and weaknesses. The study presents methods most frequently described in literature and their modifications and implementations utilized for the purpose of the author's developed proprietary method.

Further, it presents the author's developed method of virtual photographs as a tool to support the work of technicians in the process of analyzing the photographic material collected during annual areal inspections of the lines. Additionally, the study discusses individual stages of the developed method and their software implementations. The primary objective of the virtual photograph method is to limit the number of analyzed photographs by qualified personnel to only those photographs which indicate the potential risk of inconsistencies with the model - lack of an element or deformation. This method incorporates mechanisms drawn from screening analysis.

In order to achieve a correctly working method, the study describes the adopted principles of photograph evaluation, incorporates a series of analyses regarding the correct determination of irregularities in the latticework structure. During tests photographs of a column printed in a 3D printer were used - these photographs have been taken in strictly specified laboratory conditions, in addition to photographs of the actual object. The resulting principles of evaluating the object's condition, developed based on an analysis conducted in laboratory conditions, also apply to the photographic material taken in the field.

The study also presents an analysis of the developed method's results for different types of photographs, when modifying the values of specific variables which affected the achieved results. The final section of the study presents proposed values of variables which should be used in the method calibration process for different photograph sets.

The conclusion of the study consists of a summary, containing the author's conclusions regarding the possibilities and limitations associated with utilizing the developed method. It also presents the directions of further research in terms of functional development of the method and potential new applications.

Spis rysunków

- Rys. 3.1. Schemat działania aparatu, a) podczas kadrowania, b) w momencie wykonania zdjęcia
1. Obiektyw, 2. Ruchome lustro, 3. Matówka, 4. Pryzmat pentagonalny, 5. Wizjer, 6. Kurtyna migawki, 7. Matryca [BISpi]
- Rys. 3.2. Obraz: a) z widoczną dystorsją poduszkowatą, b) z widoczną dystorsją beczkowatą, c) prawidłowy
- Rys. 3.3. Aberracja sferyczna [Prwy]
- Rys. 3.4. Aberracja chromatyczna [Prwy]
- Rys. 3.5. Elementy orientacji zewnętrznej, kąty nachylenia ω , zwrotu φ i skręcenia κ
- Rys. 3.6. Graficzna prezentacja zagadnienia kolinearności wektorów
- Rys. 3.7. Przykładowy skan konstrukcji wsporczej, zawierający ok 107 mln punktów
- Rys. 3.8. Zasada działania systemu z zastosowaniem wiązki laserowej [ToR07]
- Rys. 3.9. Zasada działania systemu z wykorzystaniem wzorca świetlnego [ToR07]
- Rys. 3.10. Zasada działania systemu z wykorzystaniem wzorca świetlnego oraz dwóch kamer [ToR07]
- Rys. 4.1. Algorytm metody zdjęć wirtualnych
- Rys. 4.2. Słup odporowo-naróżny H52 – rysunek techniczny [DTech07]
- Rys. 4.3. Wykonany model konstrukcji w środowisku CAD
- Rys. 4.4. Przykładowe zdjęcia badanego obiektu laboratoryjnego
- Rys. 4.5. Wyznaczanie elementów orientacji wewnętrznej kamery naziemnej z użyciem planszy kalibracyjnej [BeJ08]
- Rys. 4.6. Błąd odwzorowania punktu (Δr) spowodowany dystorsją radialną obiektywu: a) w płaszczyźnie osi kamery, b) w płaszczyźnie obrazu [BeJ08]
- Rys. 4.7. Rozkład wektora dystorsji na składowe: radialną (Δr) i tangencjalną (Δt) [BeJ08]
- Rys. 4.8. Przykładowe zdjęcia po usunięciu dystorsji
- Rys. 4.9. Nałożenie zdjęć przed i po procesie usunięcia dystorsji
- Rys. 4.10. Geometria epipolarna – idea działania [MaGA04]
- Rys. 4.11. Model punktowej kamery perspektywicznej [MaGA04]
- Rys. 4.12. Podstawowe elementy dla punktowej kamery perspektywicznej [MaGA04]
- Rys. 4.13. Badany obiekt – wydrukowany model słupa
- Rys. 4.14. Określone odległości kamery od obiektu, celem zachowania powtarzalności wykonywanych zdjęć (czarne znaczniki oznaczają umiejscowienie nóg statywu)
- Rys. 4.15. Schemat analizowanej sceny
- Rys. 4.16. Wykonane zdjęcia z pozycji frontalnej oraz z boku
- Rys. 4.17. Zdjęcia obiektu laboratoryjnego po usunięciu dystorsji
- Rys. 4.18. Wyznaczenie 150 punktów charakterystycznych
- Rys. 4.19. Skorelowanie ze sobą charakterystycznych punktów z obydwu zdjęć
- Rys. 4.20. Wyznaczenie linii epipolarnych
- Rys. 4.21. Wygenerowanie sceny z wynikiem określającym umiejscowienie kamer
- Rys. 4.22. Podgląd zdjęcia wirtualnego po ustaleniu wszystkich parametrów kamery
- Rys. 4.23. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne (b) – widok frontalny
- Rys. 4.24. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne (b) – widok pod kątek 30°
- Rys. 4.25. Zdjęcie rzeczywiste (a) i wygenerowane zdjęcie wirtualne w programie Matlab (b) – widok frontalny
- Rys. 4.26. Zdjęcia przygotowane do nałożenia – a) zdjęcie rzeczywiste z usuniętą dystorsją, b) zdjęcie wirtualne
- Rys. 4.27. Wynik projekcji zdjęć rzeczywistego i wirtualnego
- Rys. 4.28. Zdjęcia przygotowane do procesu rejestracji automatycznej
- Rys. 4.29. Wynik rejestracji automatycznej
- Rys. 4.30. Wyznaczone ręcznie punkty CP
- Rys. 4.31. Wyliczone punkty korelacyjne obrazów
- Rys. 4.32. Wynik rejestracji z ręcznie wskazanymi punktami

