

RECENZJA ROZPRAWY DOKTORSKIEJ DLA RADY NAUKOWEJ DYSCYPLIN MATEMATYKA I INFORMATYKA UNIwersytetu Warszawskiego

Tytuł rozprawy:

Efficient Methods for Machine Learning in Sequential Decision Making

(Wydajne metody uczenia maszynowego dla problemów sekwencyjnego podejmowania decyzji)

Autor rozprawy: mgr Błażej Osiński

1. Analiza strony merytorycznej rozprawy

1.1. Obszar problemowy

Recenzowana rozprawa doktorska dotyczy zagadnień sekwencyjnego podejmowania decyzji, w których agent wchodzi w interakcję ze środowiskiem, wykonując serię akcji, w celu osiągnięcia określonego celu.

Główną osią rozprawy jest poszukiwanie efektywnych pod względem wykorzystania danych treningowych (sample-efficient) metod uczenia maszynowego, gdyż wysoki koszt związany z uzyskaniem danych jest jednym z głównych problemów ograniczających jak dotąd zastosowania algorytmów opartych na uczeniu maszynowym w rozwiązywaniu zagadnień sekwencyjnego podejmowania decyzji. Problem ten ma praktyczny wymiar między innymi w robotyce, gdzie uzyskanie zbiorów danych o wielkości zbliżonej do zbiorów używanych w nadzorowanym uczeniu np. w zakresie przetwarzania języka naturalnego lub klasyfikacji obrazów jest często niemożliwe, a etykietowanie danych czasochłonne, kosztowne i podatne na błędy. Za główny cel rozprawy Autor obrał badanie strategii mających na celu efektywne wykorzystanie danych przez algorytmy uczenia maszynowego, lub zastąpienie danych trudnych do zebrania danymi łatwiejszymi (tańszymi) do uzyskania. Badane strategie można podzielić na trzy grupy: zwiększenie efektywności wykorzystania danych przez algorytmy uczenia ze wzmocnieniem, użycie "tańszych" źródeł danych (mniej kosztownych sensorów) i wykorzystanie istniejącej już wiedzy zakodowanej w wytrenowanych wcześniej modelach uczenia maszynowego. Określając w ten sposób cel i zakres pracy, Autor rozprawy podjął się rozwiązania problemów poruszanych w literaturze z zakresu informatyki (uczenia maszynowego, symulacji), z praktycznymi zastosowaniami między innymi w robotyce. Problematyka rozprawy daje możliwość uzyskania nowych wyników naukowych w zakresie informatyki oraz robotyki. Poruszane w niej zagadnienia jak dotąd nie zostały rozwiązywane w sposób zadowalający, a niektóre z proponowanych algorytmów lub modeli uczenia maszynowego mają charakter pionierski. Pod względem formalnym cel pracy zdefiniowany przez Autora i zakres podejmowanych badań uzasadniają twierdzenie, że obszar problemowy rozprawy mieści się w zakresie uczenia maszynowego, tworzenia algorytmów, konstrukcji symulatorów programowych i oprogramowania czasu rzeczywistego pojazdów autonomicznych, a więc uwzględniając obecny stan prawny, w zakresie dyscypliny informatyka. Jednocześnie w rozprawie poruszono wiele wątków dotyczących robotyki, która jest obszarem naturalnie interdyscyplinarnym.

Recenzowana rozprawa oparta jest na zbiorze siedmiu artykułów, których współautorem jest mgr B. Osiński. Wszystkie zostały opublikowane w latach od 2020 do 2022 w materiałach renomowanych

konferencji z zakresu robotyki lub uczenia maszynowego. W rozprawie nie sformułowano jawnie tezy naukowej. Wobec jasnego sformułowania celu badań nie uważam braku tezy za istotne uchybienie warsztatowi naukowemu, niemniej jednak dobrze sformułowana teza mogłaby ułatwić weryfikację osiągnięcia założonego celu poprzez prezentowany cykl publikacji. Rozprawa składa się z siedmiu rozdziałów zwartego tekstu, z których ostatni zawiera podziękowania Autora, zasadniczej bibliografii cytowanej w tych rozdziałach, oraz kopii artykułów.

