



Kraków, 15 sierpnia 2021

*Prof. zw. dr hab. inż. Witold Dzwiniel*

*Katedra Informatyki AGH,*

*Wydział Informatyki Elektroniki i Telekomunikacji,*

*Akademia Górniczo-Hutnicza im. Stanisława Staszica w Krakowie*

## Recenzja

Przedmiotem recenzji jest rozprawa doktorska Pana **mgr inż. Macieja Pawelczyka** pt. „**Aviation Engineering Applications of Artificial Intelligence for UAV Detection and Gas Turbine Predictive Maintenance**”. Promotorem rozprawy jest Pan dr hab. Marek Wojtyra, prof.n. PW. Recenzję opracowałem na wniosek Rady Naukowej Dyscypliny Inżynieria Mechaniczna Wydziału Matematyki Informatyki i Mechaniki Politechniki Warszawskiej.

### **1. Dziedziny i dyscypliny nauki związane z tematyką rozprawy**

Tematyka rozprawy doktorskiej, która jest przedmiotem tej recenzji, dotyczy dziedziny nauk inżynieryjno-technicznych oraz bezpośrednio, dyscypliny inżynieria mechaniczna. Dysertacja jest jednak pracą interdyscyplinarną, wykorzystującą metody sztucznej inteligencji w wybranych problemach inżynierii mechanicznej. Zatem związana jest też bardzo silnie z dyscypliną informatyka techniczna i telekomunikacja. Zgodnie z taksonomią dyscyplin naukowych wykorzystywaną przez Narodowe Centrum Nauki (NCN) – odpowiada ona panelowi dziedzinowemu ST8 (Inżynieria Procesów i Produkcji), a także panelowi ST6 (Informatyka i Technologie Informacyjne), w szczególności pod-tematowi ST6.11 (uczenie maszynowe, statystyczne przetwarzanie danych i zastosowanie w przetwarzaniu sygnałów).

## **2. Istotność podejmowanej tematyki, jakość postawionych tez, nowatorstwo i inne walory pracy**

### **2.1. Istotność tematyki rozprawy**

Rozpoznawanie obiektów jest jednym z podstawowych zadań sztucznej inteligencji (SI). Problematyka ta należy do domeny SI: rozpoznawanie obrazów, stanowiącej wraz z uczeniem maszynowym podstawową bazę algorytmiczną związaną z inżynierią cech oraz klasyfikacją i regresją. Problemy rozpoznawania złożonych struktur (np. twarzy konkretnej osoby w tłumie) i niejednoznacznych oraz niepewnych obiektów 3D na równie złożonym i niejednolitym tle (detekcja i rozpoznawanie statków powietrznych, interpretacja obrazów medycznych etc.) należą do szerokiej klasy zadań nierozstrzygalnych w których jakość decyzji, w ogólnym przypadku, nie jest imponująca. Problem rozpoznawania bezzałogowych statków powietrznych w tym dronów, zdecydowanie należy do tego typu zadań. Jak wynika z dostępnej szerokiej literatury przedmiotu, a także dobrze napisanej motywacji ocenianej dysertacji, od czasu istnienia dronów i różnych pól ich zastosowań zaczęły powstawać różne systemy ich detekcji. Zdecydowanie na pierwszy plan wysuwa się zastosowania militarne tego typu systemów, a także inne „pokojowe” zastosowania, zabezpieczające teren i obiekty chronione przed ich penetracją przez niechciane drony. Systemy te bazują na różnych kanałach informacyjnych: dźwięku, falach radiowych, krótkich migawkach filmowych, zdjęciach w świetle naturalnym, podczerwieni itp. Istnieją oczywiście hybrydowe systemy wojskowe stosujące analizę wielokanałową. O wadze tego tematu świadczy ilości trafień w bazie GoogleScholar dla terminów: „drone detection”, pattern recognition, machine learning”. Od roku 2020 znalazłem ponad 450 trafień, natomiast bez ograniczenia czasowego 850. Wskazuje to na rosnącą wagę tej tematyki. Dużą część z najbardziej cytowanych artykułów stanowią te poświęcone detekcji dronów ze zdjęć – migawek. Jest to zdecydowanie najtańszy z kanałów informacyjnych, ale ze względu na złożoność jego analizy, według mnie, raczej drugoplanowy i uzupełniający. Wynika to chociażby z faktu, iż najgroźniejsze w kontekście bezpieczeństwa są wtargnięcia dronów pod wieczór i nocą, kiedy klasyczne kamery stają się bezużyteczne.