Rys. 4.33. Otrzymany wynik: a) przed korektą, b) po korekcie

Rys. 4.34. Fragment kratownicy przygotowany do analizy, a) całość, b) z brakami

Rys. 4.35. Obraz wynikowy metody zdjęć wirtualnych – a) widoczne braki, b) braki nałożone na obraz wejściowy, w celu wizualizacji uszkodzeń

Rys. 5.1. Przykładowe zdjęcia rzeczywiste i wirtualne z zaznaczonymi punktami CP reprezentującymi korespondujące piksele

Rys. 5.2. Obrazy przed rejestracją – różne umiejscowienie punktów CP

Rys. 5.3. Obrazy przed rejestracją – zwiększenie liczby CP

Rys. 5.4. Porównanie wartości przeciętnej parametru Accuracy dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Rys. 5.5. Porównanie wartości przeciętnej parametru Intersection over Union dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Rys. 5.6. Porównanie wartości przeciętnej parametru False discovery rate dla 15 wariantów punktów CP z zastosowaniem różnych metod rejestracji

Rys. 5.7. Analizowane sceny: a) front view, b) side view

Rys. 5.8. Porównanie Accuracy dla widoków obiektów - front view, side view

Rys. 5.9. Porównanie Intersection over Union dla widoków obiektów - front view, side view

Rys. 5.10. Porównanie False discovery rate dla widoków obiektów - front view, side view

Rys. 5.11. Otrzymany wynik: a) przed korektą, b) po korekcie

Rys. 5.12. Porównanie wartości przeciętnej parametru Accuracy dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Rys. 5.13. Porównanie wartości przeciętnej parametru Intersection over Union dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Rys. 5.14. Porównanie wartości przeciętnej parametru False discovery rate dla 15 wariantów CP z zastosowaniem różnych metod rejestracji po dokonaniu korekty

Rys. 5.15. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji Affine

Rys. 5.16. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji o Non-reflective similarity

Rys. 5.17. Porównanie wartości przeciętnej parametru FDR dla 15 wariantów CP przed i po korekcie dla metody rejestracji Projective

Rys. 5.18. Fragmenty obrazów przygotowanych do analizy – zestaw 1 i 2 – a,b – kratownica rzeczywista, c,d – kratownica rzeczywista z brakami, e,f – kratownica wirtualna

Rys. 5.19. Wynik operacji odjęcia obrazów – uzyskano obszary stanowiące braki w konstrukcji

Rys. 5.20. Obraz kratownicy z nałożonymi brakami

Rys. 5.21. Wynik operacji binaryzacji obrazu rzeczywistego

Rys. 5.22. Wynik operacji odjęcie obrazu wirtualnego od obrazu rzeczywistego (w okręgu po lewej stronie po inwersji kolorów)

