

**Politechnika Opolska**  
Wydział Elektrotechniki, Automatyki i Informatyki

mgr inż. Jakub Osuchowski

tytuł pracy:

„Detekcja izolatorów linii elektroenergetycznej z wykorzystaniem metod przetwarzania obrazów cyfrowych”



**POLITECHNIKA**  
OPOLSKA

**AUTOREFERAT PRACY DOKTORSKIEJ**

**PROMOTOR:**

**dr hab. inż. Michał Tomaszewski, prof. uczelni**

**PROMOTOR POMOCNICZY:**

**dr inż. Paweł Michalski**

**Opole 2021 r.**

# 1. Wprowadzenie

Bezpieczeństwo oraz prawidłowe funkcjonowanie napowietrznych linii energetycznych jest czynnikiem niezwykle ważnym dla naszego codziennego życia. Przerwy w dostawie energii elektrycznej mogą nie tylko powodować ogromne straty finansowe, ale także stanowią zagrożenie dla środowiska i bezpieczeństwa publicznego. W dzisiejszych czasach, w związku z rozwojem nowych, zielonych technologii w Europie i na świecie rośnie zapotrzebowanie na większą i bardziej niezawodną zdolność transportu energii elektrycznej [PaHT13]. Aby zapobiec wystąpieniu awarii i wykryć usterki na najwcześniejszym etapie, przedsiębiorstwa energetyczne muszą przeprowadzać rutynowe inspekcje całej infrastruktury energetycznej. Najczęściej stosowanymi środkami diagnostyki linii energetycznych są obecnie piesze patrole oraz inspekcja wspomagana helikopterem [KaPe10, WaZh16]. Tradycyjna forma diagnostyki linii (inspekcja piesza) wymaga od grupy ekspertów sprawdzenia całego korytarza linii energetycznej pieszo lub pojazdem naziemnym. Forma taka jest mniej wydajna i czasochłonna. Na jej wyniki może łatwo wpłynąć osąd eksperta lub słaba wizyjna dostępność kluczowych elementów linii. W związku z tym tradycyjne metody diagnostyki linii napowietrznych wydają się być dalekie od doskonałych [AdXC19, JYSZ08, OIFo09, ShKK07, SPLJ18].

Rozwiązanie powyższych problemów wydaje się być wspomagana helikopterem lub bezałogowym statkiem powietrznym (pojazdem BSP z ang. *unmanned aerial vehicle*) inspekcja linii wysokiego napięcia polega na wykorzystaniu pojazdu BSP lub helikoptera, który wykonuje przelot wzdłuż linii elektroenergetycznej wyposażonego w różne urządzenia do teledetekcji. Mogą to być na przykład kamery działające w zakresie światła widzialnego, kamera obrazująca w podczerwieni służące do wykrywania gorących punktów (z ang. *hot spot*) lub kamera obrazująca w ultrafiolecie wykorzystywana do wykrywania wylądowań niezupełnych [PaHT13, WaZh16]. Ten rodzaj inspekcji jest znacznie bardziej wydajny niż pieszy patrol, ponieważ śmigłowiec lub pojazd BSP może pokonać duży dystans w bardzo krótkim czasie.

Materiał wideo jest następnie ręcznie przeglądany przez zespoły eksperckie, w celu dostarczenia obszernych raportów z inspekcji wraz ze zdjęciami wad. Chociaż znacznie szybsza w porównaniu z inspekcją pieszego patrolu, inspekcja taka jest często mniej dokładna, a co najważniejsze wymaga przejrzania ogromnych ilości danych wygenerowanych podczas przelotu. Wraz ze wzrostem dokładności kamer (tj. np. jej rozdzielczości) znacząco wzrasta także rozmiar materiału wizyjnego.

Zdolność do dokładnego zlokalizowania i segmentowania izolatora na obrazie jest warunkiem wstępnym do dalszej diagnostyki oraz detekcji jego wad i uszkodzeń [WuAn14, ZLSL12]. W ostatnich latach prowadzonych jest coraz więcej badań dotyczących rozpoznawania izolatora na zdjęciach lotniczych. Istnieją jednak dwa główne wyzwania w obecnych badaniach. Różne rodzaje izolatorów wymuszają zróżnicowane podejścia do problemu detekcji, a większość istniejących metod rozpoznawania izolatora jest dostosowana do konkretnych typów izolatorów oraz przypadków użycia i nie może być stosowana w innych sytuacjach. Drugim dużym problemem jest zaśmiecone tło, które bardzo często występuje w przypadku zdjęć powietrznych. Nadmiarowe informacje zawarte w tle mogą łatwo wpłynąć na procedurę rozpoznawania, zwiększając obciążenie obliczeniowe i zmniejszając wskaźnik

udanych detekcji. W niewielu badaniach prowadzone były testy na obrazach izolatorów z bardzo złożonym tłem, a jeszcze mniej dotyczyło prób rozwiązania tego problemu przed samą procedurą detekcji [WaZh16].

W pracy skupiono się na wykorzystaniu do celu detekcji algorytmów detekcji i opisu cech, ze szczególnym uwzględnieniem algorytmu SURF (z ang. *Speeded-Up Robust Features*) oraz konwolucyjnych sieci neuronowych (z ang. *Convolutional Neural Network*, CNN). Ponadto podjęto próbę budowy worka cech kluczowych (dystynktywnych) na podstawie parametrów LPR (z ang. *local point repeatability*) oraz Ratio, które nie były wcześniej stosowane do tego celu.

Niezależnie od tego jaka metoda została wykorzystana do akwizycji danych oraz jakiego typu informacje otrzymano w jej rezultacie, ważnym pytaniem jest: w jaki sposób przeprowadzić detekcję izolatorów, aby była ona precyzyjna, szybka, a także nie generowała zbyt wiele dodatkowej pracy dla zespołu eksperckiego.

W niniejszej rozprawie autor przedstawia propozycje metod oraz narzędzi umożliwiających rozwiązanie wyżej wspomnianych problemów badawczych. Korzystając z wiedzy z zakresu przetwarzania i rozpoznawania obrazów, wizji komputerowej, a także uczenia głębokiego autor opracował metody oraz narzędzia umożliwiające automatyczną detekcję izolatorów na obrazach cyfrowych. Autor ma nadzieję, że przedstawione w pracy wyniki będą miały wkład w rozwój metod detekcji obiektów na obrazach cyfrowych, a także pozwolą w przyszłości na ich wykorzystanie do w pełni automatycznej diagnostyki izolatorów linii elektroenergetycznej.

## 2. Cel pracy

Celem pracy jest opracowanie metody umożliwiającej automatyczne wykrywanie izolatorów linii wysokiego napięcia na obrazach cyfrowych z wykorzystaniem zaawansowanych metod przetwarzania obrazów cyfrowych, a w szczególności metod detekcji obiektów.

### 2.1. Teza pracy

Praca zmierza do wykazania prawdziwości następującej tezy:

*Możliwa jest skuteczna detekcja izolatorów linii elektroenergetycznej w złożonej scenie na obrazach cyfrowych rejestrowanych przy użyciu BSP z wykorzystaniem systemów przetwarzania obrazów cyfrowych także przy zastosowaniu ograniczonego zbioru danych uczących.*

## 3. Zbiory danych użyte podczas detekcji izolatorów linii wysokiego napięcia

Problem pozyskania i określenia odpowiedniej wielkości zbioru treningowego jest często poruszany przez badaczy. Aktualny rozwój technik uczenia głębokiego był możliwy właśnie dzięki dużym zbiorom danych oraz możliwościami ich szybkiego przetworzenia. W przypadku wykorzystania algorytmów, których prognozy różnią się znacząco w zależności od konkretnych danych używanych do ich szkolenia, kluczowa jest wielkość próbki danych treningowych. Na wielkość próbki mają wpływ dwa główne czynniki: złożoność problemu – funkcja, która najlepiej wiąże zmienne wejściowe ze zmienną wyjściową oraz złożoność algorytmu uczącego użytego do indukcyjnego uczenia się nieznanej podstawowej funkcji mapowania na podstawie konkretnych przykładów. Dane wizyjne uzyskane w procesie akwizycji (przelet lub obchód wzdłuż linii wysokiego napięcia) są w dużej mierze homogeniczne, dlatego na etapie postprocessingu mogą zostać zwykle bez większych komplikacji posegmentowane na dane treningowe, testowe, walidacyjne. Po zlokalizowaniu istotnych elementów w próbkach treningowych można na ich podstawie wyuczyć klasyfikator modyfikując jego parametry w oparciu o wynik uzyskany dla danych testowych.

### **3.1. Zbiór danych do celów detekcji izolatorów linii wysokiego napięcia z wykorzystaniem algorytmu detekcji i opisu cech SURF oraz metod filtracji przestrzennej**

Zbiór danych opracowany do celów detekcji izolatorów z wykorzystaniem algorytmu detekcji i opisu cech SURF oraz algorytmów filtracji przestrzennej składał się z obrazów pozyskanych z wykorzystaniem różnych narzędzi oraz metod akwizycji. Były to sceny uzyskane w wyniku przeletu pojazdem BSP, helikopterem oraz z pieszego obchodu linii. Ponadto użyto aparatu fotograficznego Canon 5D Mark II oraz kamery GoPro Hero 4. W zbiorze danych znalazły się sceny zawierające rzeczywiste działające izolatory (Rys. 3.1).



Rys. 3.1. Wybrane obrazy cyfrowe przedstawiające izolatory na istniejących liniach elektroenergetycznych.

Dla potrzeb analizy detekcji izolatorów z wykorzystaniem algorytmu SURF dodatkowo zarejestrowane zostały także obrazy cyfrowe porcelanowego izolator długopniowego w warunkach laboratoryjnych.

Do celów ułatwienia akwizycji obrazów cyfrowych zawierających izolatory w warunkach rzeczywistych jak i laboratoryjnych w Katedrze Elektrowni, Diagnostyki i Inżynierii Komputerowej Politechniki Opolskiej skonstruowana zostało stanowisko badawcze umożliwiające łatwe podwieszanie izolatorów energetycznych w różnych warunkach (Rys. 3.3.). Skonstruowanie stanowiska badawczego w znacznym stopniu ułatwiało akwizycję obrazów izolatorów niezbędnych do skonstruowania zbiorów danych uczących oraz testowych.

Poprzez jego zastosowanie możliwa była akwizycja danych w zmieniających się warunkach oświetleniowych, pod różnymi kątami oraz na tle różnego rodzaju obiektów przemysłowych oraz naturalnych.

### **3.2. Zbiór danych do celów detekcji izolatorów na podstawie analizy częstości występowania cech dystynktywnych**

Na potrzeby ewaluacji metody detekcji izolatorów na podstawie analizy częstości występowania cech dystynktywnych wykonane zostały sekwencje filmowe wykorzystując pojazd BSP z zamontowaną kamerą wysokiej rozdzielczości. Przelot wykonywany był wzdłuż linii z zachowaniem odległości od linii na poziomie ok 10 m. Na uzyskanych sekwencjach zarejestrowano obraz zbliżony do obrazu otrzymywanego w trakcie przelotu diagnostycznego przedstawiający konstrukcje wsporcze, przewody oraz izolatory.


Zbiór danych na podstawie którego budowano różne warianty zbioru cech dystynktywnych nazwano zbiór D1 (zbiór treningowy). W jego skład wchodziły pojedyncze klatki z sekwencji video. Dla każdej z klatek wyznaczono ręcznie ROI zawierające lokalizację izolatora w scenie. Przykładowe klatki wchodzące w skład zbioru D1 przedstawiono na Rys. 3.2.



Rys. 3.2. Przykładowe klatki ze zbioru danych D1 (zbiór treningowy)

W celu weryfikacji uzyskanej metody opracowane zostały dwa zbiory danych testowych. Zdjęcia wchodzące w skład zbioru D2 to również klatki pochodzące z tych samych przelotów jak w przypadku zbioru D1 jednak w innych ujęciach. Podejście takie pozwala ocenić czy wykorzystany algorytm jest w stanie zlokalizować ten sam obiekt przy zmieniającej się skali oraz perspektywie.

W ostatnim zbiorze nazwanym D3 zgromadzone zostały mocno zróżnicowane obrazy cyfrowe różnych typów izolatorów ceramicznych. Zbiór ten zawierał ponad 100 fotografii o zróżnicowanej rozdzielczości, zmiennym oświetleniu oraz różnym tle, na którym widoczne były izolatory. W zbiorze D3 celowo nie zawarto klatek uzyskanych w ramach przelotów oraz wykorzystywanych do budowy zbioru cech powtarzalnych. Przykłady obrazów cyfrowych wchodzących w skład zbioru danych D3 przedstawiono na Rys. 3.3.



Rys. 3.3. Przykładowe klatki ze zbioru danych D3 (zbiór testowy)

Obrazy zawarte w zbiorze D3 pozyskane zostały z wykorzystaniem różnych metod akwizycji tj. aparat fotograficzny Canon 5D Mark II (różne rodzaje obiektywów) oraz kamery GoPro Hero 4.

