

Częstochowa, 8.01.2024 r.

dr hab. inż. Janusz Starczewski, prof. PCz
Katedra Inteligentnych Systemów Informatycznych
Wydział Inżynierii Mechanicznej i Informatyki
Politechnika Częstochowska

POLITECHNIKA ŚLĄSKA
Biuro Rady Dyscypliny
Automatyka, Elektronika, Elektrotechnika
i Technologie Kosmiczne

wpłynęło dnia 12.01.2024

nr zał.

Recenzja rozprawy doktorskiej

Tytuł rozprawy: **Diagnostyka elektrycznego napędu rogatek z wykorzystaniem uczenia maszynowego**

Autor: **mgr inż. Roman Pawełczyk**

Promotor: **dr hab. inż. Damian Grzechca, prof. Pol. Śl.**

Opiekun przemysłowy: **mgr inż. Tomasz Pisarek**

Przewód doktorski w dyscyplinie: Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne

Dziedzina: nauki inżyniersko-techniczne

Recenzja wykonana na podstawie Uchwały nr 67/2023 Rady Dyscypliny Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne Politechniki Śląskiej z dnia 26 września 2023.

Podstawa prawna: art. 190 ust. 2 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2023 r., poz. 742 ze zm.).

Dziedzina problemowa i charakter rozprawy

Na bezpieczeństwo ruchu drogowego istotny wpływ ma tzw. skrzyżowanie rogatkowe, tj. skrzyżowanie drogi kołowej z drogą kolejową w jednym poziomie. Za zasadnością wyboru tematu pracy stoi zatem dbałość o odpowiedni poziom bezawaryjnej pracy urządzeń automatyki stosowanych na przejazdach kolejowych. Newralgicznymi elementami tych urządzeń są napędy rogatek do tzw. dróg rogatek zabezpieczających użytkowników pojazdów samochodowych przed wjazdem na przejazd w otoczeniu czasowym przejazdu szynowego. Wg badań European Union Agency for Railways cytowanych także w rozprawie 30% wypadków ze skutkiem śmiertelnym dotyczy użytkowania przejazdów kolejowo-drogowych. Istnieje zatem pilna konieczność wyposażania systemów rogatki w zaawansowane metody diagnostyczne i kontroli, m.in. w celu optymalizacji czasu wstępnego ostrzeżenia.

Komplikacje na tej drodze wprowadza fakt, że aktualnie używane są odmienne technologicznie napędy rogatek o różnym stopniu automatyzacji sterowania drągiem rogatek. Popularnym napędem jest napęd rogatek JEGD 50 zbudowany na silniku

elektryczny o napięciu 24V DC i niewielkiej mocy 225W wyposażony w układ przekaźnikowy z tranzystorami polowymi albo stycznikowy w starszych wersjach. Napęd rogatekowy produkowany przez Zakłady Automatyki KOMBUD typu RHR-95 wyposażony natomiast jest w hydrauliczny mechanizm sterowania położeniem drąga rogatekowego z sinusoidalnym przebiegiem prędkości ze sterownikiem SEN-4X. Kolejny przykładowy napęd produkowany przez Bombardier Transportation ZWUS Polska typu EEG-3 jest elementem jest przystosowany do współpracy z sygnalizacją przejazdową SPA-5 i charakteryzuje się malejącą prędkością drąga i sterowaniem stycznikowym z silnikiem z magnesami trwałymi 24V DC lub 230V AC. Natomiast w systemie BUES 2000 firmy Scheidt & Bachmann stosowany jest napęd rogatekowego HSM 10E ze sterowaniem hydraulicznym silnikiem asynchronicznym 36V za pomocą mikrokontrolera z interfejsem CAN. Praca dotyczy usprawnienia działania elektrycznego napędu rogatekowego rodziny EBI Gate 630 typu EEG-3.

W ogólności diagnostyka napędów elektrycznych, szczególnym przypadkiem których są napędy rogatekowe, jest szeroko opisana w literaturze w kontekście zapewnienia ciągłości utrzymania ruchu. Współcześnie automatykę diagnostyczną wyposaża się w modele uczenia maszynowego redukując w ten sposób m.in. koszty montażu dodatkowych czujników. Zagadnieniom związanym z badaniami laboratoryjnymi i w części z badaniami przemysłowymi nad metodami diagnostyki napędów rogatekowych poświęcona została rozprawa doktorska Pana mgr inż. Romana Pawełczyka, której dotyczy niniejsza recenzja. Rozprawa ma charakter wdrożeniowy.