Rys. 5.23. Obraz po przeprowadzeniu operacji erozji i dylatacji (w okręgu po lewej stronie po inwersji kolorów)

Rys. 5.24. Finalny wynik operacji wyliczania pikseli stanowiących braki w konstrukcji (w okręgu po lewej stronie po inwersji kolorów)

Rys. 6.1. Matryca przedstawiająca stany działania opracowanej metody

Rys. 6.2. Analizowane zestawy zdjęć laboratoryjnych, po lewej zdjęcie rzeczywiste, po prawej wirtualne, odpowiednio: a –zestaw 1, b –zestaw 2, c –zestaw 3, d –zestaw 4, e –zestaw 5, f –zestaw 6, g –zestaw 7, h –zestaw 8

Rys. 6.3. Wyniki rejestracji obrazów dla poszczególnych zestawów

Rys. 6.4. Przykładowe zdjęcie obiektu rzeczywistego z zaznaczonym fragmentem z którego usunięto elementy

Rys. 6.5. Analizowane zestawy zdjęć obiektu rzeczywistego, po lewej zdjęcie rzeczywiste, po prawej wirtualne, odpowiednio: a –zestaw 9, b –zestaw 10, c –zestaw 11, d –zestaw 12, e –zestaw 13, f –zestaw 14, g –zestaw 15, h –zestaw 16

Rys. 6.6. Wyniki rejestracji obrazów rzeczywistego obiektu dla poszczególnych zestawów

Rys. 7.1. Wyniki uzyskanych blobów dla zmiany stanu dystorsji

Rys. 7.2. Wyniki uzyskanych blobów dla zmiany poziomu binaryzacji

Rys. 7.3. Wyniki uzyskanych blobów dla zmiany metody preprocesingu
Rys. 7.4. Wyniki uzyskanych blobów dla zmiany poziomu korekty
Rys. 7.5. Wyniki uzyskanych blobów dla zmiany rozmiaru rozdzielczości
Rys. 7.6. Wyniki uzyskanych blobów dla zmiany zastosowanej metody rejestracji
Rys. 7.7. Uzyskane wyniki Acc dla zmiany stanu dystorsji
Rys. 7.8. Uzyskane wyniki Acc dla zmiany poziomu binaryzacji
Rys. 7.9. Uzyskane wyniki Acc dla zmiany metody preprocesingu
Rys. 7.10. Uzyskane wyniki Acc dla zmiany poziomu korekty
Rys. 7.11. Uzyskane wyniki Acc dla zmiany rozmiaru obrazu
Rys. 7.12. Uzyskane wyniki Acc dla zmiany metody rejestracji
Rys. 7.13. Uzyskane wyniki IoU dla zmiany stanu dystorsji
Rys. 7.14. Uzyskane wyniki IoU dla zmiany poziomu binaryzacji
Rys. 7.15. Uzyskane wyniki IoU dla zmiany metody preprocesingu
Rys. 7.16. Uzyskane wyniki IoU dla zmiany poziomu korekty
Rys. 7.17. Uzyskane wyniki IoU dla zmiany rozmiaru obrazu
Rys. 7.18. Uzyskane wyniki IoU dla zmiany metody rejestracji
Rys. 7.19. Uzyskane wyniki FDR dla zmiany stanu dystorsji
Rys. 7.20. Uzyskane wyniki FDR dla zmiany poziomu binaryzacji
Rys. 7.21. Uzyskane wyniki FDR dla zmiany metody preprocesingu
Rys. 7.22. Uzyskane wyniki FDR dla zmiany poziomu korekty
Rys. 7.23. Uzyskane wyniki FDR dla zmiany rozmiaru obrazu
Rys. 7.24. Uzyskane wyniki FDR dla zmiany metody rejestracji
Rys. 7.25. Uzyskane wyniki parametru Precision dla zmiany stanu dystorsji
Rys. 7.26. Uzyskane wyniki parametru Precision dla zmiany poziomu binaryzacji
Rys. 7.27. Uzyskane wyniki parametru Precision dla zmiany metody preprocesingu
Rys. 7.28. Uzyskane wyniki parametru Precision dla zmiany poziomu korekty
Rys. 7.29. Uzyskane wyniki parametru Precision dla zmiany rozmiaru obrazu
Rys. 7.30. Uzyskane wyniki parametru Precision dla zmiany metody rejestracji
Rys. 7.31. Uzyskane wyniki parametru Recall dla zmiany stanu dystorsji
Rys. 7.32. Uzyskane wyniki parametru Recall dla zmiany poziomu binaryzacji
Rys. 7.33. Uzyskane wyniki parametru Recall dla zmiany metody preprocesingu
Rys. 7.34. Uzyskane wyniki parametru Recall dla zmiany poziomu korekty
Rys. 7.35. Uzyskane wyniki parametru Recall dla zmiany rozmiaru obrazu
Rys. 7.36. Uzyskane wyniki parametru Recall dla zmiany metody rejestracji
Rys. 7.37. Wyniki uzyskanych blobów dla zmiany stanu dystorsji
Rys. 7.38. Wyniki uzyskanych blobów dla zmiany poziomu binaryzacji
Rys. 7.39. Wyniki uzyskanych blobów dla zmiany metody preprocesingu
Rys. 7.40. Wyniki uzyskanych blobów dla zmiany poziomu korekty
Rys. 7.41. Wyniki uzyskanych blobów dla zmiany rozmiaru obrazu
Rys. 7.42. Wyniki uzyskanych blobów dla zmiany metody rejestracji
Rys. 7.43. Uzyskane wyniki parametru Acc dla zmiany stanu dystorsji
Rys. 7.44. Uzyskane wyniki parametru Acc dla zmiany poziomu binaryzacji
Rys. 7.45. Uzyskane wyniki parametru Acc dla zmiany metody preprocesingu
Rys. 7.46. Uzyskane wyniki parametru Acc dla zmiany poziomu korekty
Rys. 7.47. Uzyskane wyniki parametru Acc dla zmiany rozmiaru obrazu
Rys. 7.48. Uzyskane wyniki parametru Acc dla zmiany metody rejestracji
Rys. 7.49. Uzyskane wyniki parametru IoU dla zmiany stanu dystorsji
Rys. 7.50. Uzyskane wyniki parametru IoU dla zmiany poziomu binaryzacji
Rys. 7.51. Uzyskane wyniki parametru IoU dla zmiany metody preprocesingu
Rys. 7.52. Uzyskane wyniki parametru IoU dla zmiany poziomu korekty
Rys. 7.53. Uzyskane wyniki parametru IoU dla zmiany rozmiaru obrazu
Rys. 7.54. Uzyskane wyniki parametru IoU dla zmiany metody rejestracji
Rys. 7.55. Uzyskane wyniki parametru FDR dla zmiany stanu dystorsji
Rys. 7.56. Uzyskane wyniki parametru FDR dla zmiany poziomu binaryzacji
Rys. 7.57. Uzyskane wyniki parametru FDR dla zmiany metod preprocesingu