### 3.3. Zbiór danych do celów detekcji izolatorów linii wysokiego napięcia z wykorzystaniem konwolucyjnych sieci neuronowych

Podczas procesu tworzenia zbioru danych dla celów uczenia konwolucyjnej sieci neuronowej skoncentrowano się na zastosowaniu możliwie niedużego zbioru zdjęć cyfrowych. Celem takiego działania było podniesienie jakości zbioru treningowego oraz znaczne skrócenie procesu preprocessingu i uczenia poszczególnych modeli sieci neuronowych. W skład treningowego oraz testowego zbioru danych wchodzi zdjęcia pozyskane podczas przelotu pojazdem BSP wzdłuż linii wysokiego napięcia. Do akwizycji danych wykorzystana została kamera GoPro Hero 4.

Wszystkie zdjęcia składające się na treningowy oraz testowy zbiór danych zostały poddane procesowi ręcznego etykietowania (adnotacji) uzyskując w ten sposób zbiór treningowy oraz ręcznie oznaczone ramki pól ograniczających dla zbioru testowego. Dla każdego zdjęcia wygenerowany został osobny plik XML zawierający koordynaty ( $x_{min}$ ,  $y_{min}$ ,  $x_{max}$ ,  $y_{max}$ ) obszarów zainteresowania ROI określające pozycje obiektów w scenie. Na Rys. 3.4 przedstawiono przykładowe zdjęcia zawierające oznaczenia poszukiwanych obiektów, wykonane podczas przelotu wzdłuż linii wysokiego napięcia.



Rys. 3.4. Przykładowe zdjęcia wraz z etykietami pozyskane podczas przelotu pojazdem BSP wzdłuż linii wysokiego napięcia.

Cały zbiór danych zawierał 343 zdjęcia. Zaznaczonych zostało 3138 obszarów zainteresowania zawierających izolator. Testowy zbiór danych składał się z 283 zdjęć (2560 obszarów zainteresowania), a cały treningowy zbiór danych z 60 zdjęć (578 obszarów zainteresowania). Dodatkowo zbiór treningowy podzielony został w taki sposób, iż

wyodrębnione zostały z niego mniejsze zestawy zdjęć tj.: 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55 i 60 zdjęć (klatek sekwencji video).

## **4. Detekcja izolatorów linii wysokiego napięcia z wykorzystaniem algorytmu detekcji i opisu cech SURF oraz wybranych metod filtracji przestrzennej**

W niniejszym rozdziale przedstawiony został pierwszy etap badań związanych z detekcją izolatorów elektroenergetycznych na obrazach cyfrowych rejestrowanych podczas inspekcji linii elektroenergetycznych. Podczas prac analizowano efekty zastosowania filtracji przestrzennej obrazów cyfrowych dla potrzeb wykrycia izolatorów elektroenergetycznych z wykorzystaniem algorytmu detekcji i opisu cech lokalnych SURF. W rozdziale przedstawiony został wpływ użycia różnego rodzaju filtrów przestrzennych tj.: filtrów N-tego rzędu, filtru dolnoprzepustowego, filtrów dylatacyjnego i erozyjnego oraz filtrów wykorzystywanych do detekcji krawędzi, na ilość i jakość detekcji cech kluczowych na izolatorze energetycznym. W rozdziale przedstawiona została ponadto idea filtracji przestrzennej oraz jej najczęstsze zastosowania.

### **4.1. Przebieg eksperymentu badawczego**

W pracy skoncentrowano się na wpływie przedstawionych powyżej filtrów przestrzennych na zwiększenie liczby cech lokalnych występujących na wybranych obiektach znajdujących się na obrazach, tj.: izolatorach elektroenergetycznych. Zastosowane filtry zostały zaimplementowane z wykorzystaniem środowisk National Instrument LabView oraz MathWorks MATLAB®.


Głównym etapem podjętych działań była analiza możliwości wzmocnienia w obrazie wybranych elementów (cech kluczowych znajdujących się na elemencie) zgodnych z podanym wzorcem (izolator). Odbywało się to poprzez zastosowanie różnego rodzaju filtrów przestrzennych, a następnie detekcję cech z wykorzystaniem algorytmu SURF, oraz późniejsze porównanie wyników detekcji w odniesieniu do wyników detekcji cech na obrazie, który nie został poddany filtracji. Celami dodatkowymi były minimalizacja szumów i zakłóceń występujących w obrazach cyfrowych, a także zwiększenie jakości obrazu poprzez wyostrenie, zwiększenie kontrastu oraz usunięcie określonych wad obrazu (np. efektu rozmycia obiektów obserwowanych na obrazach rejestrowanych przez przemieszczające się pojazdy latające i naziemne).

### **4.2. Wyniki z przeprowadzonych analiz**

Głównym kryterium oceny wpływu różnych rodzajów filtracji na działanie algorytmu detekcji oraz opisu cech lokalnych SURF było wyznaczenie liczby cech lokalnych wykrywanych na izolatorze oraz na obszarach zdjęcia cyfrowego poza izolatorem.

W trakcie badania skupiono się na porównaniu udziału procentowego ilości cech lokalnych, które algorytm wykrył w obszarach zawierających izolator, dla scen przed filtracją oraz dla różnych rodzajów filtracji oraz różnych jej parametrów.

Obrazy zostały poddane procesowi detekcji cech kluczowych z wykorzystaniem algorytmu SURF (najpierw obraz bez filtracji, a następnie przefiltrowana scena). Wynik tego procesu przedstawia Rys. 4.1.

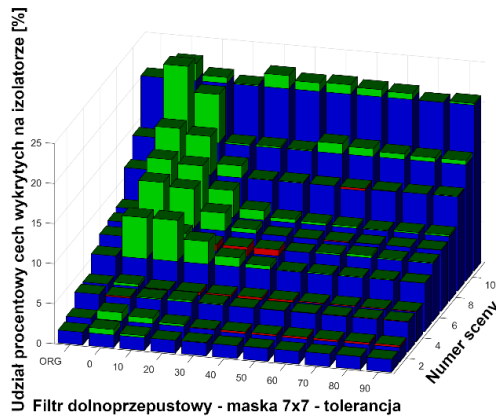


Rys. 4.1. Przykładowy obraz zawierający sceny przed (A) i po filtracji (B) z zaznaczonymi 2000 cechami wykrytymi z wykorzystaniem algorytmu SURF.

Jak widać na Rys. 4.1 proces detekcji cech na obydwu obrazach przebiegł pomyślnie. Na powyższym rysunku zaznaczonych zostało jedynie po 2000 najsilniejszych posortowanych malejąco. W kolejnym kroku przeprowadzana została klasyfikacja cech wykrytych na wszystkich scenach. Podzielone one zostały na te znajdujące się na izolatorze energetycznym (zgodnie z wyznaczonym wcześniej ROI) oraz na te znajdujące się na obszarze tła. Przykładowo scena A zawierała 11555 wykrytych cech kluczowych, z czego 739 znajdowało się na izolatorze. Z kolei scena B zawierała 4510 cech, w czym 460 w obszarze zaznaczonym jako izolator.

W wyniku tego procesu otrzymano wykresy zależności udziału procentowego cech lokalnych wykrytych na izolatorze w zależności od rodzajów oraz parametrów filtracji dla różnych wybranych scen (sceny 1:10 - zdjęcia izolatorów na istniejących liniach energetycznych, scena 11 - zdjęcie izolatora wykonane w laboratorium). Na wszystkich otrzymanych wykresach zależności udziału procentowego cech lokalnych izolatora w zależności od rodzaju i parametrów filtracji kolorem niebieskim zaznaczony jest udział procentowy cech lokalnych wykrytych na izolatorze bez filtracji. Kolorem zielonym oznaczono przypadki (rodzaj filtra i jego parametry), które spowodowały zwiększenie udziału procentowego cech lokalnych wykrytych na izolatorze, z kolei kolorem czerwonym zmniejszenie udziału procentowego cech lokalnych wykrytych na izolatorze.

Na Rys. 4.2 przedstawiono przykładowy wykres obrazujący zmianę udziału procentowego cech lokalnych wykrytych na izolatorze po zastosowaniu filtra dolnoprzepustowego o macierzy konwolucji 7x7.



Rys. 4.2. Przykładowy wykres zależności udziału procentowego cech lokalnych wykrytych na izolatorze od ustawienia parametru tolerancji filtra dolnoprzepustowego z macierzami konwolucji o rozmiarze 7x7.

Na Rys. 4.2 przedstawiono zmianę udziału procentowego cech lokalnych wykrytych na izolatorze po zastosowaniu filtra dolnoprzepustowego. W przypadku wszystkich zastosowanych rozmiarów macierzy konwolucji (3x3, 4x4, 5x5, 6x6 i 7x7) filtr dolnoprzepustowy dla większości scen i rodzajów izolatorów pozwolił na zwiększenie udziału procentowego cech lokalnych wykrywanych na badanym obiekcie, w szczególności dla niskiej wartości parametru tolerancji (0, 10, 20). Zaobserwowano wprost proporcjonalną zależność wpływu wielkości macierzy konwolucji na zwiększenie udziału procentowego cech lokalnych wykrytych na izolatorze (im większa była macierz tym więcej cech lokalnych udało się znaleźć). Dodatkowo odnotowano, iż filtr dolnoprzepustowy we wszystkich przebadanych przypadkach (różne rozmiary masek konwolucji i wartości parametru tolerancji) nie powodował znacznego pogorszenia udziału procentowego znalezionych cech lokalnych.

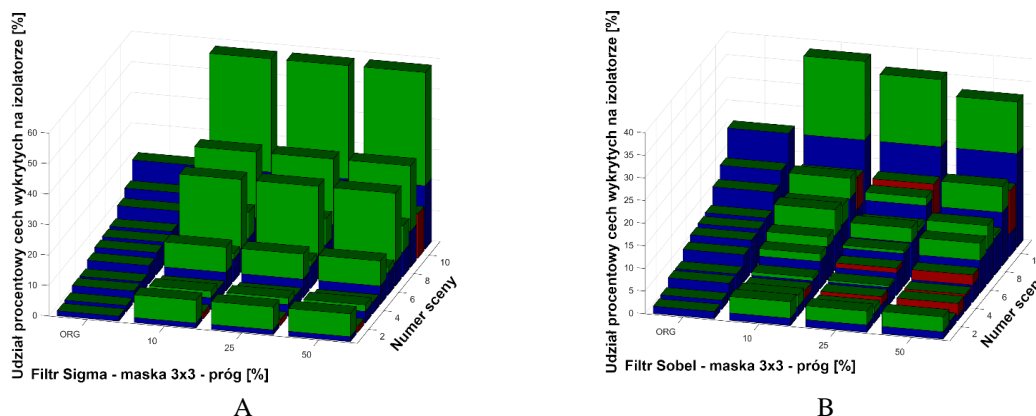
Zastosowanie Filtra n-tego rzędu miało znaczący wpływ na udział procentowy cech lokalnych wykrytych na izolatorze. Dla niektórych scen zmiana parametru rzędu filtra powodowała zwiększenie liczby wykrytych cech lokalnych a dla innych zaobserwowano ich zmniejszenie. sceny od 1 do 10 to obrazy monitoringu linii napowietrznych. Natomiast scena 11 to scena laboratoryjna. Dla tej sceny szczególnie wyraźnie widać negatywny wpływ filtracji z wartościami rzędu filtra mniejszymi od mediany oraz pozytywny wpływ wartości większych. Podobne efekty uzyskano przy zastosowaniu filtrów dylatacyjnego i erozyjnego.

Dla filtra dylatacyjnego (maksymalnego) znaczący wpływ miał kształt macierzy konwolucji na ilość cech lokalnych wykrytych na izolatorze. Zaobserwowano zwiększenie udziału procentowego cech lokalnych na izolatorze w przypadku następujących kształtów masek: diament, dysk, linia, linie okresowe, ośmiokąt, pary. Największy wpływ zauważono w scenie laboratoryjnej, oraz mniejsze (ale zauważalne) w pozostałych scenach. Dla zdecydowanej większości analizowanych scen i różnej konfiguracji parametrów wejściowych zaobserwowano poprawę przy zastosowaniu filtra z macierzą konwolucji w kształcie linie okresowe (poprawa w 31 przypadków z 33). Największy pozytywny wpływ (o 18,31%) zaobserwowano natomiast dla filtra z maską konwolucji w kształcie ośmiokąta, jednak poprawa wystąpiła w 27 przypadków z 33.

Filtr erozyjny miał zazwyczaj negatywny wpływ na wynik badania (zmniejszenie liczby cech lokalnych wykrytych na izolatorze). Zwiększenie udziału procentowego cech lokalnych

na izolatorze zaobserwowano jednak także w przypadku zastosowania następujących kształtów masek konwolucji: linie okresowe, ośmiokąt.