Zawartość rozprawy

Przedłożona rozprawa doktorska proponuje nowe podejście do diagnostyki elektrycznego napędu rogatekowego z wykorzystaniem uczenia maszynowego. Powszechnie stosowane podejścia bazują w głównej mierze na granicznych przedziałach czasu dla działania napędu rogatekowego w trakcie otwarcia oraz zamknięcia. Praca wykorzystuje standardową konstrukcję układu rogatekowego i elementów sterowania jego napędem. Zaproponowane zostały trzy zasadnicze metody, które jako niezależne moduły mogą być wdrożone w modelu przyrostowym rozwoju systemu.

Rozprawa obejmuje propozycję trzech metod diagnostycznych dla napędu rogatekowego:

1. opracowanie nieinwazyjnej metody detekcji kąta położenia drąga elektrycznego napędu rogatekowego *Barrier Machine Angle Detection* - BMAD w oparciu o analizę wartości prądu zasilającego; metoda jest metodą programistyczną wyposażoną w modele uczenia maszynowego z zachowaniem standardowego interfejsu kontrolno-sterującego dla napędu,
2. opracowanie metody prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego *Barrier Machine Movement Time* - BMMT pomiędzy położeniami skrajnymi również z wykorzystaniem uczenia maszynowego na danych z pomiarów parametrów elektrycznych, czasowych oraz środowiskowych,
3. opracowanie nieinwazyjnej metody *Barrier Machine Failure Detection* - BMFD umożliwiającej identyfikację wymienionych trzech typów zdarzeń usterkowych w oparciu o analizę przebiegu prądu zasilającego z wykorzystaniem uczenia maszynowego.

Metoda BMAD jest odpowiedzią na niedokładność powszechnie stosowanego rozwiązania technicznego bazujących na sygnałach pochodzących z wyłączników krańcowych informujących o osiągnięciu przez drąg ustalonych położeń kątowych. Ponieważ sygnały są dyskretne w tym

przypadku, rozwiązanie to nie pozwala na dokładny pomiar nachylenia w punktach nieciągłości, a sterowanie uwzględniać musi maksymalne czasy dopuszczalne dla poszczególnych pozycji kątowych drąga. Metoda BMAD polega na działaniu czterech modułów uczenia maszynowego służących estymacji wartości kątowej drąga (nazywanej w rozprawie "predykcją położenia kątowego drąga") oraz ocenie, czy kąt drąga osiągnął zakładaną wartość (nazywanej w rozprawie "predykcją zajęcia wybranego położenia kątowego drąga"), w obu przypadkach oddzielnych dla ruchu w górę i ruchu w dół. Zestaw estymatorów aktualnej wartości kątowej rozwiązuje problem kontroli ruchu drąga w trybie ciągłym. Zestaw estymatorów osiągnięcia zadanej wartości kątowej przydatny jest w sytuacjach, gdy konieczna jest detekcja pewnych wartości kątowych dla układów automatyki bez rozmieszczania dodatkowych wyłączników krańcowych.

Wyniki badań dla estymacji wartości kątowej drąga z założoną rozdzielczością $\Delta\alpha=3^\circ$ odznaczają się dokładnością powyżej 90% dla klasyfikatora Random Forest. Ten sam algorytm okazał się być najbardziej skuteczny w zadaniu estymacji zajęcia przez drąg wybranego kąta przy tej samej rozdzielczości $\Delta\alpha=3^\circ$, a czułość, swoistość i dokładność algorytmu przewyższyły wartość 90%. Autor wykazał w ten sposób, że analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatek z wykorzystaniem algorytmu uczenia maszynowego umożliwia wyznaczenie aktualnego położenia kąta drąga bez konieczności ingerencji w konstrukcję urządzenia.

Metoda BMMT w oparciu o zestaw danych zebranych w początkowej fazie ruchu napędu rogatek oraz informację o parametrach środowiskowych dostarcza predykcji całkowitego czasu ruchu pomiędzy pozycjami skrajnymi. W standardowym układzie kontroli i sterowania, do którego odnosi się Autor, czas ten szacowany był z zapasem jako maksymalny dopuszczalny czas ruchu, a rozwiązanie takie nie dawało możliwości optymalizacji czasu trwania poszczególnych faz pracy systemu sygnalizacji przejazdowych. Metoda BMMT dostarcza informacji o spodziewanym czasie zamykania i otwiera nowe możliwości dla systemów zabezpieczających przejazdy kolejowe. Dla tej metody założeniem jest zabudowanie enkodera w napędzie rogatek.