Tematyka doktoratu związana z detekcją dronów na zdjęciach (migawkach) jest trudnym i ważnym zagadnieniem współczesności. Wytworzone nowe metodologie i narzędzia mogą być wykorzystane w wielu podobnych problemach (rozpoznawanie ptaków, detekcja przemiesz-

czających się pojazdów, osób, statków etc.), biorąc jednak po uwagę specyficzne własności każdego z analizowanych danych.

Drugim z problemów poruszanych w pracy jest wykorzystanie nowoczesnych metod uczenia maszynowego – tym razem regresji – w niedestruktywnej i predyktywnej diagnostyce złożonych systemów. To zastosowanie analizy sygnałów, rozpoznawania obrazów i uczenia maszynowego ma, w przeciwieństwie do poprzedniej tematyki, bardzo długą historię i niezwykle szeroką literaturę. Generalnie celem jest wskazanie parametrów urządzenia, które ulegają degradacji w trakcie jego eksploatacji, ich optymalny dobór do określonych reżimów pracy oraz przewidywanie zarówno zużycia jak i optymalizacja predyktywna zarówno czasu eksploatacji jak i parametrów pracy (istnieją także innego typu zastosowania). Dawniej polegało to głównie na analizie szeregów czasowych generowanych przez czujniki, natomiast nowoczesne metody wykorzystują do tego złożone modele danych (np. uczenie ze wzmocnieniem, różne architektury sieci neuronowych przeznaczone do analizy szeregów czasowych np. reservoir computing), a także formalne modele matematyczne i komputerowe urządzeń wykorzystujące wyszukane algorytmami asymilacji danych. Dysertacja koncentruje się na problemie pokrewnym i dotyczy wirtualnego wyznaczenia, trudnego do zmierzenia parametru decydującego o prawidłowej pracy turbiny. Zaproponowany model, bazujący na danych z innych turbin, ma na celu określenie stanu eksploatowanego urządzenia i oszacowaniu, kiedy należy przeprowadzić konserwację turbiny. Zaprężenie do tego celu współczesnych narzędzi uczenia maszynowego jest ważną, nośną i przyszłościową tematyką. Wskazanie na konkretną metodologię i zdefiniowanie sposobu jej zastosowania do predyktywnej konserwacji określonych, ważnych i złożonych technologicznie urządzeń może znacznie zoptymalizować koszty ich utrzymania poprzez poprawę parametrów pracy i wydłużenie czasu ich eksploatacji.

Podsumowując, tematyka podejmowana w pracy jest aktualna i podlegająca szybkiej ewolucji, a otrzymane wyniki mogą mieć wpływ na rozwój zarówno dyscypliny inżynieria mechaniczna jak i informatyka techniczna. Mają one także bardzo duży potencjał wdrożeniowy.

## **2.2. Teza i cele pracy**

Dysertacja składa się z dwóch oddzielnych, nierównych objętościowo i jakościowo części, nieposiadających jakiegoś wspólnego mianownika pozwalającego taką tezę (wystarczająco

szczegółową, jak na dysertację doktorską) sformułować. W przypadku prac doktorskich o charakterze aplikacyjnym w dziedzinie nauk inżynieryjno-technicznych, brak tezy jest już regułą. Teza w postaci, że coś się „nadaje” (patrz str.31) jest tezą zbyt ogólną i z reguły zawsze prawdziwą co dowodzą zazwyczaj wcześniej opublikowane prace i ... intuicja. W zamian, dysertacja posiada klarownie zdefiniowane cele oraz zadania cząstkowe, konsekwentnie realizowane w ramach zaproponowanych badań, posiadające uzasadnioną kolejność i pokazujące, że Kandydatowi dobrze znane są dobre praktyki prowadzenia badań naukowych.

Podsumowując, cele dysertacji oraz poszczególne zadania cząstkowe związane z realizacją badań są jasne i konsystentne. Ten podstawowy szkielet dysertacji, uzasadnia zaliczenie prowadzonych prac jako prac badawczych posiadających walory poznawcze.