W kolejnym etapie badań analizowano wpływ filtrów krawędziowych na udział procentowy cech wykrytych na izolatorze (Rys. 4.3). Zastosowano następujące rodzaje filtrów: Filtr Gradientowy, Filtr Prewitt'a, Filtr Roberts'a, Filtr różnicowy, Filtr Sigma (A), Filtr Sobel'a (B).



Rys. 4.3. Wykres zależności udziału procentowego cech lokalnych wykrytych na izolatorze od parametru threshold (próg) dla filtrów: Sigma (A), Sobel'a (B).

Na rysunku Rys. 4.3 przedstawiono przykładowe wyniki zastosowania filtrów krawędziowych. Wprowadzenie filtrów znacząco zwiększało udział procentowy cech lokalnych wykrywanych na izolatorze (kolor zielony), jednak równocześnie znacząco zmniejszało całkowitą liczbę cech lokalnych znajdujących się w analizowanej scenie (w skrajnym przypadku z 2156 cech lokalnych z obrazu przed filtracją do 11 cech lokalnych po zastosowaniu filtracji Sigma). Jak wykazano w dalszym etapie badań taka redukcja cech lokalnych była niewystarczająca do detekcji izolatora po zastosowaniu algorytmu SURF.

Zastosowane filtry miały zauważalny (pozytywny lub negatywny) wpływ na ilość wyszukanych cech lokalnych oraz na ich rozdystrybuowanie na powierzchni sceny (udział procentowy na izolatorze). W niektórych przypadkach odnotowano zwiększenie udziału procentowego cech lokalnych na izolatorze nawet o 37,19%.

Kolejnym kryterium oceny filtracji była analiza dopasowania cech lokalnych z obrazu wzorcowego do cech lokalnych wykrytych na obrazie docelowym. W badaniu była mierzona ilość cech lokalnych dopasowanych na izolatorze przed oraz po transformacji geometrycznej oraz czas detekcji, opisu oraz dopasowywania cech lokalnych. Ponadto brane pod uwagę było także to w jaki sposób algorytm wyznaczył Ramki pól ograniczających. Zadaniem transformacji geometrycznej jest zwrócenie obiektu przekształcenia geometrycznego 2D. Obiekt ten odwzorowuje wartości wewnętrzne (z ang. *inliers*) punktów (cech) obiektu wzorcowego na wartości wewnętrzne punktów dopasowanych w scenie. Transformacja geometryczna wyklucza wartości odstające przy użyciu algorytmu MSAC (z ang. *m-estimator sample consensus*). Algorytm MSAC jest wariantem algorytmu RANSAC. Wyniki takiej transformacji mogą nie być identyczne między seriami z powodu losowej natury algorytmu MSAC. Uzyskane rezultaty podzielono na trzy grupy, tj.: poprawianie wyznaczona ramka, błędnie wyznaczona ramka, brak wyznaczonej ramki. Badanie przeprowadzone zostało wyłącznie dla sceny laboratoryjnej (scena 11).



## **5. Detekcja izolatorów linii wysokiego napięcia na podstawie analizy częstości występowania cech dystynktywnych**

W rozdziale przedstawiono koncepcję selekcjonowania charakterystycznych cech lokalnych zmierzającą do detekcji określonych obiektów linii elektroenergetycznej w zróżnicowanych scenach. Głównym celem prac była automatyzacja procesu wyszukiwania charakterystycznych obiektów na obrazach cyfrowych z wykorzystaniem ograniczonego zbioru uczącego. W przeprowadzonym badaniu opis izolatora wykonano na podstawie zbioru dystynktywnych cech lokalnych, które charakteryzowały się największą powtarzalnością na poszczególnych obrazach zbioru testowego. Zbiór taki umożliwił lokalizację izolatorów w pozostałych próbkach uzyskanych z przelotu diagnostycznego.

W celu weryfikacji opracowanej metody opracowano trzy zróżnicowane zbiory weryfikacyjne. Do wyszukiwania oraz opisu cech lokalnych wykorzystano algorytm SURF. Opracowany zbiór uczący oraz przyjęta metodologia badania pozwoliły na uzyskanie obiecujących rezultatów w ramach analizowanego scenariusza (przelot wzdłuż linii elektroenergetycznej). Prowadzone analizy zmierzają do opracowania metod wspomagających utrzymanie sieci elektroenergetycznej bazujących na zaawansowanych technikach przetwarzania obrazów cyfrowych.

Głównym celem prowadzonych badań było uzyskanie jak najmniejszego zbioru cech kluczowych opisujących izolator energetyczny na podstawie zbioru treningowego, którego elementy w jak największej liczbie będą zlokalizowane na wykrywanych obiektach zbioru testowego. Zbiór taki miał umożliwiać lokalizację izolatorów w pozostałych próbkach uzyskanych z przelotu diagnostycznego.

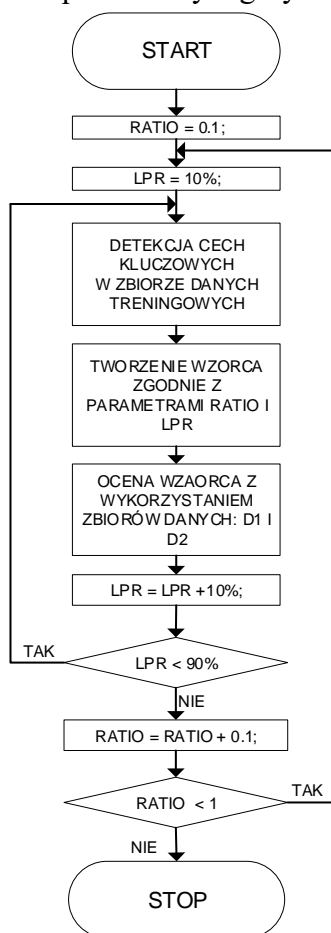
### **5.1. Przebieg eksperymentu badawczego**

Przeprowadzone badanie miało na celu sprawdzenie możliwości budowy zbioru powtarzalnych cech lokalnych opisujących obiekt na obrazach cyfrowych. W badaniu obiektem dla którego opracowano zbiór powtarzalnych cech jest ceramiczny długopniowy izolator energetyczny. Jednym z etapów badania była próba selekcji cech najlepiej opisujących obiekt w różnych scenach oraz warunkach oświetleniowych. Parametry wykorzystywane na etapie tworzenia zbioru cech powtarzalnych to parametr ratio określający zakres filtracji punktów kluczowych oraz częstość która dotyczy powtarzalności określonej cechy w pozostałych scenach. Celem badania jest ocena oraz dobór optymalnych wartości obu parametrów. Kolejnym celem prowadzonych badań była próba stworzenia zbioru cech opisujących obiekt na podstawie zredukowanego zbioru treningowego.

Kluczowymi parametrami z punktu widzenia przeprowadzonego badania były parametry LPR oraz parametr Ratio. LPR jest cechą która zwykle wykorzystywana jest jako metryka do oceny skuteczności działania detektorów cech [ScRB13]. Metryka ta niesie informację na temat częstości powtórzeń wybranej cechy we wszystkich obrazach treningowego zbioru danych obrazującego izolator energetyczny w różnych scenach przy zmiennych warunkach

oświetleniowych. W prowadzonym badaniu wykorzystano jednak parametr LPR nie jako miarę oceny detektora lecz jako parametr mówiący o przydatności cechy podczas budowy zbioru cech kluczowych opisujących analizowany obiekt. Była to próba wyekstrahowania cech dystynktywnych, których występowanie w obrazach testowych pozwolić miała na stwierdzenie, że z wysokim prawdopodobieństwem scena zawiera badany obiekt. W niniejszym rozdziale parametr LPR wyrażony jest jako udział procentowy liczby dopasowań określonej cechy w obrazach z całego treningowego zbioru danych.

Parametr ratio pozwala na wykluczenie dopasowań wektorów cech kluczowych, których poziom (wartość błędu średniokwadratowego) nie jest wystarczający. Przyjmuje on wartość z zakresu 0 – 1. Uproszczony algorytm badania przedstawiony został na Rys. 5.1.



Rys. 5.1. Diagram procesu tworzenia wariantów testowych zbioru lokalnych cech powtarzalnych przy zmianie parametrów ratio i częstość

Jak można zauważyć na Rys. 5.1 zbiór cech dystynktywnych budowany jest w 4 następujących krokach:

1. We wszystkich obrazach z treningowego zbioru danych wyszukiwane są cechy kluczowe (w tym przypadku z wykorzystaniem algorytmu SURF), następnie wektoryzowane (również z wykorzystaniem algorytmu SURF)
2. Następnie każda wykryta cecha kluczowa jest dopasowywana do wszystkich cech z pozostałych obrazów treningowego zbioru danych.
3. Cechy, które zostały poprawnie dopasowane (zależnie od ustalonego poziomu parametru Ratio) zostają dodane do tymczasowego zbioru cech.
4. W ostatnim kroku zbiór jest filtrowany i pozostają w nim jedynie cechy, których częstość występowania jest wyższa lub równa założonemu poziomowi LPR.

Powyższy proces był powtarzany dla różnych wartości parametru Ratio (0.1 do 1) oraz parametru LPR (10% do 90%).

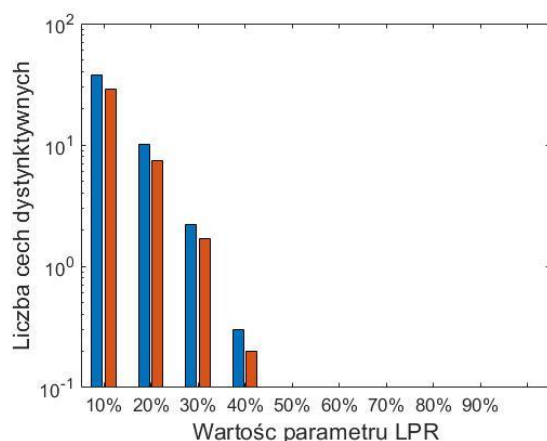
## 5.2. Wyniki z przeprowadzonych analiz

Zbiór cech powtarzalnych utworzono na podstawie obszarów zainteresowania ROI określających pozycję izolatorów w zbiorze danych D1. Główny wpływ na wielkość utworzonego zbioru ma parametr Ratio, który ma za zadanie odfiltrować część błędnie dopasowanych cech kluczowych wyszukanych na etapie detekcji w scenach. W trakcie wykonywania analiz przyjęto parametr Ratio na poziomie 0.6 jako kompromis pomiędzy

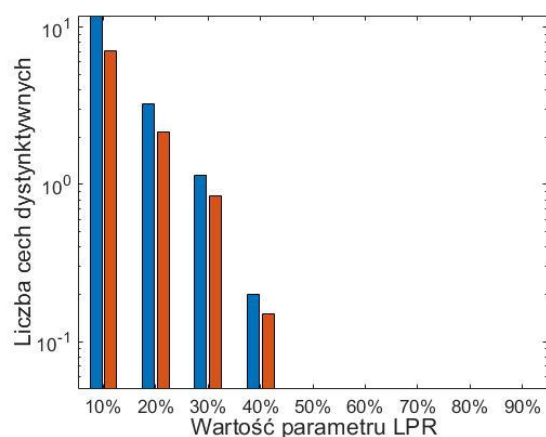
wielkością zbioru cech dystynktywnych a powtarzalnością określonych cech w tym zbiorze. Dla zbioru danych D1 i parametru ratio 0.6 uzyskano następujące wielkości zbiorów cech dystynktywnych dla określonych wielkości parametru LPR: 615 cech dla LPR równego 10%, 157 cech dla LPR równego 20%, 34 cechy dla LPR równego 30%, 4 cechy dla LPR równego 40%, 1 cechę dla LPR równego 50% oraz 0 cech dla pozostałych przypadków.

Tak jak się spodziewano w miarę zwiększania poziomu odcięcia (określony poziom parametru LPR) zmniejsza się znacząco liczba cech dystynktywnych wchodzących w skład zbioru wzorcowego. Celem badań powinno więc być wyekstrahowanie takiej liczby cech dystynktywnych wchodzących w skład zbioru wzorcowego opisujących izolator elektroenergetyczny, aby możliwa była jego późniejsza detekcja.

Na Rys. 5.2 i Rys. 5.3 przedstawiono średnia liczbę cech powtarzalnych dopasowanych w wszystkich scenach zbiorów danych D1 oraz D2.



Rys. 5.2. Średnia liczba cech powtarzalnych dopasowanych we wszystkich scenach zbioru danych D1 (niebieski) do cech dopasowanych na izolatorze (czerwony): (oś x – Wartość parametru LPR, oś y – Średnia liczba dopasowanych cech dystynktywnych)




Rys. 5.3. Średnia liczba cech powtarzalnych dopasowanych we wszystkich scenach zbioru danych D1 (niebieski) do cech dopasowanych na izolatorze (czerwony): (oś x – Wartość parametru LPR, oś y – Średnia liczba dopasowanych cech dystynktywnych)

Wykres przedstawiony na Rys. 5.2 pokazuje że bardzo duża część cech dystynktywnych dopasowanych w zbiorze D1 znajduje się na izolatorze. W szczególności widać to dla parametru LPR w przedziale od 10% do 30%. Dlatego aby ograniczyć złożoność obliczeniową całego procesu, celowym wydaje się ograniczenie wielkości zbioru cech dystynktywnych poprzez odpowiednie dopasowanie parametru LPR.