Pierwszy rozdział rozprawy stanowi wstęp, zawierający uzasadnienie dla podjęcia tematu badawczego związanego z redukcją kosztów pozyskiwania danych w uczeniu maszynowym i wprowadzający problematykę sekwencyjnego podejmowania decyzji oraz uczenia ze wzmocnieniem. Rozdział ten zawiera też zwięzły przegląd znanych z literatury podejść do uczenia maszynowego w sekwencyjnym podejmowaniu decyzji.

Rozdział drugi stanowi omówienie podstawowych założeń, metod i środowisk związanych z uczeniem ze wzmocnieniem opartym na modelu (MBRL) w odniesieniu do zagadnień, w których dane są dostępne głównie w postaci obrazów. Autor podkreśla, że główną motywacją do zastosowania metod MBRL jest ich lepsza wydajności próbkowania (*sample efficiency*), pomimo zauważalnie trudniejszego trenowania w porównaniu do metod uczenia ze wzmocnieniem bez modelu. W rozdziale tym wprowadzono także *Arcade Learning Environment (ALE)* jako powszechnie używany punkt odniesienia dla technik uczenia ze wzmocnieniem, wskazując, że do niedawna nie było demonstracji udanego planowania z wyuczonym modelem w ALE. Na tym tle rozdział drugi wprowadza prace Autora dotyczące zastosowania MBRL w grach Atari.

Rozdział trzeci koncentruje się na autonomicznych pojazdach, stanowiąc wprowadzenie do głównego obszaru aplikacji rozważanych w recenzowanej rozprawie. Zawiera przegląd ważniejszych wątków badań dotyczących autonomii pojazdów i zastosowań symulatorów jako alternatywy dla gromadzenia danych rzeczywistych. W rozdziale tym przedstawiono też metodologie przenoszenia reguł sterowania pojazdem z symulowanego do rzeczywistego środowiska, odnosząc się do prac Autora.

Zagadnieniom autonomicznych pojazdów poświęcony jest także rozdział czwarty. Koncentruje się on na problemach *imitation learning* (uczenia się przez naśladowanie), które jest dobrze ugruntowanym podejściem do rozwiązywania sekwencyjnych problemów decyzyjnych przy użyciu uczenia nadzorowanego. Zastosowanie tego podejścia dla autonomicznych pojazdów nie jest koncepcją nową, jednak Autor wskazuje na zalety tego podejścia związane z łatwością gromadzenia dużego zbioru danych z demonstracji ekspertów, w przeciwieństwie do uczenia ze wzmocnieniem na podstawie polityki, które wymaga dużej liczby interakcji ze środowiskiem. W rozdziale wprowadzono rozwiązania systemu planowania ruchu dla samochodów autonomicznych opartego na koncepcji *imitation learning*, nad którymi pracował Autor. Umożliwiają one skuteczne zastosowanie tej koncepcji dla samochodów poruszających się w rzeczywistym środowisku, radząc sobie ze zjawiskiem *covariate shift*, sytuacją, w której nauczona polityka nieznacznie odbiega od demonstracji eksperta, lecz prowadzi do napotkania rozkładów danych, których algorytm nie analizował podczas treningu. Ponadto, wyniki osiągnięte w zakresie uczenia przez imitację eksperta dotyczą analizy jakości danych zbieranych na etapie demonstracji, nowej koncepcji symulatora, w którym sterowanie (polityka) niezależnych agentów nie jest kodowane, lecz uczone na podstawie demonstracji, oraz *SafetyNet*, systemu który zwiększa bezpieczeństwo planowania ruchu poprzez integrację alternatywnych planów opartych na regułach.

Tematyka rozdziału piątego dotyczy zastosowaniach dużych, wstępnie wytrenowanych modeli neuronowych, nazywanych modelami podstawowymi (*foundation models*). Przedstawiono w tym rozdziale system *LM-Nav (Large Model Navigation)*, opracowany ze znacznym udziałem Autora, który demonstruje możliwość użycia modeli podstawowych, a szczególnie dużego modelu języka (*large language model, LLM*) *GPT-3* do kierowania robotem w oparciu o instrukcje w języku naturalnym. *LM-Nav* nie wymaga treningu lub dostrajania użytych modeli podstawowych i można go uznać za efektywną metodę próbkowania, ponieważ całkowicie eliminuje konieczność gromadzenia danych do celów treningowych.