W trakcie badań służących opracowaniu metody BMMT w pierwszym kroku porównane zostały algorytmy Random Forest, z siecią MLP, z prostą regresją liniową oraz z nieskomplikowanym modelem zwracającym wartości średnie (Naive Model Mean) z regresją typu Dummy. W kolejnym kroku algorytmy zostały poddane optymalizacji hiperparametrycznej, i tu najważniejszym wyborem na tym etapie okazał się Random Forest Regresor. W ostatnim kroku ze zwyciężającymi algorytmami porównany został model zespołowy (MLP+RF) Voting Regresor oraz Stacking Regresor, który wykazał się największą dokładnością działania w sensie błędu średniokwadratowego, przy czym Voting Regresor wyróżnił się większą zdolnością generalizacji w pomiarach na danych testowych. Zaobserwowany maksymalny błąd regresji bazując na danych zebranych w czasie krótszym niż 1 s od rozpoczęcia danej fazy ruchu jest niższy niż 0,5 s, a dla wymienionego modelu Stacking Regresor nie przekracza nawet 0,4 s, co spełnia założone wymagania.

Bardzo rzetelną czynnością badawczą jest przedstawione badanie odporności modeli na uszkodzone dane. Modele działają dokładnie pomimo uszkodzeń czujników temperatury i wilgotności oraz czujnika prędkości i kierunku wiatru, jeśli brakujące dane zastąpimy danymi imputowanymi. Niestety z analizy błędów wynika awaria czujnika prądu wpływa destrukcyjnie dla wszystkich modeli, co jest wnioskiem słusznym, aczkolwiek trywialnym.

Metoda BMFD wymagała uprzedniego zdefiniowania modeli zdarzeń występujących podczas pracy elektrycznego napędu rogatek: ruch bez zakłóceń, zderzenie z przeszkodą stałą,

sprężystą i uszkodzenie mechanizmu napędowego we wszystkich przypadkach dla ruchu w górę i ruchu w dół drąga rogatkowego. Tak utworzone modele zdarzeń stały się podstawą do opracowania mechanizmu detekcji wystąpienia założonych rodzajów usterek. Katalog usterek jest znacznie większy od bazowego systemu sygnalizacji przejazdowej, skutkiem czego daje duże możliwości w budowaniu scenariuszy reakcji na usterkę systemu lokalnego sygnalizacji, jak również całego systemu kolejowego. Wyniki przeprowadzonych badań wskazują na przewagę klasyfikatora Random Forest z dostrojeniem hiperparametrycznym za pomocą RandomizedSearchCV nad konkurencyjną siecią MLP oraz algorytmami bez strojenia hiperparametrycznego. Random Forest nie wykazywał błędnych alarmów w przypadku braku błędów, a pojedyncze błędy braku klasyfikacji usterek pojawiają się w przy poruszaniu się drąga w górę, a jeden błąd pojawił się w kierunku przeciwnym. Autor wskazuje jednak, że poziom czułości został w badaniu ustawiony na wartość maksymalną, a granice zakresów parametrów dla modeli zdarzeń zostały powiększone o 10% względem obserwowanych zakresów dla rzeczywistych przypadków. Argumentacja, że celem takiego postępowania było zaobserwowanie skuteczności metody dla przypadku granicznego, jest słuszna.

Autor podkreśla, że wszystkie metody są modułowymi rozszerzeniami istniejącej koncepcji sterowania elektrycznym napędem rogatkowym. Ma to istotne znaczenie ze względu na fakt, że istniejące systemy spełniają normy i obowiązujące wymagania w zakresie bezpieczeństwa, natomiast zmiany powiązane z istotną ingerencją w dotychczas przyjęte rozwiązania techniczne są wyjątkowo trudne i kosztowne w procesie ich dopuszczenia do eksploatacji. M.in. w systemach tej klasy zapewniony ma być poziom nienaruszalności bezpieczeństwa SIL4, a propozycja rozbudowy systemu o kolejne moduły pozostawiając niezmienione dotychczasowe kluczowe funkcje systemu nie zmienia tego poziomu.