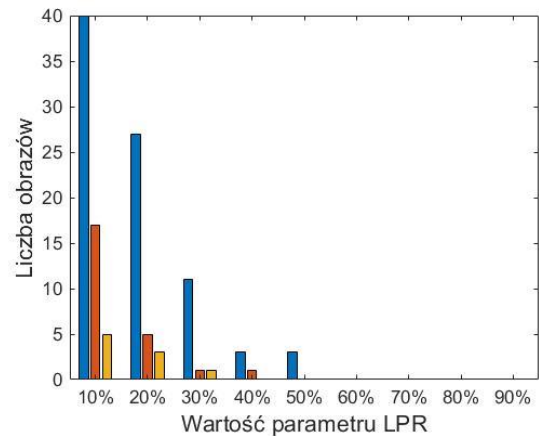
Na wykresie przedstawionym na Rys. 5.3 zaobserwować można sytuację analogiczną jak ta na Rys. 5.2 jednakże zauważyć tutaj należy, że liczba cech dopasowanych jest w tym przypadku niemalże o rząd wielkości mniejsza. Niemniej jednak również w tym przypadku celowym wydaje się ograniczenie zbioru cech dystynktywnych poprzez zmianę parametru LPR, w celu zwiększenia wydajności algorytmu (Stosowana analiza czasu przetwarzania algorytmu zostanie przedstawiona na Rys. 5.6).

Na Rys. 5.4 i Rys. 5.5 przedstawiono wynik dopasowania wyekstrahowanych cech dystynktywnych w zbiorach testowych D2 i D3 w zależności od zmiany parametru LPR. Słupki niebieski przedstawia liczbę obrazów, w których dopasowano przynajmniej jedną cechę natomiast pozostałe słupki przedstawiają odpowiednio liczbę obrazów, w których jednocześnie

znaleziono przynajmniej 2 cechy (słupek czerwony) oraz liczbę obrazów, w których jednocześnie znaleziono przynajmniej 3 cechy (słupek pomarańczowy).



Rys. 5.4. Liczba obrazów ze zbioru danych D2, w których dopasowano odpowiednio przynajmniej 1,2 lub 3 cechy w zależności od wartości parametru LPR (oś x - LPR, oś y - Liczba zdjęć na których dopasowano cechy na izolatorze, (1 cecha – kolor niebieski, 2 cechy – kolor czerwony, 3 cechy – kolor żółty))

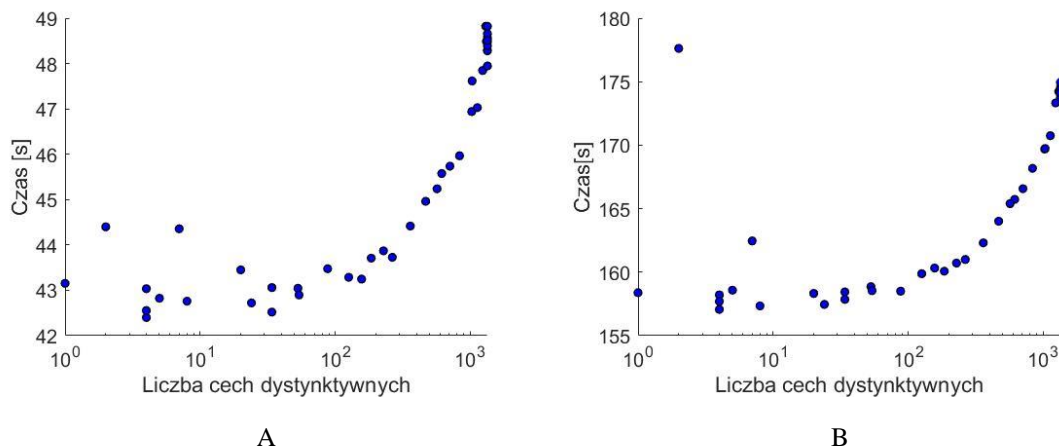


Rys. 5.5. Liczba obrazów ze zbioru danych D3, w których dopasowano odpowiednio przynajmniej 1,2 lub 3 cechy w zależności od wartości parametru LPR (oś x - LPR, oś y - Liczba zdjęć na których dopasowano cechy na izolatorze, (1 cecha – kolor niebieski, 2 cechy – kolor czerwony, 3 cechy – kolor żółty))

Jak pokazuje Rys. 5.4 w miarę zwiększania parametru LPR liczba dopasowanych cech maleje dla każdego z analizowanych przypadków (tj. 1, 2, 3 cech). Trzy cechy, które mogą być niezbędne do zastosowania większości algorytmów detekcji udało się dopasować jedynie dla parametru LPR w przedziale od 10% do 30%. Dla LPR większego od 50% nie udało się dopasować żadnych cech.

Rys. 5.5 przedstawia sytuację analogiczną jak ta na Rys. 5.4 jednakże tutaj zaobserwowano zmniejszenie liczby obrazów, na których udało się wykryć cechy wraz ze wzrostem parametru LPR jest znacznie bardziej widoczny. Zmierzając do detekcji określonego obiektu celowe jest dopasowanie jak największej liczby cech kluczowych w analizowanej scenie. Jak widać dopasowanie jednej cechy było możliwe w zakresie powtarzalności od 10 do 50% ale znacząco ogranicza to możliwości wykorzystania różnych technik detekcji obiektów. Analiza wykresów Rys. 5.4 i Rys. 5.5 sugeruje, że zbiory cech wykorzystywane do detekcji obiektów w scenie powinny być jak największe aby uzyskać możliwie wysoki poziom dopasowania cech w obrazach testowych. Jednakże wzrost wielkości zbioru cech dystynktywnych prowadzi do zwiększenia czasu detekcji cech w scenach testowych.

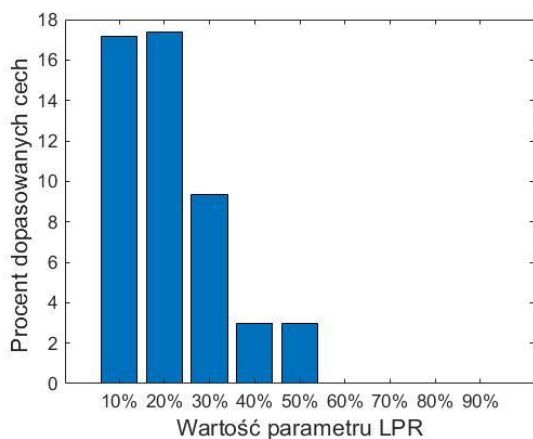
Na Rys. 5.6 przedstawiono zależność czasu detekcji analizy scen ze zbiorów danych D2 i D3 od wielkości zbioru cech dystynktywnych. Czas analizy sceny obejmuje: wczytanie sceny, detekcję cech na scenie z wykorzystaniem algorytmu SURF, proces dopasowania poszczególnych cech w ścianach oraz dodatkowe obliczenia mające na celu ustalenie pozycji znalezionych cech lokalnych względem ROI.



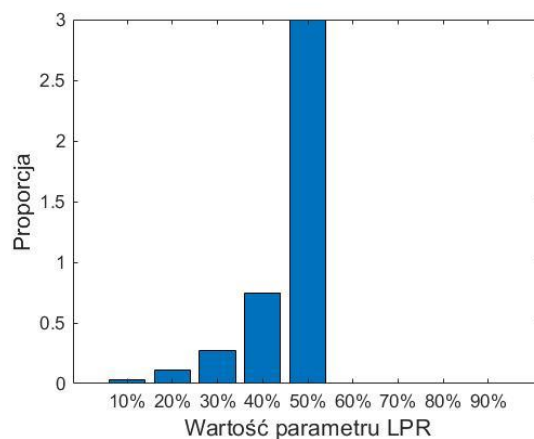
Rys. 5.6. Porównanie czasów przetwarzania dla: A – zbioru danych D2, oraz B – zbioru danych D3 dla różnych wielkości zbiorów wyselekcjonowanych cech dystynktywnych (oś x – wielkość zbioru wyselekcjonowanych cech dystynktywnych, oś y – czas przetwarzania [s])

Badanie zostało przeprowadzone z wykorzystaniem środowiska MathWorks MATLAB®, oraz komputera wyposażonego w procesor Intel Core i7-3517U oraz 8GB pamięci RAM. Z Rys. 5.6 wynika, że zwiększenie wielkość zbioru cech dystynktywnych wpływa znacząco na czas analizy scen oraz na zwiększenie kosztu obliczeniowego procesu dopasowywania.

Weryfikację zbioru cech uzyskanego na podstawie treningowego zbioru danych wykonano w oparciu o testowy zbiór danych D3. Wyniki analizy przedstawiają Rys. 5.7 i Rys. 5.8. Badanie miało na celu odpowiedzieć na pytanie jaki udział procentowy cech dopasowanych znajdował się w ROI izolatora, a jaki poza.



Rys. 5.7. Stosunek liczby cech dopasowanych na izolatorze do wszystkich cech dopasowanych w całej scenie dla różnych wartości parametru LPR (zbiór danych D3)(oś x – powtarzalność, oś y -udział procentowy cech dopasowanych na izolatorze do wszystkich cech dopasowanych w obrazie)



Rys. 5.8. Stosunek liczby cech dopasowanych na izolatorze do wszystkich cech dopasowanych w całej scenie w odniesieniu do wielkości zbioru cech powtarzalnych dla różnych wartości parametru LPR (zbiór danych D3)(oś x – powtarzalność, oś y – udział procentowy cech dopasowanych na izolatorze do wszystkich cech dopasowanych w obrazie w odniesieniu do wielkości zbioru cech powtarzalnych)

Na Rys. 5.7 można zauważyć, że najwyższy stosunek liczby cech dopasowanych na izolatorze do wszystkich cech dopasowanych w całej scenie dla różnych wartości parametru LPR oraz zbioru danych testowych D3 otrzymano dla wartości parametru LPR równego 20%.

Porównywalny wynik otrzymano dla LPR = 10%. Niższą wartość otrzymano dla LPR = 30%, oraz znacznie niższe dla LPR = 40% i 50%. Dla pozostałych wartości parametru LPR, stosunek liczby cech dopasowanych na izolatorze do wszystkich cech dopasowanych w całej scenie dla zbioru testowego D3 wyniósł 0.

Na Rys. 5.8 przedstawiona została ta sama statystyk co na Rys. 5.7, ale w odniesieniu do całkowitej wielkości zbioru cech dystynktywnych. Na podstawie analizy Rys. 5.7 i Rys. 5.8 można wnioskować, że zmniejszenie parametru LPR, który wpływa na wzrost zbioru cech dystynktywnych nie przekłada się liniowo na zwiększenie stosunku liczby cech dopasowanych na izolatorze do wszystkich cech dopasowanych w zbiorze danych D3.

## 6. Detekcja izolatorów linii wysokiego napięcia z wykorzystaniem konwolucyjnych sieci neuronowych

W rozdziale przedstawiono analizę skuteczności detekcji obiektów na obrazach cyfrowych przy zastosowaniu ograniczonej liczby danych wejściowych. Możliwość wykorzystania ograniczonego zbioru danych uczących uzyskano poprzez opracowanie szczegółowego scenariusza zadania, ściśle określającego warunki pracy detektora – w rozważanym przypadku – sieci konwolucyjnej. Opisane rozwiązanie wykorzystuje znane architektury głębokich sieci neuronowych w procesie uczenia, oraz detekcji obiektów. W artykule przedstawiono porównania wyników detekcji wybranych głębokich sieci neuronowych przy zachowaniu ograniczonego zbioru uczącego składającego się z określonej liczby wyselekcjonowanych obrazów filmu inspekcyjnego. Zbiór ten opisany został w rozdziale 3.3. Analizowany materiał wejściowy zarejestrowano podczas przelotu inspekcyjnego wykonanego wzdłuż linii wysokiego napięcia. Wykorzystane w badaniu konwolucyjne sieci neuronowe nie były uczone od zera. Wykorzystano modele uczone wstępnie na zbiorze COCO (z ang. *COCO dataset*), a następnie wykonano proces przeniesienia wiedzy i dostrojenia modelu (ang. *transfer learning*).

W rozdziale przedstawiono wyniki badań związane z eliminacją wskazanego powyżej problemu. Wykonano analizę efektów uczenia wybranych implementacji konwolucyjnych sieci neuronowych przy zastosowaniu ograniczonego zbioru wizyjnych danych treningowych zarejestrowanych podczas przelotu statku BSP nad obiektami infrastruktury elektroenergetycznej.