Rozdział szósty to krótkie podsumowanie wątków badań opisanych w rozprawie, wraz z podkreśleniem pionierskiego charakteru części z prezentowanych osiągnięć, takich jak udane zastosowanie podejścia MBRL w grach Atari oraz pomyślne testy w świecie rzeczywistym samochodu, którego system

sterowania był całkowicie trenowany w symulowanym środowisku przy użyciu uczenia ze wzmocnieniem.

Rozprawa zawiera niezbyt obszerną, lecz reprezentatywną dla poruszanej problematyki bibliografię, która w większości przypadków właściwie ilustruje omawiane zagadnienia.

Druga część manuskryptu zawiera kopie artykułów i prezentuje główne osiągnięcia doktoranta, w tym oryginalne koncepcje rozwiązania istotnych zagadnień w zakresie informatyki oraz robotyki.

Artykuł "Model-based Reinforcement Learning for Atari" przedstawia system uczenia ze wzmocnieniem oparty na modelu (MBRL), będący pierwszym opublikowanym tego rodzaju skutecznym rozwiązaniem dla środowiska gier Atari z wejściem w postaci obrazów (ekranów gry).

Praca "Simulation-based reinforcement learning for real-world autonomous driving" dotyczy rozwiązania opartego na uczeniu ze wzmocnieniem pozwalającego na przenoszenie trenowanych całkowicie w symulacji modeli do świata rzeczywistego (autonomicznego samochodu), tym samym skutecznie rozwiązując problem sim2real.

Kolejny załączony artykuł, "What data do we need for training an av motion planner?" dotyczy badania wpływu jakości zebranych danych treningowych na jakość planów ruchu generowanych przez trenowany model, oraz wskazuje na możliwość użycia większej ilości danych pochodzących ze źródeł gorszej jakości (tańszych) do skutecznego trenowania modeli.

Praca "SimNet: Learning reactive self-driving simulations from real-world observations", stawia sobie za cel poprawę realizmu samych symulacji używanych do trenowania samochodów autonomicznych poprzez uczenie polityk ruchu niezależnych agentów (pojazdy, piesi) obecnych w tych symulacjach.

Kolejny artykuł załączony do manuskryptu, "Urban driver: Learning to drive from real-world demonstrations using policy gradients", wykorzystuje pewne elementy z poprzedniej pracy (symulator) do opracowania nowej metody uczenia na podstawie dużego korpusu rzeczywistych demonstracji, stosując metodę gradientu polityki offline.

Praca "SafetyNet: Safe planning for real-world self-driving vehicles using machine-learned policies" przedstawia rozwiązanie systemu planowania ruchu dla samochodów autonomicznych pozwalające na zwiększenie bezpieczeństwa planowania opartego na uczeniu maszynowym jazdy poprzez warstwę awaryjną opartą na regułach, która przeprowadza kontrolę poprawności decyzji podjętych przez model oparty na uczeniu, zastępując błędne decyzje prostymi, lecz bezpiecznymi regułami.

Ostatni z załączonych artykułów (wymieniony jednaj jako trzeci na liście prac sporządzonej przez Autora), "LM-Nav: Robotic navigation with large pre-trained models of language, vision, and action", prezentuje system nawigacji robotów zbudowany całkowicie ze wstępnie wytrenowanych modeli nawigacji (ViNG), asocjacji obraz-język (CLIP) i modelowania języka (GPT-3), który nie wymaga zbierania danych treningowych lub dostrajania, jednocześnie charakteryzując się zdolnością do nawigacji w złożonym środowisku naturalnym.

Spośród siedmiu załączonych artykułów cztery były prezentowane podczas konferencji IEEE International Conference on Robotics and Automation (ICRA), będącej największą i jedną z najważniejszych konferencji dotyczących robotyki (obecnie pierwsze miejsce na liście Google w kategorii 'Robotics', h5-index=119). Pozostałe prace były prezentowane na Conference on Robot Learning (CoRL) - dwie, oraz International Conference on Learning Representations (ICLR) - jedna. Są to bardzo dobre konferencje z obszaru uczenia maszynowego, przy czym ICLR zajmuje drugie miejsce na liście Google w kategorii 'Artificial Intelligence', h5-index=309, a CoRL jest dynamicznie rozwijającą się, choć stosunkowo nową konferencją poświęconą problemom uczenia maszynowego w robotyce i pokrewnych systemach. Wszystkie artykuły stanowiące podstawę rozprawy są wieloautorskie (od 4 do 11 autorów). Autor rozprawy w trzech pracach jest pierwszym autorem lub pierwszym autorem równorzędnym i deklaruje swoje udziały procentowe w poszczególnych artykułach w zróżnicowanym zakresie od 5% do 50%, opisując jednocześnie swój wkład w rozwiązanie problemu poruszanego w danym artykule i wkład w przygotowanie pracy. Opisy te są jednak dość pobieżne