### **2.3 Nowatorstwo zaproponowanych rozwiązań**

Dysertacja ma charakter aplikacyjny i reprezentuje osiągnięcia w dwóch pokrewnych dyscyplinach: inżynierii mechanicznej i informatyce technicznej. Jej bezpośrednie rezultaty oraz zebrane dane, tj. sposób akwizycji danych, tworzenie reprezentacji danych do dalszej analizy, dotyczą tej pierwszej, zaś narzędzia analizy danych związane są z uczeniem maszynowym, które jest domeną informatyki (zarówno tej bez przymiotnikowej jak i technicznej). Do nowatorskich elementów związanych z dyscypliną inżynieria mechaniczna należy zaliczyć następujące rezultaty prowadzonych badań.

1. Stworzenie od podstaw bazy danych do detekcji dronów, wymagające znajomości problematyki związanej z ich budową i charakterem ich wykorzystania. Zarówno inżynieria cech jak i metodologia etykietowania próbek danych wymaga zazwyczaj wiedzy dziedzinowej. Od definicji cech i przygotowania danych zależy przyszły sukces czy porażka stosowania algorytmów rozpoznawania obrazów. Uważam, że zastosowanie odpowiedniej i szybkiej metodologii pozyskiwania i etykietowania danych, stworzenie i opublikowanie unikalnego, publicznie dostępnego zbioru danych jest elementem nowatorskim dysertacji w dyscyplinie inżynieria mechaniczna.
2. W celu uzyskania jak najbardziej efektywnych i optymalnych rozwiązań zadań dysertacji – tj. stworzenia jak najdokładniejszych systemów rozpoznawania dronów oraz efektywnych i skutecznych monitorowania i predykcyjnej konserwacji turbin – dopa-

sowanie do ich specyfiki, metodologii klasyfikacji i predykcji, odpowiednich architektur sieci neuronowych oraz metaparametrów proponowanych systemów, stanowi także nowatorski element pracy związany z dyscypliną inżynieria mechaniczna.

3. Podobnie, z inżynierią mechaniczną związane są badania i ich rezultaty związane z zaproponowaniem efektywnego systemu do analizy i monitoringu oraz diagnostyki predykcyjnej turbiny gazowej. Szczególnie ciekawa i wymagająca wiedzy w tej dyscyplinie jest zastosowana metodologia inżynierii cech. Bazując na wiedzy domenowej dotyczącej turbin gazowych Autora (a także inżynierów konstruktorów z nim współpracujących, którzy byli w stanie ocenić współczynnik korelacji pomiędzy zmiennymi, estymatory „ważności” cech) był on w stanie zredukować zbiór cech do „najlepszych”. W ten sposób uzyskał zbiór 21-wymiarowy składający się z 653056 próbek. Bazując na tym zbiorze danych Autor stworzył model turbiny bazujący na danych.

System rozpoznawania i detekcji dronów wykorzystujący najnowsze metodologie w dziedzinie uczenia maszynowego sam w sobie jest także nowatorskim rozwiązaniem dotyczącym dyscypliny informatyka techniczna. Należy podkreślić wysoką – na granicy lub ponad SOTA - efektywność i skuteczność zarówno systemu do detekcji dronów jak i systemu do monitoringu turbiny gazowej.

#### **2.4 Inne walory pracy**

Oprócz nowatorskich elementów pracy wyszczególnionych powyżej, niezwykle interesującej i nowoczesnej tematyki podejmowanych badań, praca posiada także inne walory. Stanowi ona dojrzałe dzieło naukowe reprezentujące konsekwentny wywód prowadzący od założeń, definicji problemu naukowego, stworzenia unikalnego zbioru danych poprzez alternatywne próby jego rozwiązania, aż do eksperymentów oraz dyskusji ich rezultatów w kontekście wyznaczonych celów naukowych. W swojej monografii Autor wnikliwie przedstawia tło prowadzonych prac. Rozbudowany rozdział dotyczący motywacji i aktualnych rozwiązań jest naprawdę bardzo rzetelny i ciekawy.

Osobnym interesującym elementem pracy jest bardzo rozbudowany i dobrze napisany wstęp (2. Research Background), który sam w sobie mógłby zostać wydany jako popularno-

naukowy blog dotyczący metod i algorytmów współczesnego uczenia maszynowego. Jest to jednak także element kontrowersyjny pracy do czego nawiążę w dalszej części recenzji.