Dokładność oraz skuteczność detekcji wykonanych przez konwolucyjne sieci neuronowe została obliczona na podstawie parametrów takich jak IOU, precision, recall oraz parametru AP. Parametr IoU określa jaka jest różnica w położeniu oraz wielkości pomiędzy dwoma obszarami. Parametr ten jest obliczany za pomocą wzoru:

$$IoU = \frac{A \cap B}{A \cup B}$$

gdzie:

A – obszar wyznaczony ręcznie,

B – obszar wyznaczony przez detektor,

$A \cap B$  – powierzchnia iloczynu pól,

$A \cup B$  – powierzchnia sumy pól.

Parametr precision mówi o tym jak dokładny jest detektor tj. jaka część predykcji jest prawidłowa. Parametr ten jest opisany następującym wzorem:

$$precision = \frac{TP}{TP + FP}$$

gdzie:

TP – predykcje poprawne,

FP – predykcje nie poprawne,

TP + FP – Suma wszystkich predykcji obiektów dokonanych przez detektor.

Z kolei parametr recall mówi o tym jak dobrze detektor wyszukuje obiekty tj., ile zaznaczonych ręcznie obiektów udało się znaleźć. Wzór opisujący ten parametr ma następującą postać:

$$recall = \frac{TP}{TP + FN}$$

gdzie:

TP – predykcje poprawne,

FN – braki predykcji w miejscach, w których powinny wystąpić,

TP + FN – Suma wszystkich zaznaczonych ręcznie obiektów.

Do wyznaczania parametru AP konieczne jest wyrysowanie krzywej precision(recall). Ogólnie wyznaczenie parametru AP polega na znalezieniu obszaru pod krzywą za pomocą wzoru:

$$AP = \int_0^1 p(r) dr$$

gdzie:

AP – parametr AP,

p – parametr precision,

r – parametr recall.

Przed obliczeniem parametru AP krzywa precision(recall) jest zwykle wygładzana. Graficznie odbywa się to tak, że dla każdego poziomu recall zastępujemy każdą wartość parametru precision maksymalną wartością tego parametru znajdującą się po prawej stronie tego poziomu recall. Matematycznie oznacza to, że wartości parametru precision dla recall  $\hat{r}$  zostały zamienione na maksymalną wartość parametru precision dla każdego recall  $\geq \hat{r}$ . Co można opisać wzorem:

$$p'(r) = \max_{\hat{r} \geq r} p(\hat{r})$$

gdzie:

p – wartość precision,

p' – nowo obliczony parametr precision,

r – wartość recall,

$\hat{r}$  – wartość parametru recall dla którego obliczany jest nowy parametr precision.

W ostatnim kroku parametr AP obliczany jest za pomocą wzoru:

$$AP = \frac{1}{11} \sum_{r \in \{0.0, 0.1, \dots, 1.0\}} p'(r)$$

gdzie:

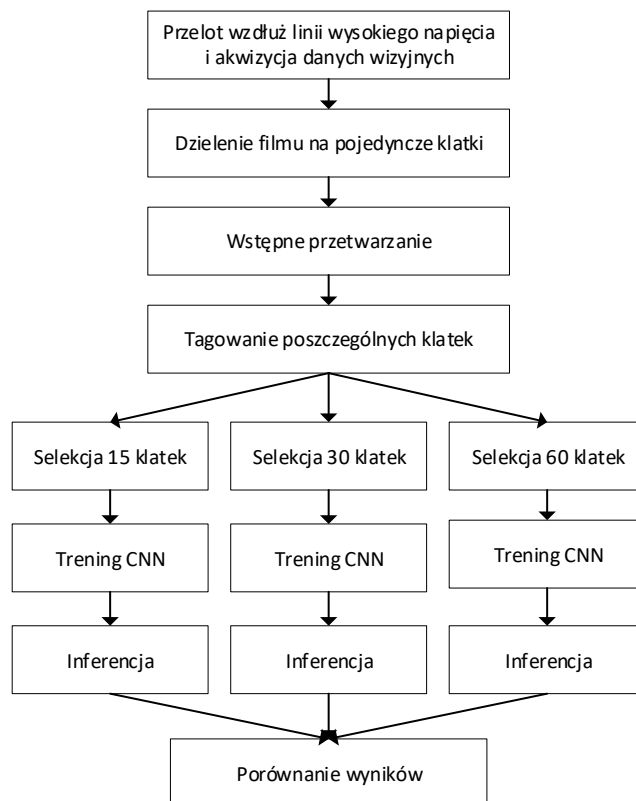
AP – parametr AP,

p' – nowo obliczony parametr precision,

r – wartość recall,

## 6.1. Przebieg eksperymentu badawczego

Schemat blokowy (Rys 6.1.) przedstawia poszczególne etapy przeprowadzonego eksperymentu badawczego.



Rys. 6.1. Poszczególne etapy eksperymentu badawczego [ToMO20].

Pierwszy etap eksperymentu badawczego to wykonanie przełotu inspekcyjnego wzdłuż linii elektroenergetycznej z wykorzystaniem bezzałogowego statku latającego oraz kamery rejestrującej obraz cyfrowy w rozdzielczości 3840 na 2160 pikseli. Następnie zarejestrowany materiał video został podzielony na pojedyncze obrazy cyfrowe z określonym interwałem czasowym. Wyselekcjonowane zdjęcia zawierające badany obiekt lub obiekty zostają poddane wstępnej obróbce wstępnej, a następnie etykietowaniu.

W kolejnym etapie wyselekcjonowane obrazy zostały podzielone na uczący zbiór danych składający się odpowiednio z 15, 30 oraz 60 klatek oraz testowy zbiór danych obejmujący 283 klatki zawierające 2560 obszarów zainteresowania przedstawiających izolator energetyczny

W pierwszej fazie eksperymentu: analizowano wybrane modele CNN: Faster R-CNN (Faster Region-Convolutional neural network) [RHGS16] Sieć YOLO v3 (You Only Look Once v3) [ReFa18], dwie różne implementacje sieci SSD (Single Shot MultiBox Detector) [LAES16] oraz sieć R-FCN (Region-based Fully Convolutional Network) [DLHS16]. Ich szczegółowy opis przedstawiono w doktoracie. Dla każdego przygotowanego zbioru danych (15, 30, 60 klatek) przeprowadzono proces uczenia wybranych konwolucyjnych sieci neuronowych, wykonano proces wnioskowania dla identycznego zbioru testowego oraz w ostatnim etapie porównano otrzymane wyniki.

W pogłębionym badaniu do celów testowania przygotowano także uczące zbiory danych obejmujące odpowiednio 5, 10, 20, 25, 35, 40, 45, 50 oraz 55 klatek. To badanie wykonano tylko na dwóch wybranych modelach sieci konwolucyjnych dla których w poprzednim badaniu uzyskano najlepsze wyniki detekcji. Sieci te to Faster R-CNN i R-FCN, które krótko zostały scharakteryzowane poniżej.

Sieć Faster R-CNN jest następcą sieci R-CNN [GDDM14] i Fast R-CNN [Girs15]. R-CNN jest algorytmem opartym na konwolucyjnej sieci neuronowej umożliwiającym detekcję obiektów. Algorytm sieci Faster R-CNN dostarcza cały obraz na wejście sieci konwolucyjnej. Zamiast wykorzystywać algorytm wyszukiwania selektywnego (z ang. *selective search*) na mapie cech (jak ma to miejsce np. w sieci R-CNN), używana jest tutaj osobna sieć do predykcji propozycji regionów. Architektura Faster R-CNN składa się w rzeczywistości z dwóch sieci. Pierwsza z nich sieć RPN (z ang. *region proposal network*), wykorzystywana jest do generowania propozycji regionów, a kolejna do detekcji obiektów na podstawie tych propozycji. Sieć RPN wykorzystuje mechanizm okna przesuwającego dla każdej lokalizacji na mapie cech. W każdej lokalizacji k predefiniowanych kształtów zwanych skrzyniami kotwicznymi (z ang. *anchor box*) jest wykorzystywanych do generowania propozycji regionów. Faster R-CNN wykorzystuje 9 rodzajów skrzyń kotwicznych w trzech skalach (128, 256 i 512) oraz 3 proporcjach (1:1, 1:2, 2:1). Faster R-CNN jak wiele innych konwolucyjnych sieci neuronowych wykorzystuje funkcję straty (z ang. *loss function*) w procesie dopasowywania modelu oraz reprezentacji rozbieżności wartości dopasowanej funkcji dla danych obserwowanych i prognozowanych. W przypadku sieci Faster R-CNN funkcja ta ma następującą postać:

$$L(\{p_i\}, \{t_i\}) = \frac{1}{N_{cls}} \sum_i L_{cls}(p_i, p_i^*) + \lambda \frac{1}{N_{reg}} \sum_i p_i^* L_{reg}(t_i, t_i^*)$$

gdzie:

$p_i$  – obliczone prawdopodobieństwo, że skrzynia kotwiczna i zawiera obiekt,

$p_i^*$  – etykieta (binarna wyznaczona ręcznie) mówiąca o tym czy skrzynia kotwiczna i faktycznie zawiera obiekt,

$t_i$  – obliczone współrzędne obiektu,

$t_i^*$  – współrzędne obiektu wyznaczone ręcznie,

$N_{cls}$  – współczynnik służący do normalizacji,

$N_{reg}$  – współczynnik służący do normalizacji,

$\lambda$  – współczynnik równoważący.

W celu predykcji ramek pól ograniczających (z ang. *bounding box regression*) sieć Faster R-CNN korzysta z metody opartej na parametryzacji 4 współrzędnych, które wyliczane są według następujących wzorów:

$$\begin{aligned} t_x &= \frac{x - x_a}{w_a}, & t_y &= \frac{(y - y_a)}{h_a}, \\ t_w &= \log\left(\frac{w}{w_a}\right), & t_h &= \log\left(\frac{h}{h_a}\right), \\ t_x^* &= \frac{x^* - x_a}{w_a}, & t_y^* &= \frac{(y^* - y_a)}{h_a}, \\ t_w^* &= \log\left(\frac{w^*}{w_a}\right), & t_h^* &= \log\left(\frac{h^*}{h_a}\right), \end{aligned}$$

gdzie:

$x, y$  – oznaczają współrzędne środka,

$w, h$  – oznaczają szerokość i wysokość,

$x, x_a, x^*$  - oznaczają kolejno współrzędną z predykcji, współrzędną z skrzynki kotwicznej oraz współrzędną wyznaczoną ręcznie (tak samo dla  $y, w$  i  $h$ ).

Konwolucyjna sieć neuronowa R-FCN (Region-based Fully Convolutional Network) [DLHS16]. Podobnie jak ma to miejsce w architekturze Faster R-CNN do predykcji propozycji regionów wykorzystywana jest w sieć RPN. Jednak w przeciwieństwie do architektury Faster R-CNN w pełni połączone warstwy znajdujące się po algorytmie łączenia ROI zostały usunięte. Zamiast tego większość obliczeń jest przeniesiona wcześniej. W celu generowania map wyników. Wszystkie propozycje regionów, po zsumowaniu ROI, wykorzystają ten sam zestaw map wyników do wykonania średniego głosowania. Oznacza to, że po warstwie ROI nie występuje żadna możliwa do nauczenia warstwa sieci neuronowej, a wykorzystywane tutaj mapy cech oparte na regionach (z ang. *region-based feature maps*) są niezależne od ROI. W sieci R-FCN do generowania map cech jest wykorzystywane pierwsze 100 wstępnie przeszkolonych warstw konwolucyjnych sieci ResNet-101.

Proces takiej detekcji/oceny wygląda następująco. Region dzielony jest np. na 3x3 równe części, a następnie oceniane jest prawdopodobieństwo tego, że każdy region zawiera odpowiednią część obiektu. Na przykład, jak prawdopodobne jest to, że lewy górny obszar ROI zawiera lewe oko. Wyniki tego prawdopodobieństwa przechowywane są w tablicy głosów (z ang. *vote array*). Ten proces mapowania map wyników i ROI do tablicy głosów nazywany jest łączeniem ROI wrażliwym na pozycję (z ang. *position-sensitive ROI-pool*), który jest bardzo podobna do odpowiadającego mu procesu w architekturze Faster R-CNN [RHGS16].

Funkcja straty w sieci R-FCN składa się z dwóch funkcji: straty klasyfikacji oraz straty lokalizacji (z ang. *bounding box regression loss*). Funkcja ta ma następującą postać:

$$L(s, t_{x,y,w,h}) = L_{cls}(S_{c^*}) + \lambda[c^* > 0]L_{reg}(t, t^*)$$

gdzie:

$L_{cls}(S_{c^*})$  – strata klasyfikacji, obliczana za pomocą funkcji Softmax,

$L_{reg}(t, t^*)$  – strata lokalizacji obliczana za pomocą funkcji  $\text{smooth}_{L1}$ ,

$[c^* > 0]$  – wskaźnik równy **1**, jeśli argument jest prawdziwy i **0** w przeciwnym wypadku,

$\lambda$  – waga,

$t^*$  - ramka ograniczająca wyznaczona ręcznie,

$c^*$  - etykieta ramki ograniczającej wyznaczonej ręcznie.