Efektom przeprowadzonych badań laboratoryjnych jest wdrożenie części rozwiązań do komercyjnego systemu automatycznej sygnalizacji przejazdowej lub też dalszych badań przemysłowych i prac rozwojowych nad systemem.

Kompozycja pracy jest prawidłowa. Równomierne rozłożenie treści w rozdziałach ułatwia zapoznanie się przebiegiem pracy badawczej. Jedynym zaburzeniem struktury pracy jest rozdział siódmy poświęcony projektowi wdrożeniowemu metody detekcji kąta usytuowania drąga dla napędu rogatkowego EEG-3.

Opinia o pracy i wskazanie oryginalnych osiągnięć

Po pierwsze należy podkreślić, że problem badawczy jest kluczowy dla bezpieczeństwa ruchu drogowego. W celu rozwiązania prawidłowo postawionego problemu diagnostyki elektrycznego napędu rogatkowego Doktorant skrupulatnie dowodzi trzech tez cząstkowych łącząc wiedzę z zakresu automatyki i elektrotechniki z umiejętnością praktycznego stosowania metod uczenia maszynowego i programowania z użyciem pakietu sci.kit

Przeprowadzone studia literaturowe w zakresie krajowym i międzynarodowym jest bogate i adekwatne do podejmowanego problemu badawczego (109 pozycji włącznie z dwoma autocytowaniami solidnych publikacji). Pozyskana przez Autora wiedza dotyczy szerokich również interdyscyplinarnych aspektów naukowych.

Badania prowadzone przez Doktoranta w dużej mierze mają charakter badań przemysłowych z ukierunkowaniem na wdrożenie autorskiej koncepcji systemu do diagnostyki elektrycznych napędów rogatekowych na poziomach 4-6 TRL (ang. *technology readiness levels*), tj. oszacowaniu gotowości technologicznej prototypu w warunkach laboratoryjnych oraz wykazaniu gotowości technologicznej podczas badań na stanowisku symulującym rzeczywiste warunki. Jedną z badanych metod została wdrożona u użytkownika końcowego, jednak wyniki tego etapu są opisane nazbyt skrótowo, aby można było przypisać temu wdrożeniu konkretny poziom gotowości technicznej.

Najważniejsze oryginalne osiągnięcia w pracy obejmują badania w celu opracowania trzech metod diagnostycznych dla napędu rogatekowego oraz opracowanie modelu usterek:

1. opracowanie nieinwazyjnej metody detekcji kąta położenia drąga elektrycznego napędu rogatekowego *Barrier Machine Angle Detection* (BMAD) z wykorzystaniem uczenia maszynowego w oparciu o analizę wartości prądu zasilającego,
2. opracowanie metody prognozowania całkowitego czasu ruchu drąga elektrycznego napędu rogatekowego *Barrier Machine Movement Time* (BMMT) wykorzystaniem uczenia maszynowego bazując na danych z pomiarów parametrów elektrycznych, czasowych oraz środowiskowych (temperatura, wilgotność, prędkość i kierunek wiatru),
3. opracowanie modelu usterek, rozumianego jako implementacja, analiza i dostrojenie modeli wybranych typów zdarzeń usterkowych dla elektrycznego napędu rogatekowego symulujących przebiegi usterkowe prądu zasilającego, w tym modelu uderzenia w przeszkodę stałą, modelu uderzenia w przeszkodę sprężystą oraz modelu uszkodzenia mechanizmu napędowego,
4. opracowanie nieinwazyjnej metody *Barrier Machine Failure Detection* (BMFD) umożliwiającej identyfikację wymienionych trzech typów zdarzeń usterkowych w oparciu o analizę przebiegu prądu zasilającego także z wykorzystaniem uczenia maszynowego.

W toku przeprowadzonych badań Autor jednoznacznie potwierdził słuszność tez pracy, stwierdzając że:

1. analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia wyznaczenie aktualnego położenia kąta drąga bez konieczności ingerencji w konstrukcję urządzenia, jednocześnie zwiększając poziom bezpieczeństwa poprzez wygenerowanie dodatkowej informacji dla systemu sterującego,
2. algorytm uczenia maszynowego zbudowany na podstawie zmiennych środowiskowych, informacji o kątowym położeniu drąga oraz kształcie prądu zasilającego umożliwia predykcję czasu otwierania i zamykania z zachowaniem wymagań czasowych systemu czasu rzeczywistego,
3. analiza czasowa przebiegu prądu zasilającego elektryczny napęd rogatekowy z wykorzystaniem algorytmu uczenia maszynowego umożliwia ocenę wystąpienia zdarzeń w trakcie ruchu drąga, takich jak zderzenie z przeszkodą stałą, sprężystą oraz uszkodzenie mechanizmu napędowego.