Należy podkreślić także ogromny wysiłek doktoranta w: (a) przygotowanie w sposób półautomatyczny (a czasem manualny) unikalnego dużego zbioru danych, (b) zaproponowanie ciekawej metodologii jego etykietowania, a także (c) znaczny czas obliczeniowy świadczący o wnikliwości prowadzonych eksperymentów komputerowych potrzebnych do realizacji eksperymentów obliczeniowych i realizacji planu badań. Z uznaniem podchodzę także do nieprześcietnej wiedzy Kandydata w zakresie uczenia maszynowego, której nabycie wymagało czasu, podobnie jak doświadczenia w operowaniu złożonymi narzędziami i infrastrukturą informatyczną.

Dysertacja posiada czytelną i logiczną ogólną strukturę. Zrealizowana jest na dobrym edycyjnym poziomie. Język angielski pracy jest poprawny i klarowny. Zwracają uwagę staranne, w większości czytelne, a czasem bardzo złożone rysunki i wykresy samodzielnie opracowane przez Autora oraz bardzo bogata (ok 300 pozycji), aktualna i dobrze wyselekcjonowana literatura przedmiotu istotna dla podejmowanej tematyki badawczej.

### **3. Krytyczne, kontrowersyjne i dyskusyjne elementy pracy**

Rozdział ten będzie obszerniejszy od poprzedniego opisującego walory pracy, tylko ze względu na większą szczegółowość poruszanych zagadnień. Praca nie posiada krytycznych elementów obniżających w sposób drastyczny jej jakości. Posiada jednak pewne wady dotyczące jej szczegółowej struktury, a także szczegółowe niejasności i niedopowiedzenia. Zawiera także fragmenty wymagające szerszej dyskusji, zarówno w trakcie jej obrony jak i w przygotowywanych późniejszych publikacjach.

#### ***3.1 Kontrowersyjne elementy szczegółowej struktury dysertacji***

Monografia zawiera dwie oddzielne i nierównoważne pod względem jakości i szczegółowości części. Jedna dotyczy detekcji dronów druga zagadnień predykcji konserwacji (ang. predictive maintenance) turbiny gazowej. Są to dwie różne klasy zagadnień. W obu przypadkach Kandydat używa także różnych narzędzi informatycznych. Skala złożoności i czasu trwania obliczeń wydaje się także zdecydowanie różna. Nierównowaga tematyczna dotyczy także jakości

poszczególnych części. Jeżeli pierwsza, dotycząca detekcji dronów może sama w sobie stanowić treść dobrej pracy doktorskiej, druga może być wykorzystana jako materiał na publikację i może zapoczątkować oddzielny nurt badań. Brakuje jakiegokolwiek spinającej te dwa zagadnienia idei (oczywiście, spina je bardzo ogólna, stąd kompletnie „niedysertabilna”, teza związana z możliwościami wykorzystania w obu przypadkach nowoczesnych narzędzi SI).

Jak podkreśliłem w poprzednim rozdziale, dysertacja zawiera dobrze napisany wstęp dotyczący współczesnych narzędzi uczenia maszynowego. Jest on jednak zarówno walorem jak i niepotrzebnym obciążeniem pracy. Jest on zbyt szeroki by stanowić część monografii doktorskiej, gdyż zawiera opisy (przegląd) nie tylko wykorzystywanych, ale także w ogóle nie wykorzystywanych w pracy metodologii uczenia maszynowego (UM). Powoduje to zbędne „spuchnięcie” objętości pracy. Nie wiadomo dla kogo ten fragment pracy został napisany.

Problem ze zbyt dużą objętością pracy związany jest także z językiem pracy. Kandydat skutecznie unika (lub używa w niewystarczającym stopniu) lapidarnego języka definicji, diagramów, tabelaryzacji opisów (danych, sprzętu, architektur NN etc.), pseudokodów, oznaczeń i formalizmów matematycznych. Powoduje to, że pracę trudno się czyta, co może być powodem wielu nieporozumień.