## 6.2. Wyniki z przeprowadzonych analiz

Wyniki działania wybranych konwolucyjnych sieci neuronowych oceniano na podstawie trzech parametrów tj. precision, recall oraz average precision. W analizie działania sieci kluczowy był parametr average precision, oraz krzywa average precision, na podstawie której parametr ten był wyznaczany. Krzywa ta wyrysowywana jest na podstawie wyznaczonych uprzednio parametrów precision i recall dla każdej pojedynczej detekcji obiektu. Kształt oraz położenie krzywej AP pozwala ocenić dokładność działania sieci dla przykładu jeśli krzywa AP jest bardziej horyzontalna i umiejscowiona wyżej na osi y tym dokładniejsza jest sieć, a im sięga dalej na osi x tym więcej obiektów udało jej się prawidłowo wykryć. W idealnym przypadku byłaby to linia prosta na poziomie  $y=1$  sięgająca aż do wartości  $x=1$ .

### 6.2.1 Analiza wyników detekcji wszystkich wytypowanych konwolucyjnych sieci neuronowych

Początkowo w badaniu testowano możliwość wykorzystanie do celów uczenia konwolucyjnych sieci neuronowych 15, 30 oraz 60 początkowych klatek z filmu z przelotu

wzdłuż linii wysokiego napięcia. Zauważono, że zastosowanie do budowy zbioru danych uczących 15, 30 i 60 początkowych klatek z filmu z przelotu wzdłuż linii wysokiego napięcia nie pozwoliło uzyskać zadowalających wyników tj. bardzo niska wartość parametru recall oraz dość niska precyzja detekcji. Badanie to pozwoliło jednak zaobserwować pewne tendencję oraz zależności pomiędzy ilością klatek wejściowych, a skutecznością detekcji. Zauważono także, że niektóre sieci osiągnęły znacząco lepsze wyniki (Faster R-CNN, R-FCN) od innych (SSD Inception, SSD MobileNet, YOLO).

W dalszej części badania zdecydowano się na wykorzystanie do celów budowy uczących zbiorów danych klatek, które pochodziły z tego samego filmu z przelotu, ale tym razem były on równomiernie rozłożone w całym filmie. W taki sposób, że pierwsza i ostatnia klatka zbioru danych to pierwsza i ostatnia klatka filmu, a pozostałe zostały wycięte z filmu w równych odstępach. Ważną kwestią w tym przypadku jest to, że film z przelotu zawiera tylko i wyłącznie klatki, na których znajdują się izolatory energetyczne.


W Tab. 6.1 przedstawione zostały wyniki analiz dla wybranych sieci neuronowych wytrenowanych na podstawie 15, 30 oraz 60 klatek z całego filmu z przelotu wzdłuż linii wysokiego napięcia. Ponadto, tabela zawiera wartości parametrów average precision, precision i recall obliczone dla trzech różnych ustalonych wartości IoU (tj. 0.25, 0.5, 0.75).

Tab. 6.1. Zestawienie wyników analiz dla wszystkich wybranych konwolucyjnych sieci neuronowych [ToMO20].

Model sieci	Ilość klatek filmu	Average precision IOU = 0.25	Precision IOU = 0.25	Recall IOU = 0.25	Average precision IOU = 0.5	Precision IOU = 0.5	Recall IOU = 0.5	Average precision IOU = 0.75	Precision IOU = 0.75	Recall IOU = 0.75
R-FCN	15	0.7069	0.9123	0.7027	0.4805	0.7110	0.5477	0.1110	0.1668	0.1285
R-FCN	30	0.8015	0.9272	0.8461	0.5580	0.7354	0.6711	0.1178	0.2098	0.1914
R-FCN	60	0.8948	0.9515	0.9266	0.6598	0.8139	0.7926	0.1589	0.2720	0.2648
Faster R-CNN	15	0.6156	0.8846	0.6137	0.3952	0.6537	0.4535	0.1064	0.1509	0.1047
Faster R-CNN	30	0.7044	0.8989	0.7223	0.4723	0.7000	0.5625	0.0670	0.1731	0.1391
Faster R-CNN	60	0.8043	0.9274	0.8328	0.6718	0.7964	0.7152	0.1584	0.2671	0.2398
SSD Inception	15	0.3589	0.9479	0.3910	0.2285	0.6771	0.2793	0.0909	0.1752	0.0723
SSD Inception	30	0.4486	0.9528	0.4813	0.3096	0.7301	0.3688	0.0331	0.1570	0.0793
SSD Inception	60	0.5365	0.9589	0.5465	0.3944	0.7615	0.4340	0.1199	0.2557	0.1457
SSD MobileNet	15	0.3520	0.9286	0.3555	0.2238	0.6224	0.2383	0.0273	0.1327	0.0508
SSD MobileNet	30	0.4344	0.9211	0.4238	0.2956	0.6842	0.3148	0.0303	0.1171	0.0539
SSD MobileNet	60	0.5290	0.9225	0.5207	0.3014	0.6657	0.3758	0.0268	0.1488	0.0840
YOLO v3	15	0.2651	0.9324	0.2965	0.1418	0.5258	0.1672	0.0056	0.0590	0.0188
YOLO v3	30	0.3493	0.9208	0.3727	0.1127	0.4797	0.1941	0.0114	0.0531	0.0215
YOLO v3	60	0.4445	0.9427	0.4500	0.2000	0.5483	0.2617	0.0909	0.0687	0.0328

Jak można zauważyć w Tab. 6.1 zmiana wartości parametru IoU miała znaczący wpływ na wyniki analiz. Do dalszych analiz przyjęto, że poziom IoU równy 0.5 jest wystarczający, aby stwierdzić, że izolator został poprawnie wykryty na obrazie. Dla IoU równego 0.5 można zauważyć że sieci Faster RCNN oraz R-FCN cechują się zdecydowanie najwyższą skutecznością. Należy tutaj zwrócić szczególną uwagę na parametr recall, który dla sieci R-FCN wytrenowanej na 60 klatkach dla IoU równego 0.5 miał wartość aż 0.7925. Oznacza to że w tym przypadku sieci udało się poprawnie wykryć prawie 80% izolatorów.

Na Rys. 6.2 przedstawiony został przykładowy wykres przedstawiający 5 różnych implementacje konwolucyjnych sieci neuronowych tj. Faster R-CNN, R-FCN, SSD Inception, SSD MobileNet oraz YOLO v3 dla uczącego zbioru danych skonstruowane na podstawie 60 klatek całego filmu z przelotu. Ma to na celu łatwiejsze porównanie poszczególnych modeli sieci pomiędzy sobą.




Rys. 6.2. Krzywa AP dla wszystkich analizowanych w badaniu sieci (R-FCN, Faster R-CNN, SSD Inception, SSD MobileNet oraz YOYOLO v3) oraz 60 klatek z filmu z przelotu wzdłuż linii wysokiego napięcia.

Powyższe zestawienie (Rys. 6.2) udowadnia że sieci R-FCN oraz Faster R-CNN najlepiej radzą sobie z niewielką liczbą danych uczących. Na ich podstawie (zbiór uczący wygenerowany na podstawie 60 klatek z przelotu wzdłuż linii wysokiego napięcia) sieci te były w stanie poprawnie wykryć ponad 70% izolatorów energetycznych znajdujących się w testowym zbiorze danych, przy precyzji powyżej 0.79. Pozostałe architektury przedstawione na powyższym wykresie nie osiągnęły tak dobrych rezultatów (maksymalnie 43,40% wykrytych izolatorów). Widać jednak wyraźnie, że zastosowanie zbioru danych składającego się z klatek wybranych równomiernie z całego filmu z przelotu wzdłuż linii wysokiego napięcia miało znaczący pozytywny wpływ na jakość detekcji w stosunku do poprzedniej próby (klatki wybrane z początku filmu z przelotu).

### 6.2.2 Rozszerzona analiza wyników detekcji izolatorów energetycznych z wykorzystaniem sieci: Faster R-CNN i R-FCN


Zważywszy na to, że sieci Faster RCNN oraz R-FCN osiągnęły znacznie lepsze rezultaty niż pozostałe algorytmy właśnie one zostały wytypowane do dalszych dokładniejszych analiz.

Pierwszym krokiem w dalszej analizie było sprawdzenie w jaki sposób przyrost liczby klatek filmu użytych do treningu wpływa na jakość detekcji sieci. W tym celu obydwie sieci zostały powtórnie przetrenowane z wykorzystaniem 5, 10, 15, 20, 25, 30, 35, 40, 45, 50, 55 i 60 klatek. Na zostały przedstawione krzywe AP sieci Faster RCNN dla IoU równego 0.5 przedstawiające wynik działania sieci na zbiorze testowym dla różnej liczby klatek, które wzięły udział w procesie treningowym.



Rys. 6.3. Krzywa Average precision dla sieci Faster RCNN przetrenowanej na 5 do 60 klatkach [ToMO20].

Jak można zauważyć na Rys. 6.3 liczba klatek treningowych, które wzięły udział w procesie uczenia ma znaczący wpływ na jakość detekcji przez sieć Faster R-CNN. Zauważalnie najlepszy wynik miała sieć wytrenowana na zbiorze danych składającym się z 60 klatek treningowych. Należałoby także zauważyć, że zaskakująco dobrze sprawdziły się sieci wytrenowane na 25 i 35 klatkach. Na Rys. 6.4 przedstawiony został analogiczny przypadek przedstawiający wyniki uzyskane dla sieci R-FCN.




Rys. 6.4. Krzywa Average precision dla sieci R-FCN przetrenowanej na 5 do 60 klatkach [ToMO20].

Jak można zaobserwować na Rys. 6.4 krzywe AP dla sieci R-FCN są bardziej wypłaszczone i sięgają dalej wzdłuż osi x niż te dla sieci Faster R-CNN. Można także zauważyć, że zwiększenie liczby klatek nie ma tutaj aż tak ogromnego znaczenia jak miało to miejsce w przypadku sieci Faster R-CNN. W szczególności dobrze jest to widoczne dla sieci

wytrenowanych dla więcej niż 15 klatek. Nie zmienia się tutaj też tak znacząco nachylenie krzywych AP.

W ostatnim kroku analizy sprawdzono zależność pomiędzy wzrostem liczby klatek treningowych, a wartością parametru AP. Uzyskane wyniki przedstawiono na Rys. 6.5. Na rysunku przedstawione zostały także wykresy oraz wzory funkcji dopasowanych do danych pomiarowych wraz z wyliczonymi współczynnikami determinacji.



Rys. 6.5. Wartości average precision (AP) dla sieci Faster RCNN oraz RFCN przetrenowanej na 5 do 60 klatkach w zależności od liczby klatek. Z wyznaczoną linią trendu oraz obliczonym współczynnikiem determinacji  $R^2$  [ToMO20].

Jak można zauważyć na współczynnik determinacji  $R^2$  dla obydwu funkcji jest na podobnym poziomie około 0.94. Nachylenie funkcji dla sieci R-FCN jest nieznacznie mniejsze co oznacza, że w teorii potrzebne jest mniej klatek treningowych, aby otrzymać porównywalny efekt jak dla sieci Faster R-CNN.

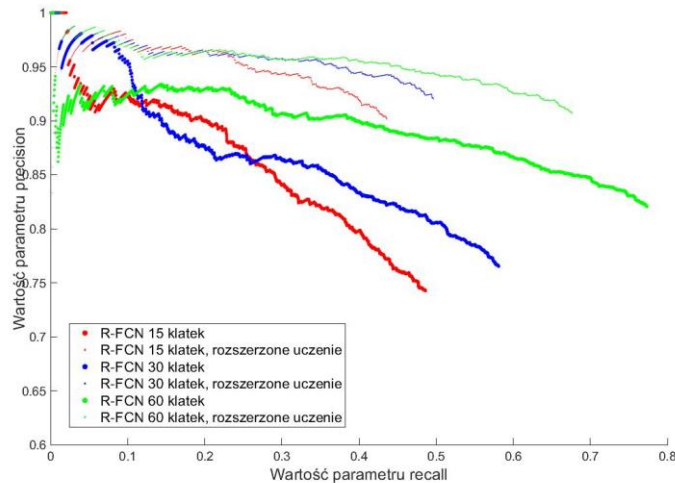
W dalszej części badania sprawdzony był dodatkowo wpływ losowości, która ma miejsce podczas każdego procesu uczenia konwolucyjnych sieci neuronowych. Obydwie wytypowane sieci (R-FCN oraz Faster R-CNN) zostały kolejno trzykrotnie nauczone z wykorzystaniem tych samych 60 klatek wejściowych. Następnie po wykonanym procesie wnioskowania powstałe krzywe AP zestawiono z tymi otrzymanymi uprzednio.

Cztery modele otrzymane w przypadku uczenia sieci R-FCN posiadają bardzo zbliżone kształty. Największą różnicę można zauważyć w początkowej części wykresu, jednakże zanika ona w jego dalszej części. Maksymalna różnica pomiędzy modelami wynosiła: w przypadku parametru AP 0.34%, precision 1.132%, recall 0.23%. Podobnie jak w przypadku sieci R-FCN maksymalne różnice pomiędzy dwoma implementacjami sieci Faster R-CNN były bardzo znikome i wynosiły: AP 0.28%, precision 0.72%, recall 0.11%.