Rys. 7.58. Uzyskane wyniki parametru FDR dla zmiany poziomu korekty
Rys. 7.59. Uzyskane wyniki parametru FDR dla zmiany rozmiaru obrazu
Rys. 7.60. Uzyskane wyniki parametru FDR dla zmiany metod rejestracji
Rys. 7.61. Uzyskane wyniki parametru Precision dla zmiany stanu dystorsji
Rys. 7.62. Uzyskane wyniki parametru Precision dla zmiany poziomu binaryzacji
Rys. 7.63. Uzyskane wyniki parametru Precision dla zmiany metody preprocesingu
Rys. 7.64. Uzyskane wyniki parametru Precision dla zmiany poziomu korekty
Rys. 7.65. Uzyskane wyniki parametru Precision dla zmiany rozmiaru obrazu
Rys. 7.66. Uzyskane wyniki parametru Precision dla zmiany metody rejestracji
Rys. 7.67. Uzyskane wyniki parametru Recall dla zmiany stanu dystorsji
Rys. 7.68. Uzyskane wyniki parametru Recall dla zmiany poziomu binaryzacji
Rys. 7.69. Uzyskane wyniki parametru Recall dla zmiany metody preprocesingu
Rys. 7.70. Uzyskane wyniki parametru Recall dla zmiany poziomu korekty
Rys. 7.71. Uzyskane wyniki parametru Recall dla zmiany rozmiaru obrazu
Rys. 7.72. Uzyskane wyniki parametru Recall dla zmiany metody rejestracji
Rys. 9.1. Zdjęcie rzeczywiste konstrukcji wsporczej – a) RGB, b) IR