### ***3.2 Kontrowersyjne oraz dyskusyjne elementy metodologiczne***

#### **Detekcja dronów**

Dyskusyjnym elementem pracy jest samo podejście do problemu rozpoznawania dronów. Jak sygnalizowałem na wstępie, odnajdywanie dronów na klasycznych zdjęciach może być jednym z kilku sposobów ich detekcji, niekoniecznie najefektywniejszym, ale na pewno najtrudniejszym. Cechy „rozpoznające” drony mają stosunkowo wysoką saturację i są trudne do wykrycia i łatwe do zewnętrznej manipulacji. Intuicyjnie, człowiek szybciej rozpozna taki statek powietrzny poprzez kombinację aktualnie obserwowanej sceny oraz ruchu czy dźwięku. Oznacza to, że w wielu przypadkach te inne cechy mogą być wyraźnie dominujące. Tylko drony szpiegowskie posiadają skuteczne systemy wyciszające, jednak dalej rozpoznawane przez wystarczająco czułe sensory akustyczne czy radiowe. Drony amatorskie, rzadko przez długi czas wiszą nieruchomo w powietrzu. W jakim stopniu „wyrzucenie” z analizowanych

zdjęć ruchu zubaża zbiór danych? Czy nie warto byłoby zamiast pojedynczego zdjęcia brać ich kilkuklatkową sekwencję, wtedy różnicowe filtry konwolucyjne oprócz analizy sceny odkrywałyby ruch jako ważną cechę? Oczywiście w takim przypadku należałoby się zastanowić nad architekturą całej sieci.

Kontrowersyjny jest sposób zastosowania przez Autora metody transferu wiedzy (ang. transfer learning) i wykorzystanie wyuczonej wcześniej na innych przykładach sieci. Zgodnie z listowną korespondencją z Autorem, wykorzystał on do tego celu wytrenowaną sieć MobileNet (lub Faster R-CNN) na zbiorze COCO. Na opracowanym przez Kandydata zbiorze treningowym cała sieć była trenowana (wszystkie wagi, nawet te w warstwach konwolucyjnych). Najczęściej zakłada się, że wagi warstw konwolucyjnych zostają zamrożone (cechy zagregowane zostały już wcześniej zdefiniowane na innym zazwyczaj olbrzymim zbiorze danych), a doucza się tylko wagi końcowego fragmentu MLP i szczególnie te identyfikujące nowy zbiór danych. Oczywiście istnieje metoda delikatnego dostrojenia (ang. fine tuning) wszystkich wag zakładając jednak wyjściową strukturę klas, a nowe dane traktując jako nową klasę. Zakłada się wtedy także małą wartość stałej uczącej by nie „wypaść” z obszaru minimum funkcji strat reprezentującego sieć bazową. Tymczasem, struktura klas w podejściu Kandydata została całkowicie zmieniona. Wszystkie klasy zbioru referencyjnego COCO zostały zastąpione jedną klasą (obecność drona). Trening wszystkich wag, nawet z mniejszą wartością stałej uczącej, może zniszczyć wiedzę ukrytą w sieci referencyjnej. Istnieje uzasadnione niebezpieczeństwo, że zostanie odnalezione minimum funkcji strat w zupełnie innym miejscu. Sytuacja będzie podobna do tej gdybyśmy zaczęli trening zadanej architektury sieci od początku. By przekonać się o tym, należałoby nauczyć sieć od początku dla randomowej inicjalizacji wag tylko na zbiorze danych przygotowanych przez Autora (bez fine-tuningu). Gorąco rekomenduję przeprowadzenie tego eksperymentu. Zbiór jest na tyle duży, że *transfer learning* może okazać się zbędny. Sam MobileNet (i jego odmiany) jest raczej oszczędny w ilości parametrów, stąd opracowany przez Autora zbiór danych może okazać się wystarczający, jeżeli chodzi o jego wielkość do wytrenowania takiej sieci. Ponadto istnieją nowoczesne architektury sieci do wyuczenia których nie potrzebna jest tak duża liczba przykładów (np. DenseNet, Dense-MobileNet). Z drugiej strony ciekawym wynikiem Autora jest zbadanie jakości otrzymanych rozwiązań w zależności od wielkości zbioru treningowego. Okazuje się,



że wystarczy mniejsza ilość danych by otrzymać satysfakcjonującą dokładność klasyfikacji. Czy jest to jednak wynik *transfer learning* 'u, czy oszczędnej sieci, nie wiadomo (?).

Równie kontrowersyjne jest niewykorzystanie przez Autora standardowej procedury walidacji krzyżowej zarówno w kontekście zbioru walidacyjnego i testowego. Pozytywnymi obrazami testowymi mogłyby być np. drony o różnej wielkości lub sfotografowane na innym tle niż te należące do zbioru treningowego. Pozwoliłoby to ocenić (zbiór walidacyjny) optymalny, odnośnie nadmiarowego dopasowania, czas treningu jak i (zbiór treningowy) błąd dokładności klasyfikacji i innych metryk. Weryfikacja wytrenowanej sieci na zbiorze obrazów obojętnych, dalej nie pozwala na obiektywną ocenę jej jakości.