### 6.2.3 Badanie efektów dwuetapowego uczenia sieci konwolucyjnej

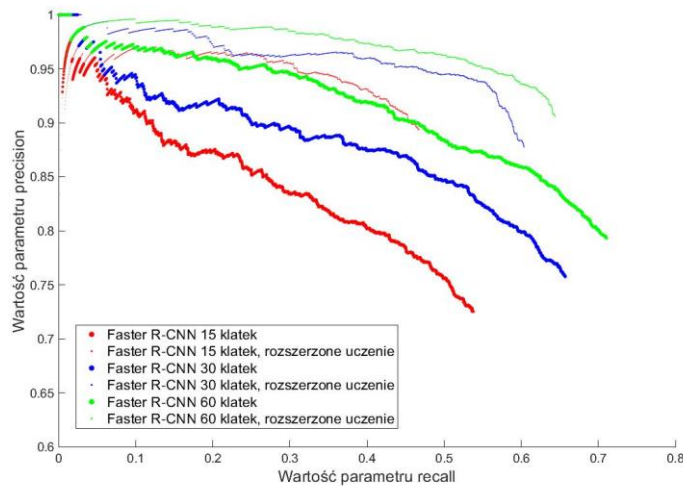
W ostatnim etapie przedstawionych prac wykonana została ostatnia część badania, mająca na celu zbadanie wpływu dostrojenia konwolucyjnych sieci neuronowych z wykorzystaniem danych pozyskanych podczas procesu wnioskowania.

W pierwszym etapie wytypowane sieci (R-FCN i Faster R-CNN) wytrenowano w 20000 kroków odpowiednio dla 15, 30 i 60 klatek zarejestrowanego materiału. Następnie wykonano wnioskowanie i w ten sposób uzyskano zbiór obrazów, które przedstawiały zarówno poszukiwane obiekty oraz inne obiekty, które zostały sklasyfikowane błędnie. Dokonano następnie ręcznej selekcji poprawnie sklasyfikowanych obiektów przyjmując parametr IOU = 0.5, którymi uzupełniono pierwotne zbiory treningowe. Tak przygotowanymi rozszerzonymi zbiorami treningowymi w drugim etapie uczenia dostrojono kolejny raz uzyskane wcześniej modele. Otrzymane rezultaty przedstawiono na Rys. 6.6, Rys. 6.7.



Rys. 6.6. Krzywa AP dla sieci R-FCN przetrenowanej na treningowym zbiorze danych oraz dodatkowo dostrojona (w trzech rozpatrywanych przypadkach (15, 30, 60 klatek) [ToMO20].

Na Rys. 6.6 przedstawiono porównanie krzywych AP uzyskanych dla sieci R-FCN dla modelu otrzymanego dla danych treningowych oraz tego dodatkowo dostrojonego w trzech rozpatrywanych przypadkach (15, 30, 60 klatek). Jak można zauważyć znacząco poprawiła się dokładność detekcji (parametr precision, krzywe znajdują się bliżej prostej  $y=1$ ) lecz nieznacznemu pogorszeniu uległ parametr recall (mniej izolatorów zostało znalezionych).



Rys. 6.7. Krzywa AP dla sieci Faster RCNN przetrenowanej na treningowym zbiorze danych oraz dodatkowo dostrojona (w trzech rozpatrywanych przypadkach (15, 30, 60 klatek) [ToMO20].

Na Rys. 6.7 przedstawiona została analogiczna sytuacja jak na Rys. 6.6, z wynikami uzyskanymi po przebadaniu sieci Faster R-CNN. Również w tym przypadku zauważyć można znaczną poprawę dokładności detekcji (w szczególności dla 15 klatek filmu), jednakże również występuje spadek liczby znalezionych izolatorów. W tym przypadku zmianie uległ także kształt krzywych (30 i 60 klatek), których koniec jest znacznie bardziej skierowany ku dołowi. Dokładnie obliczone parametry average precision, precision oraz recall przedstawione zostały w Tab. 6.2.

Tab. 6.2. Zestawienie wyników pogłębionej analizy zawierające obliczone parametry average precision, precision oraz recall dla sieci Faster RCNN oraz RFCN (15, 30 i 60 klatek) [ToMO20].

Sieć	Liczba klatek	Podstawowe uczenie			Rozszerzone uczenie		
		Parametr AP	Parametr precision	Parametr recall	Parametr AP	Parametr precision	Parametr recall
Faster R-CNN	15	0.4712	0.7251	0.5379	0.4384	0.8933	0.4676
Faster R-CNN	30	0.5714	0.7574	0.6574	0.6105	0.8774	0.6039
Faster R-CNN	60	0.6672	0.7929	0.7105	0.6221	0.9061	0.6445
R-FCN	15	0.4060	0.7424	0.4863	0.4368	0.9015	0.4363
R-FCN	30	0.4852	0.7650	0.5813	0.4402	0.9204	0.4969
R-FCN	60	0.6609	0.8206	0.7738	0.6109	0.9068	0.6766

Wartość parametru AP nie jest ostatecznym wyznacznikiem, który z analizowanych przypadków 15, 30, 60 daje lepsze wyniki. Warto jednak odnotować, iż w wyniku pogłębionego badania uzyskano w każdym z przypadków poprawę wartości parametru precision. Dla sieci Faster R-CNN poprawa wynosiła odpowiednio: 23.19%, 15.84%, 14.27%, a dla sieci R-FCN odpowiednio o: 21.44%, 20.31%, 10.50%. Natomiast pogorszeniu uległ parametr recall – dla sieci Faster R-CNN odpowiedni o: 13.07%, 8.14%, 9.29%, a dla sieci R-FCN odpowiednio o: 10.28%, 14.52%, 12.57%.

## 7. Podsumowanie i wnioski

Celem niniejszej pracy było opracowanie metody umożliwiającej automatyczne wykrywanie izolatorów linii wysokiego napięcia na obrazach cyfrowych z wykorzystaniem metod przetwarzania oraz rozpoznawania obrazów. Powyższy cel został zrealizowany poprzez opracowanie, implementację oraz analizę przedstawionych w pracy metod oraz narzędzi.

W pracy zaproponowane zostały metody umożliwiające detekcję izolatorów linii wysokiego napięcia. Metody oraz narzędzia, które stanowiły bazę dla zaproponowanych w pracy rozwiązań, zostały wytypowane na podstawie przeprowadzonego studium literaturowego. Opracowane metody oraz narzędzia zostały zweryfikowane na podstawie zestawów zdjęć badanego obiektu (izolatora energetycznego), które pozyskano dzięki wykorzystaniu skonstruowanego stanowiska badawczego oraz podczas przelotu wzdłuż linii wysokiego napięcia.

Do innowacyjnych rozwiązań zaprezentowanych w ramach pracy, według wiedzy autora, należą:

1. Zastosowanie różnego rodzaju algorytmów filtracji przestrzennej, do celów poprawy jakości detekcji cech kluczowych z wykorzystaniem algorytmu detekcji i opisu cech. Ze szczególnym uwzględnieniem izolatorów linii elektroenergetycznej. Zbadanie wpływu filtracji przestrzennej na miejsce (konkretny obiekt – izolator ) detekcji cech kluczowych z wykorzystaniem algorytmu SURF.
2. Zaproponowanie metody oceny wpływu filtracji przestrzennej na jakość detekcji cech kluczowych izolatora energetycznego z wykorzystaniem algorytmu SURF.
3. Zaproponowanie parametru LPR (częstości występowania cech kluczowych w obrazach z uczącego zbioru danych) jako wskaźnika określającego przydatności cechy dystynktywnej do celów detekcji izolatorów.
4. Opracowanie oraz implementacja algorytmu opartego o parametry LPR oraz Ratio służącego do konstruowania worka cech kluczowych izolatora energetycznego.
5. Porównanie jakości detekcji izolatorów energetycznych z wykorzystaniem nowoczesnych modeli sieci neuronowych z oraz ograniczonego zbioru danych uczących w zdefiniowanym scenariuszu badawczym (przelot wzdłuż linii wysokiego napięcia)
6. Przebadanie wpływu wielkości treningowego zbioru danych (ilości klatek wejściowych) na jakość i skuteczność detekcji izolatorów linii elektroenergetycznej przez modele opracowane na podstawie sieci Faster R-CNN oraz R-FCN.
7. Udowodnienie, że w określonych warunkach jest możliwe wykorzystanie ograniczonego zbioru danych (60 klatek wejściowych) do celów skutecznej detekcji izolatorów energetycznych na obrazach cyfrowych.

W trakcie realizacji pracy konieczne było wykorzystanie różnego rodzaju środowisk programistycznych (tj. Python, MathWorks MATLAB®, National Instruments LabVIEW) do celów implementacji opracowanych metod oraz do celów ich późniejszej analizy. W ramach niniejszej pracy Autor:

1. Współuczestniczył w skonstruowaniu stanowiska badawczego umożliwiającego zebranie dokumentacji fotograficznej izolatorów energetycznych w różnych warunkach oświetleniowych, na zróżnicowanym tle oraz pod zmiennymi kątami.
2. Zaimplementował w środowisku programistycznym metodę oceny wpływu filtracji przestrzennej na jakość detekcji cech kluczowych izolatora linii wysokiego napięcia.
3. Opracował oraz zaimplementował w środowisku programistycznym metody służące do tworzenia worka cech na podstawie parametrów LPR oraz Ratio z wykorzystaniem algorytmu detekcji i opisu cech kluczowych.
4. Opracował i zaimplementował oprogramowanie umożliwiające stworzenie ściśle ograniczonego zbioru danych uczących dla potrzeb detekcji izolatorów z wykorzystaniem konwolucyjnych sieci neuronowych, a także zaimplementował w środowisku programistycznym narzędzia służące do oceny wpływu wielkości zbioru danych uczących na jakość i skuteczność detekcji.

**Biorąc pod uwagę przedstawione efekty teoretyczne i praktyczne przedstawionych badań oraz wyniki analiz otrzymane dzięki implementacji przedstawionych metod, teza pracy: „Możliwa jest skuteczna detekcja izolatorów linii elektroenergetycznej w złożonej scenie na obrazach cyfrowych rejestrowanych przy użyciu BSP z wykorzystaniem systemów przetwarzania obrazów cyfrowych także przy zastosowaniu ograniczonego zbioru danych uczących” została udowodniona.**

W trakcie realizacji celów pracy konieczne było rozwiązanie innych problemów, których nie zakładano podczas przeprowadzenia studium literaturowego. Były to między innymi:

1. Pozyskanie obrazów umożliwiających przeprowadzenie badań. W trakcie wykonania analiz niezbędne było posiadanie materiału badawczego, który jest zbliżony do tego, który jest pozyskiwany podczas inspekcji linii wysokiego napięcia przez zespoły eksperckie. W początkowej fazie badań, a także do celów stworzenia wzorca izolatora skonstruowane zostało specjalne stanowisko badawcze dzięki, któremu pozyskano niezbędne dane badacze. W późniejszym etapie przeprowadzony został oblot linii wysokiego napięcia, dzięki czemu pozyskano wystarczającą ilość obrazów o parametrach zbliżonych do tych otrzymywanych podczas przelotów kontrolnych.
2. Opracowanie metod oceny wpływu filtracji na jakość oraz skuteczność detekcji cech kluczowych izolatorów. Analiza wpływu metod filtracji, a także jej wizualizacja były elementami kluczowymi podczas procesu oceny detekcji cech kluczowych. Konieczne było wzięcie pod uwagę wpływu zastosowania określonego filtra na udział procentowy cech znalezionych na izolatorze dla każdej z nastaw filtra, a także całkowitą liczbę cech wykrytą przed i po filtracji.
3. Opracowanie metod oceny wpływu wielkości oraz jakości worka cech dystynktywnych budowanego na podstawie parametrów Ratio i LPR na jakości detekcji cech izolatora. Ocena wpływu nastaw parametrów Ratio oraz LPR, a także samej metody na jakość i skuteczność detekcji była zadaniem złożonym. Konieczne było przyjęcie pewnych poziomów (np. liczby znalezionych cech), aby w kolejnym kroku możliwa była jego prawidłowa detekcja. Poza tym niemożliwe było stwierdzenie jaki wpływ ma każdy z podanych parametrów osobno. W pracy zaprezentowany został szeroki zbiór analiz, który według autora może w pozwolić na dokładną analizę metody, a także dobór odpowiednich parametrów.
4. Problemy wyboru klatek wchodzących w skład uczących zbiorów danych. Do stworzenia treningowego zbioru danych na potrzeby uczenia konwolucyjnych sieci neuronowych. Konieczne było opracowanie metody oraz narzędzia selekcji klatek z filmu wideo. Istotną kwestią okazało się być ich równomierne rozmieszczenie w całości filmu z przelotu. W pracy zaprezentowano między innymi porównanie detekcji izolatorów z wykorzystaniem różnego rodzaju konwolucyjnych sieci neuronowych wyuczonych na podstawie początkowych oraz równomiernie wybranych klatek filmu.
5. Etykietowanie bardzo dużej liczby obrazów (testowe i treningowe zbiory danych). Oprócz wyboru klatek tj. podzielnia wszystkich danych wizyjnych na testowe oraz treningowe, niezbędne było ich ręczne etykietowanie. Biorąc pod uwagę liczbę obiektów znajdujących się na klatkach wideo, niezbędnym okazało się wykorzystanie

dedykowanego narzędzia umożliwiającego szybkie oraz dokładne etykietowanie zdjęć, tj. LabelImg lub Labelbox.