Spis tabel

- Tab. 4.1. Wyniki wyznaczania współrzędnych kamery
- Tab. 5.1. Dane analizowanych zdjęć
- Tab. 5.2. Przeciętne wartości parametru Accuracy dla 15 wariantów CP
- Tab. 5.3. Przeciętne wartości parametru Intersection over Union dla 15 wariantów CP
- Tab. 5.4. Przeciętne wartości parametru False discovery rate dla 15 wariantów CP
- Tab. 5.5. Wartości Accuracy dla widoków obiektów
- Tab. 5.6. Wartości Intersection over Union dla widoków obiektów
- Tab. 5.7. Wartości False discovery rate dla widoków obiektów
- Tab. 5.8. Wpływ zastosowania korekty na jakość rejestracji
- Tab. 5.9. Przeciętne wartości parametru Accuracy dla 15 wariantów CP po korekcie
- Tab. 5.10. Przeciętne wartości parametru Intersection over Union dla 15 wariantów CP po korekcie
- Tab. 5.11. Przeciętne wartości parametru False discovery rate dla 15 wariantów CP po korekcie
- Tab. 5.12. Wyniki powierzchni pikseli stanowiących braki w konstrukcji dla zestawu 1
- Tab. 6.1. Dane techniczne aparatu Canon EOS 30D [Can18]
- Tab. 6.2. Dane techniczne aparatu Fujifilm X20 [Fuj18]
- Tab. 6.3. Dane techniczne dalmierza laserowego Leica DISTO D8 [Dis18]
- Tab. 6.4. Dane analizowanych zdjęć
- Tab. 6.5. Wyniki dla obrazu kompletnego – zestaw 1
- Tab. 6.6. Wyniki dla obrazu z brakami – zestaw 1
- Tab. 6.7. Wyniki dla obrazu kompletnego – zestaw 2
- Tab. 6.8. Wyniki dla obrazu z brakami – zestaw 2
- Tab. 6.9. Wyniki dla obrazu kompletnego – zestaw 3
- Tab. 6.10. Wyniki dla obrazu z brakami – zestaw 3
- Tab. 6.11. Wyniki dla obrazu kompletnego – zestaw 4
- Tab. 6.12. Wyniki dla obrazu z brakami – zestaw 4
- Tab. 6.13. Wyniki dla obrazu kompletnego – zestaw 5
- Tab. 6.14. Wyniki dla obrazu z brakami – zestaw 5
- Tab. 6.15. Wyniki dla obrazu kompletnego – zestaw 6
- Tab. 6.16. Wyniki dla obrazu z brakami – zestaw 6
- Tab. 6.17. Wyniki dla obrazu kompletnego – zestaw 7
- Tab. 6.18. Wyniki dla obrazu z brakami – zestaw 7
- Tab. 6.19. Wyniki dla obrazu kompletnego – zestaw 8
- Tab. 6.20. Wyniki dla obrazu z brakami – zestaw 8
- Tab. 6.21. Przedstawienie mechanizmu wnioskowania metody zdjęć wirtualnych
- Tab. 6.22. Dane analizowanych zdjęć obiektu rzeczywistego
- Tab. 6.23. Wyniki dla obrazu kompletnego – zestaw 9
- Tab. 6.24. Wyniki dla obrazu z brakami – zestaw 9
- Tab. 6.25. Wyniki dla obrazu kompletnego – zestaw 10
- Tab. 6.26. Wyniki dla obrazu z brakami – zestaw 10
- Tab. 6.27. Wyniki dla obrazu kompletnego – zestaw 11
- Tab. 6.28. Wyniki dla obrazu z brakami – zestaw 11
- Tab. 6.29. Wyniki dla obrazu kompletnego – zestaw 12
- Tab. 6.30. Wyniki dla obrazu z brakami – zestaw 12
- Tab. 6.31. Wyniki dla obrazu kompletnego – zestaw 13
- Tab. 6.32. Wyniki dla obrazu z brakami – zestaw 13
- Tab. 6.33. Wyniki dla obrazu kompletnego – zestaw 14
- Tab. 6.34. Wyniki dla obrazu z brakami – zestaw 14
- Tab. 6.35. Wyniki dla obrazu kompletnego – zestaw 15
- Tab. 6.36. Wyniki dla obrazu z brakami – zestaw 15
- Tab. 6.37. Wyniki dla obrazu kompletnego – zestaw 16

Tab. 6.38. Wyniki dla obrazu z brakami – zestaw 16

Tab. 6.39. Przedstawienie mechanizmu wnioskowania metody zdjęć rzeczywistych