Podsumowując: W rozdziale tym najbardziej nowatorskim elementem jest opracowanie unikalnego zbioru danych. Ciekawy jest też sposób jego analizy i bardzo dobra jakość otrzymanych rezultatów. Kontrowersyjnym jest użycie w takiej postaci transferu wiedzy. Brak krzyżowej walidacji wyników uważam jednak za duży niedostatek pracy uniemożliwiający bardziej obiektywną ocenę jakości narzędzia poprzez możliwość wyliczenia błędu jego dokładności.

### **Monitoring i predykcyjna konserwacja (ang. predictive maintenance) turbiny gazowej**

Celem tej części pracy jest (str. 151) „The primary goal is to predict long-term HP (High Pressure) recoup pressure and hence enable consistent performance prediction and potentially early detection of components degradation.”. Czyli długoterminowa predykcja ciśnienia rekuperacyjnego w celu diagnostyki predyktywnej turbiny gazowej. W kontekście tego co wykonał Autor tak zdefiniowany cel jest mylący, co wraz z nieprecyzyjnym jego opisem i opisem danych było wynikiem mojej początkowej dezorientacji wyjaśnionej w listowej dyskusji z Autorem. W rzeczywistości celem Autora jest wyznaczenie jednego z trudno mierzalnych parametrów pracy turbiny (ang. recoup pressure) w czasie  $T_0$  na podstawie pomiarów czasowych z innych czujników, porównując te pomiary z pomiarami z jeszcze innych czujników w innych turbinach dla których wyznaczono wartość trudno mierzalnego ciśnienia.

Podstawową trudnością, związaną z realizacją zadania była szeroko pojęta normalizacja pomiarów (4658 pomiarów w oknie czasowym T) z różnych czujników (różne jednostki) na różnych turbinach – tzn. znalezienie na podstawie tych danych czasowych sposobu ekstrakcji niskowymiarowego „odcisku palca” reprezentującego zadaną wartość ciśnienia rekuperacyjnego (ang. recoup pressure). Do celu inżynierii cech Autor zaprzął zarówno standardowe jak i bardziej wyszukane narzędzia uczenia maszynowego. Recenzję pracy utrudnia jednak brak lub rozproszenie po tekście dokładnej specyfikacji zbioru danych i pełnego opisu używanych narzędzi informatycznych. Tego rodzaju informacje powinny być zgrupowane w jednym rozdziale w celu łatwego ich odszukania w trakcie czytania pracy (np. Opis danych, Stosowane algorytmy i narzędzia regresji - parametry). Podobnie dotyczy to organizacji eksperymentów np. opis jak dokładnie wyglądała walidacja: jak zdefiniowano zbiór treningowy i testowy? Praca badawcza nie może być nieodtwarzalna. Dużym brakiem jest zatem niedostępność zbioru danych na którym dokonywano eksperymentów.

Rysunek 111 pokazuje jakość regresji dla różnych stosowanych metod. Czy dotyczy to algorytmów/narzędzi najlepiej dostrojonych? Czy np. Autor badał, jak zmienia się błąd w zależności od wyboru metody optymalizacyjnej w sieci neuronowej? Oczywiście wszystkiego się sprawdzić nie da, ale wtedy oprócz błędu należałoby podać jeszcze osiągi czasowe odpowiednich metod jako dodatkowy element definiujący jakość narzędzia. Jeżeli wszystkie mieściły się w zadanym reżimie czasowym, dla tych najbardziej wyszukanych należało przeprowadzić bardziej wnikliwą analizę ich parametrów. Autor pisze (str. 158). “As shown, it significantly reduces a single misprediction impact on the overall maintenance system with a drawback of an increase in system response time (up to 500 minutes of real-time operations, depending on the parameter recording frequency).”. Czy te 500 min. to dużo czy mało w kontekście rozwiązywanego problemu? Na jakim komputerze ten czas był zmierzony?

Podsumowując: W rozdziale tym najbardziej przykuwającym uwagę i nowatorskim jest metodologia inżynierii cech. Niezadawalająca i myląca jest jednak jego cała szczegółowa narracja.