Na podstawie przeprowadzonych badań, analiz oraz danych otrzymanych podczas badań stworzona została lista wniosków dotyczących detekcji izolatorów linii wysokiego napięcia na obrazach cyfrowych:

1. Możliwa jest poprawa jakości detekcji z wykorzystaniem algorytmu SURF poprzez zastosowanie odpowiednich metod filtracji przestrzennej. Zaprezentowane w pracy algorytmy filtracji przestrzennej pozwoliły w wielu przypadkach na znaczące podniesienie udziału cech wykrywanych na izolatorze w stosunku do znajdujących poza nim. Można domniemywać, że dobranie odpowiedniej metody filtracji wstępnej (rodzaj i nastawy filtra) może pozwolić na znaczące podniesienie skuteczności detekcji cech kluczowych.
2. Budowanie worka cech dystynktywnych jest możliwe na podstawie zastosowania metod selekcji cech opartych o parametry LPR oraz Ratio. W odróżnieniu od standardowego podejścia do budowania worka cech tj. z wykorzystaniem algorytmu centroidów (z ang. *k-means clustering*) zastosowanie algorytmu opartego o częstość występowania cech dystynktywnych pozwala dobrać cechy, które najlepiej opisują obiekt detekcji tj. spełniające określone kryteria (poziom dopasowania cech w worku oraz częstość ich występowania we wszystkich obrazach wzorcowych).
3. Kluczowym elementem poza wybraniem odpowiedniej metody detekcji jest skonstruowanie właściwie zbudowanego uczącego zbioru danych. Jak pokazano w badaniach oprócz wielkości zbioru uczącego duże znaczenie ma jego zawartość. Właściwe dobranie obrazów pozwala sieci neuronowej na odpowiednie zgeneralizowanie danych, a co za tym idzie wykrycie większej ilości obiektów (w tym przypadku izolatorów energetycznych).
4. Na podstawie przeglądu literaturowego oraz badań własnych stwierdzono, że jakość detekcji generowanych przez konwolucyjne sieci neuronowe znacząco wyprzedza te generowane przez inne algorytmy detekcji obiektów. Dzięki umiejętności generalizacji wiedzy sieci neuronowe są skuteczniejsze niż inne metody i narzędzia wykorzystywane do detekcji obiektów. Klasyczne algorytmy detekcji i opisu cech nie posiadają skuteczności zbliżonej do tej uzyskiwanej przez detektory budowane przy użyciu konwolucyjnych sieci neuronowych.
5. Zastosowanie ograniczonego zbioru cech uczących, takiego który mógłby zostać łatwo stworzony przez osobę dokonującą inspekcji linii, może pozwolić na otrzymanie wysokiego poziomu jakości detekcji. Jak wykazano możliwe jest stworzenie skutecznego detektora obiektów (izolatorów energetycznych) z wykorzystaniem konwolucyjnych sieci neuronowych oraz metod uczenia głębokiego. Detektor taki może zostać wyuczony z wykorzystaniem niewielkiego zbioru danych, który został poddany procesowi etykietowania niedużym nakładem pracy.

## 8. Bibliografia

- [DLHS16] Dai J., Li Y., He K., and Sun J., *R-FCN: Object Detection via Region-based Fully Convolutional Networks*, no. Nips, 2016.
- [Girs15] Girshick R., *Fast R-CNN*, Proceedings of the IEEE International Conference on Computer Vision, vol. 2015 Inter, pp. 1440–1448, 2015.
- [GDDM14] Girshick R., Donahue J., Darrell T., and Malik J., *Rich feature hierarchies for accurate object detection and semantic segmentation*, Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 580–587, 2014.
- [KaPe10] Katra J. and Pernu F., *A Survey of Mobile Robots for Distribution Power Line Inspection*, Ieee Transactions on Power Delivery, vol. 25, no. 1, pp. 485–493, 2010.
- [LAES16] Liu W. *et al.*, *SSD: Single shot multibox detector*, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), vol. 9905 LNCS, pp. 21–37, 2016.
- [PaHT13] Pagnano A., Höpf M., and Teti R., *A roadmap for automated power line inspection. Maintenance and repair.*, Procedia CIRP, vol. 12, pp. 234–239, 2013.
- [ReFa18] Redmon J. and Farhadi A., *YOLOv3 : An Incremental Improvement*, 2018.
- [RHGS16] Ren S., He K., Girshick R., and Sun J., *Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks*, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 39, no. 6, pp. 1137–1149, 2016.
- [ScRB13] SCHMID C., ROGER MOHR, and BAUCKHAGE C., *Evaluation of Interest Point Detectors CORDELIA*, 2013 IEEE/ACIS 12th International Conference on Computer and Information Science, ICIS 2013 - Proceedings, vol. 37, no. 2, pp. 443–447, 2013.
- [ToOD18] Tomaszewski M., Osuchowski J., and Debita Ł., *Effect of Spatial Filtering on Object Detection with the SURF Algorithm*, vol. 720. 2018.
- [ToMO20] Tomaszewski M., Michalski P., and Osuchowski J., *Evaluation of Power Insulator Detection Efficiency with the Use of Limited Training Dataset*, Applied Sciences, vol. 10, no. 6, p. 2104, 2020.
- [WaZh16] Wang X. and Zhang Y., *Insulator identification from aerial images using Support Vector Machine with background suppression*, 2016 International Conference on Unmanned Aircraft Systems, ICUAS 2016, pp. 892–897, 2016.
- [WuAn14] Wu Q. and An J., *An active contour model based on texture distribution for extracting inhomogeneous insulators from aerial images*, IEEE Transactions on Geoscience and Remote Sensing, vol. 52, no. 6, pp. 3613–3626, 2014.
- [ZLSL12] Zhao J., Liu X., Sun J., and Lei L., *Detecting insulators in the image of overhead transmission lines*, Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), vol. 7389 LNCS, pp. 442–450, 2012.

### Wybrane publikacje doktoranta:

- [1] Osuchowski J., Michalski P.: *Analiza powierzchni paneli fotowoltaicznych z wykorzystaniem metod wizyjnych*, Energetyka w odsłonach,
- [2] Zator S., Michalski P., Osuchowski J.: *Analiza elementów przęśla elektroenergetycznego na podstawie danych LIDAR*, Diagnostyka procesów inwestycyjnych i eksploatacyjnych wybranych urządzeń energetycznych,

- [3] Osuchowski J., Szymocha S., *Microsoft Kinect Measurement Accuracy for Different Shapes of Objects*, WOFEX 2016,
- [4] Szymocha S., Osuchowski J.: *The Use of Glass with PDLC Film in Active Dimming Systems*, WOFEX 2016,
- [5] Zator S., Michalski P., Osuchowski J.: *Analiza elementów przęsla elektroenergetycznego na podstawie danych LIDAR*, Nowa Energia 2(50)/2016,
- [6] Zator S., Michalski P., Osuchowski J.: *Analiza elementów przęsla elektroenergetycznego na podstawie danych ALS*, Nowa Energia 2(50)/2016,
- [7] Osuchowski J.: *Detekcja izolatorów linii wysokiego napięcia z wykorzystaniem metod przetwarzania obrazu*, IX Interdyscyplinarna Konferencja Naukowa TYGIEL 2017 „Interdyscyplinarność kluczem do rozwoju”,
- [8] Osuchowski J.: *Computer aided analysis of studio microphones characteristics*, Zeszyty Naukowe nr 360/2016, Elektryka z. 72,
- [9] Osuchowski J.: *Badanie oraz analiza charakterystyk Mikrofonów studyjnych*, Zeszyty naukowe Politechniki Opolskiej z. 74,
- [10] Osuchowski J.: *Receiving and processing point clouds from Microsoft Kinect sensor*, Zeszyty naukowe Politechniki Opolskiej z. 74,
- [11] Michalski P., Osuchowski J.: *Analiza powierzchni paneli fotowoltaicznych z wykorzystaniem metod wizyjnych*, Europejski wymiar bezpieczeństwa energetycznego Polski a ochrona środowiska,
- [12] Osuchowski J.: *Insulator detection based on hog features descriptor*, Przegląd Naukowo-Medyczny. X Nr 1/2017 (34),
- [13] Michalski P., Osuchowski J.: *Diagnostics of the photovoltaic panels using hybrid image data model*, Przegląd Naukowo-Medyczny. X Nr 1/2017 (34),
- [14] Osuchowski J.: *Przegląd metod diagnostycznych izolatorów linii napowietrznej*, Energetyka Bezpieczeństwo w wyzwaniach badawczych,
- [15] Michalski P., Osuchowski J.: *Możliwości inspekcji elementów linii wysokiego napięcia z wykorzystaniem metod przetwarzania obrazu*, Przegląd Naukowo-Medyczny. X Nr 1/2017 (34)
- [16] Osuchowski J.: *Object localization and features determination based on the point cloud data*, Techniki Wytwarzania, Technologia wytwarzania,
- [17] Osuchowski J.: *Detection of ceramic insulators using color Thresholding*, Zeszyty Naukowe Politechniki Opolskiej Elektryka z. 75,
- [18] Osuchowski J.: *Overhead Line Insulator Detection Using Surf Algorithm*, Zeszyty Naukowe Politechniki Opolskiej Elektryka z. 75,
- [19] Osuchowski J.: *Algorithms Comparison for Electrical Insulator Key Features Detection*, WOFEX 2017, Faculty of Electrical Engineering and Computer Science, VSB – Technical University of Ostrava,
- [20] Osuchowski J.: *Detekcja izolatorów linii wysokiego napięcia z wykorzystaniem metod przetwarzania obrazu*, Współczesne problemy elektrotechniki oraz rozwój i ewaluacja procesów technologicznych,
- [21] Osuchowski J.: *Detekcja uszkodzeń izolatorów linii elektroenergetycznej z wykorzystaniem metod wizyjnych*, Nowa Energia nr 2(62)/2018,

- [22] Osuchowski J., Michalski P., Ruszczak B.: *Ocena możliwości klasyfikacji, lokalizacji i detekcji obiektów na obrazach cyfrowych*, Nowa Energia nr 2(62)/2018,
- [23] Osuchowski J.: *Diagnostyka wizyjna przewodów linii wysokiego napięcia*, Przegląd Naukowo-Metodyczny XI 1/2018 (38)
- [24] Tomaszewski M., Osuchowski J., Debita Ł.: *Effect of Spatial Filtering on Object Detection with the SURF Algorithm*, Advances in Intelligent Systems and Computing,
- [25] Osuchowski J.: *Możliwości diagnostyki wizyjnej konstrukcji wsporczych linii wysokiego napięcia*, Przegląd Naukowo-Metodyczny XI 1/2018 (38)
- [26] Osuchowski J.: *Analiza otoczenia linii wysokiego napięcia z wykorzystaniem Obrazowania multispektralnego*, Przegląd Naukowo-Metodyczny XI 1/2018 (38)
- [27] Osuchowski J.: *Detekcja uszkodzeń izolatorów linii elektroenergetycznej z wykorzystaniem pojazdów UAV*, Badania i Rozwój Młodych Naukowców w Polsce Nauki techniczne i inżynierskie
- [28] Osuchowski J.: *Diagnostyka farm fotowoltaicznych z wykorzystaniem metod wizyjnych*, Badania i Rozwój Młodych Naukowców w Polsce Nauki techniczne i inżynierskie
- [29] Osuchowski J.: *Detekcja uszkodzeń izolatorów linii elektroenergetycznej z wykorzystaniem pojazdów UAV*, Badania i Rozwój Młodych Naukowców w Polsce 2017 Materiały Konferencyjne – jesień Część III - Wrocław
- [30] Osuchowski J.: *Spectral analysis of high-voltage lines Surroundings*, WOFEX 2018, Faculty of Electrical Engineering and Computer Science, VSB – Technical University of Ostrava
- [31] Szymocha S., Osuchowski J.: *Pomiary przy pomocy bezzałogowych statków powietrznych / Diagnostyka linii wysokiego napięcia*, 2019,
- [32] Tomaszewski M., Michalski P., Osuchowski J.: *Evaluation of Power Insulator Detection Efficiency with the Use of Limited Training Dataset*, Appl. Sci., 10(6), 2104, 2020.