Wynikiem przeprowadzonych badań jest wdrożenie uproszczonego systemu diagnostycznego, które potencjalnie ma duże znaczenie dla rozwoju przemysłowych metod diagnostycznych w systemach rogatekowych, wobec czego jednoznacznie należy stwierdzić, że cel

rozprawy, jakim było opracowanie diagnostyki elektrycznego napędu rogatekowego z wykorzystaniem uczenia maszynowego, został w pełni osiągnięty.

Warto dodać, że w trakcie badań Doktorant nie ograniczał się do wyboru konkretnego modelu uczenia maszynowego, ale dokonuje analizy porównawczej:

1. klasyfikatorów drzew decyzyjnych, Random Forest, Multi-Layer Perceptron oraz Perceptron w przypadku dla metody BMAD,
2. modeli regresji: Naive Model Mean/Dummy Regressor, Linear Regressor, MLP oraz Random Forest, w wersjach podstawowych, dostrojonych hiperparametrycznie oraz dostrojonych modeli złożonych Voting Regressor oraz Stacking Regressor, w kontekście metody BMMT,
3. klasyfikatorów Random Forest i klasyfikatorów Multi-Layer Perceptron również ze strojeniem hiperparametrycznym dla metody BMFD.

Pracę charakteryzuje dbałość o systematyczne prowadzenie badań dla każdej z opracowywanych metod, poprzez cykl czynności obejmujący:

- prezentację założeń metody,
- opis metody,
- schemat opracowania metody,
- akwizycja bądź wytworzenie danych,
- inicjowanie i optymalizacja parametryczna modeli,
- rozbudowana analiza porównawcza modeli w oparciu o miary dokładności, czułości i swoistości w przypadku klasyfikatorów albo błędów średniokwadratowych, maksymalnych i współczynników determinacji w przypadku regresji,
- optymalizacja hiperparametryczna i strojenie modeli,
- ocena skuteczności metody na danych testowych/rzeczywistych (BMMT, BMFD),
- badanie odporności modeli na uszkodzone dane w przypadku metody BMMT.

Podsumowując główne rezultaty badań zostały przedstawione w sposób przejrzysty, a wnioski płynące z badań są słuszne.

Uwagi wymagające dyskusji

Poniższe uwagi mają charakter krytyczny względem rozprawy i wymagają wyjaśnienia, doprecyzowania bądź pogłębionej dyskusji w trakcie obrony rozprawy doktorskiej.

1. W pracy brakuje przeprowadzenia analizy porównawczej dla znanych typów napędów rogatekowych. Komplikację wprowadza fakt, że aktualnie używane są odmienne technologicznie napędy rogatekowe o różnym stopniu automatyzacji sterowania drągiem rogatekowym takie jak wspomniane w recenzji, napęd rogatekowy JEGD 50, napęd produkowany przez Zakłady Automatyki KOMBUD typu RHR-95, napęd produkowany przez Bombardier Transportation/Alstom ZWUS Polska typu EEG-3, czy też zastosowany w systemie BUES 2000 firmy Scheidt & Bachmann HSM 10E. Czy wyniki pracy, tj. wprowadzone modele uczenia maszynowego są aplikowalne do wszystkich powszechnie stosowanych typów napędów rogatekowych, czy tylko do EEG-3, którego dotyczy wdrożenie? Jaka jest skalowalność przebadanych metod, przykładowo jakie modyfikacje i jakie strojenie parametryczne należałoby wprowadzić przy zmianie silnika napędowego?