### 3.3 Inne uwagi i pytania do Autora.

a) W dysertacji brakuje pewnego porządku, w którym przed wykonaniem eksperymentu dokładnie opisuje się (najlepiej w tabelce) zbiór danych, szczegółowe architektury modeli (sieci) z podanymi parametrami, zastosowane oprogramowanie, wykorzystywane chmury obliczeniowe oraz dokładną specyfikację sprzętu. Dobrym zwyczajem jest następnie podanie timingów dla referencyjnych eksperymentów. Prawdopodobnie większość tych specyfikacji znajduje się gdzieś w tekście pracy. Jednak duża objętość pracy i dość rozwlekły sposób prezentacji nie pozwalają na szybkie znalezienie tych specyfikacji.

b) Jak pokazuje literatura, wynik treningu sieci (jej jakość) i stabilność treningu zależy od używanej procedury optymalizacyjnej. Czy Autor porównywał wyniki dla różnych algorytmów optymalizacji przed wyborem tego najlepszego?

c) Typ problemu UM który Autor bada to raczej one-class classification (z pewnymi istotnymi różnicami odnośnie klasycznej definicji) niż *binary classification*, który to termin wielokrotnie pojawia się w dysertacji.

d) Autor twierdzi (str. 143): „In general, ANN based solutions achieve better performance than Haar Cascades but require more computational power, dedicated GPU, and processing time. Its deployment also is more challenging than that of the Haar Cascade alternative. Haar Cascades return more drone detection proposals than ANNs, but with a significantly larger amount of false positives.”. Nie można tego tak porównywać. HC były uczone dla małej liczby danych, ich uczenie na pełnym zbiorze danych trwałoby wieki. Należy, wszakże zauważyć, że jak wynika z artykułu [Pham, Nguyen, 2020], na podobnej wielkości zbiorze danych (2000 pozytywów i 2000 negatywów) wyniki klasyfikacji wykorzystujące HC mogą być większe niż 90% (w dysertacji ok 54%). Artykuł ten wykorzystuje oczywiście inny zbiór danych, ale wymaga to komentarza od doktoranta.

e) Autor pisze (str. 144): „Large auto-correlation has been noted for every few epochs, but in general, the results show that overfitting had not occurred, and that model continues to slowly increase its overall performance over time. This stands in contrast to an established statement of

neural networks overfitting above a few hundred thousand iterations.”. To zależy od wielu czynników, np. od stałej uczącej która w przypadku *fine-tuning*’u jest mała. Może to być powód takiego, a nie innego zachowania sieci.

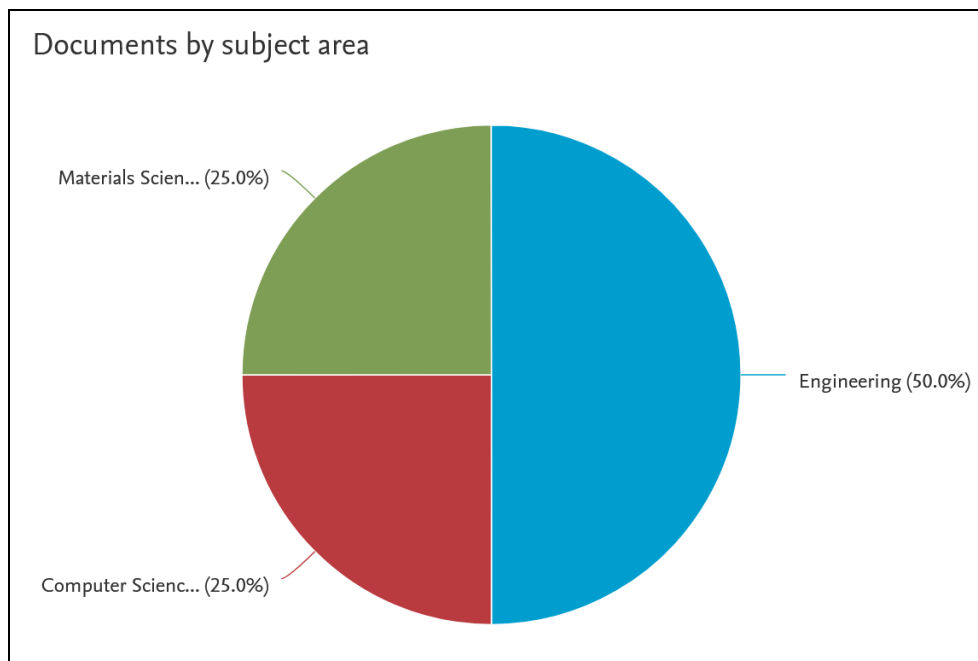
f) Autor pisze (str. 157):” MLP Deep Learning model”. Jak „deep”? Deep learning używa się dla sieci o co najmniej 10 warstwach (niektórzy piszą o 100).

g) Na rysunku 107 brakuje opisu osi.

**Język w którym pisana była praca.** Praca napisana jest w języku angielskim. Chociaż język jest poprawny Autor nie ustrzegł się paru seryjnych niedociągnięć. Zgodnie z dobrymi regułami pisania tekstów naukowych powinno się unikać tzw. rozwlekłości do których należą zwroty „in order to” (zamiast „to”) czy „due to the fact” (zamiast „because”) bardzo często używane w tekście pracy.

#### **4. Dorobek naukowy Kandydata**

Kandydat posiada w dorobku naukowym kilka publikacji naukowych w tym dwie, wydane w 2020, rozpoznawane przez bazę cytowań SCOPUS: w IEEE Access (SNIP: 1,42) oraz Eksploatacja i Niezawodność (SNIP 1,237). W pierwszej współautorem jest tylko Pan Promotor, w drugiej Kandydat jest pierwszym autorem (4 współautorów). Trzecia praca z roku 2013 (dwóch autorów) została wydana w języku polskim w czasopiśmie lokalnym Transactions of the Institute of Aviation. Kandydat posiada już 6 obcych cytowań, co jest dużym sukcesem dla tak świeżo wydanych publikacji. Pierwsza publikacja odnotowana jest także w bazie informatycznej DBLP. Liczba cytowań zgodnie z portalem ResearchGate to 12 oraz 3 rekomendacje i około 800 zainteresowanych („reads”).



Jak widać z zamieszczonego powyżej diagramu pochodzącego z bazy Scopus dorobek naukowy Kandydata lokuje się w dyscyplinach: inżynieria, informatyka, materiałoznawstwo. Zatem dobrze odpowiada dyscyplinie inżynieria mechaniczna.

Reasumując, aktualny dorobek naukowy Kandydata ukierunkowany jest na zagadnienia ściśle związane z dyscypliną informatyka techniczna w zastosowaniach w problemach inżynierskich. Jest już zauważalny i lokuje się powyżej formalnych wymagań związanych z tym etapem przewodu doktorskiego.

## 6. Podsumowanie

Biorąc pod uwagę jakość przedstawionej do oceny monografii doktorskiej oraz całościowy dorobek naukowy Kandydata, a także widoczną chociażby ze sposobu podejścia do problemu i konsekwencji na poszczególnych etapach badań, jego naukową wnikliwość, moja ogólna opinia o rozprawie jest **pozytywna** tzn. kandydat zasługuje na stopień naukowy doktora inżyniera w dziedzinie nauk technicznych w dyscyplinie inżynieria mechaniczna.

Podsumowując przedstawianą opinię, stwierdzam ostatecznie, że praca **mgr inż. Macieja Pawelczyka**, spełnia wymagania przewidziane dla rozpraw doktorskich w aktualnie obowiązujących przepisach.

zującej Ustawie. Dlatego, stawiam wniosek o **przyjęcie tej pracy jako rozprawy doktorskiej i o dopuszczenie Kandydata do jej publicznej obrony.**

#### **7. Wniosek o wyróżnienie rozprawy**

Stawiam wniosek o wyróżnienie rozprawy. Dysertacja stanowi kompletne i wielu punktach nowatorskie dzieło naukowe. Pokazuje naukową pasję Kandydata, umiejętność formułowania hipotez oraz ich przekonującego dowodzenia i obrony. Wytworzone w trakcie realizacji narzędzia mają duży potencjał wdrożeniowy i z punktu widzenia rozwoju nowych technologii mogą stanowić cenny nabytek dla gospodarki Państwa. Postawione hipotezy i rozwiązanie zostały opublikowane w czasopiśmie o wysokim współczynniku SNIP (MNiSzW 100 punktów) w których Kandydat jest pierwszym Autorem, co dodatkowo potwierdza wagę napisanej na ich podstawie rozprawy doktorskiej.



Witold Dzwiniel