2. Praca nie zawiera odniesienia się do modelu teoretycznego układu automatycznego napędu drąga. W trakcie opracowania metody BMAD autor od razu założył wykorzystanie modeli uczenia maszynowego zgodnie z rys. 4.1. Jednak jeśli model napędu rogatekowego charakteryzowałyby się nieskomplikowanym opisem matematycznym, estymacja aktualnej wartości kąta położenia drąga na podstawie chwilowych wartości prądu zasilającego możliwie byłaby obciążona mniejszym kosztem obliczeniowym. Rozważania modeli przybliżonych i teoretycznych, jeśli istnieją, powinno być punktem wyjścia dla ewentualnego wykorzystania modeli uczenia maszynowego.
3. Metoda BMAD w opisie Autora ma służyć "predykcji położenia kąтового drąga") oraz "predykcji zajęcia wybranego położenia kąтового drąga" (na schemacie z rys. 4.1. oznaczone jako modele klasyfikacyjne). Czy istotnie w przypadku obu wartości wyjściowych metody można mówić o predykcji? Jaki jest aspekt czasowy przeprowadzanych estymacji? W odniesieniu do których z metod BMAD, BMMT, BMFT uzasadnione jest użycie terminu "predykcja"?
4. W podrozdziale poświęconym określeniu zestawu danych treningowych i testowych Autor dzieli w sposób losowy na podzbiór treningowy i walidacyjny (ostatni wiersz strony 55). Przyjęło się, że walidacja służy ocenie modelu w celu przeprowadzenia optymalizacji hiperparametrycznej, natomiast testowanie służy ocenie dostrojenia parametrów/wag modelu uczenia maszynowego. Jest to o tyle mylące, że w testowaniu wykorzystujemy algorytm walidacji krzyżowej. Czy Autor miał na myśli podzbiór walidacyjny, czy testowy? Jaki charakter losowy miał podział zbioru danych? Czy dane zostały zbalansowane? Jest to o tyle istotne, że na kolejnej stronie Autor stosuje "walidację krzyżową" typu K-fold o nieznanej wartości K. Pewne światło rzucają na to niedoprecyzowanie fragmenty kodu, ale należałoby opis dotyczący testowania i walidacji doprecyzować.
5. W klasyfikatorach MLP jako optymalizator stosowany jest algorytm Adam. Co podyktowało wybór algorytmu bazującego na gradiencie stochastycznym? Dla jakich zadań Adam wykazuje się skutecznością?
6. Opis wdrożenia został potraktowany skrótowo. Interesujący jest aspekt walidacji praktycznej pierwszej z zaproponowanych metod oraz ocena perspektyw praktycznego wykorzystania pozostałych opracowanych przez Autora metod. Na jakim poziomie gotowości technicznej (TRL) prowadzone są (albo zostały już przeprowadzone) badania przemysłowe lub prace rozwojowe dla wdrożonego modułu dla napędu EEG-3? Identyfikacja poziomów gotowości technicznej stanowi uniwersalny język w zarządzaniu projektami w ramach badań przemysłowych i prac rozwojowych, do którego Autor mógłby się odnieść.

Uwagi niemerytoryczne

Rozprawa odznacza się wysoką dbałością o przekaz językowy i jest prawie pozbawiona błędów edytorskich. Jako wyjątek od tej ogólnej oceny można przytoczyć błąd opisu na stronie 64, gdzie parametr ACC określony jest "czułością" a w istocie oznacza dokładność działania modelu (pierwsze zdanie pod tabelą 4-3).

Opinia końcowa o rozprawie

W konkluzji stwierdzam, że recenzowana rozprawa doktorska pod tytułem *Diagnostyka elektrycznego napędu rogakowego z wykorzystaniem uczenia maszynowego* przedłożona przez mgr inż. Romana Pawełczyka stanowi oryginalne rozwiązanie wdrożeniowe istotnego problemu badawczego oraz potwierdza specjalistyczną wiedzę teoretyczną powiązaną z wysokimi umiejętnościami stosowania metod wykorzystania uczenia maszynowego w dyscyplinie Automatyka, Elektronika, Elektrotechnika i Technologie Kosmiczne. Pracę oceniam wysoce pozytywnie. Recenzowana rozprawa spełnia wymagania określone ustawowo i stanowi podstawę do **dopuszczenia rozprawy doktorskiej do publicznej obrony**. Ponadto uwzględniając wysokie walory merytoryczne rozprawy oraz potwierdzenie tych walorów w m.in. recenzowanej publikacji naukowej z wysokim współczynnikiem Impact Factor (w czasopiśmie IEEE Design & Test z afiliacją Doktoranta na pierwszym miejscu) zwracam się z uprzejmym wnioskiem o **wyróżnienie tej rozprawy**.

Janusz T. Starczewski