1.2. Ocena wyników oraz stopnia ich oryginalności

Recenzowana rozprawa dotyczy uczenia maszynowego w zadaniach wymagających sekwencyjnego podejmowania decyzji - w praktyce zadania takie spotykane są w grach, planowaniu działań i ruchów autonomicznych agentów. Interesującym aspektem podjętej problematyki jest rozważanie scenariuszy sekwencyjnego podejmowania decyzji dla agentów upostaciowanych - robotów, takich jak autonomiczne pojazdy.

Zaprezentowane w rozprawie rozwiązania tych zadań opierają się na kilku różnych koncepcjach, powiązanych z różnymi domenami zastosowań (gry Atari, samochody autonomiczne, roboty mobilne). Dla środowiska gier Atari zaproponowano algorytm SimPLe (artykuł 1), który jest pierwszym opublikowanym skutecznym zastosowaniem metody uczenia ze wzmocnieniem opartego na uczonej modelu dla gier Atari. Poprawia on wyraźnie efektywność wykorzystania danych w porównaniu do metod uznawanych za state-of-the-art. Dla domeny samochodów autonomicznych w rozprawie zaproponowano kilka rozwiązań opartych na efektywnym wykorzystaniu symulacji komputerowych do treningu modeli uczenia maszynowego. Pokazana została możliwość użycia danych z symulatora CARLA do wytrenowania polityki mogącej prowadzić samochód w świecie rzeczywistym (artykuł 2) oraz możliwość wykorzystania uczenia przez imitację trajektorii kierowcy-eksperta, bez potrzeby kosztownego i ryzykownego uruchamiania własnej polityki (artykuł 5). Zaprezentowano także istotne ulepszenie opartej na uczeniu maszynowym metody planowania ruchu samochodów autonomicznych dotyczące bezpieczeństwa (artykuł 6). Oryginalny wkład prac stanowiących podstawę rozprawy dotyczy także sposobów pozyskiwania danych do treningu modeli neuronowych dla pojazdów autonomicznych. Wykazano, że możliwe jest wykorzystanie do uczenia głębokich sieci neuronowych używanych do kierowania autonomicznych samochodów danych o niższej jakości, pochodzących z "tańszych" źródeł, a zastosowanie dużych zbiorów takich danych daje efekty lepsze, niż mniejsza ilość danych lepszej jakości (artykuł 3). Zaproponowano także nowe podejście do budowy symulatorów dla pojazdów autonomicznych, w którym zachowania niezależnych agentów są uczone na podstawie danych z obserwacji rzeczywistego środowiska (artykuł 4). W domenie nawigacji autonomicznej robotów mobilnych zaproponowane zostało oryginalne rozwiązanie oparte na pre-trenowanych modelach podstawowych, które wykorzystuje między innymi duży model języka GPT-3. Wszystkie z proponowanych w załączonych artykułach algorytmów, metod i modeli wpisują się w deklarowany cel rozprawy, którym jest poprawa efektywności wykorzystania danych uczących w systemach uczenia maszynowego rozwiązujących zagadnienia sekwencyjnego podejmowania decyzji.

W świetle znanej literatury dotyczącej uczenia maszynowego, szczególnie w robotyce, proponowane rozwiązania można uznać za oryginalne, a w niektórych przypadkach definiujące state-of-the-art (algorytm SimPLe, metoda transferu sim2real w artykule 2).

Wśród prezentowanych w stanowiących podstawę rozprawy artykułach nowych koncepcji oraz rozwiązań należy wyróżnić.

- opracowanie algorytmu głębokiego uczenia ze wzmocnieniem z modelem predykcji obrazu, który wykazał się w grach Atari efektywnością próbkowania znacznie przewyższającą wcześniej znane metody;
- ustanowienie nowego standardu oceny uczenia ze wzmocnieniem w grach Atari w reżimie małej ilości danych, określanym jako Atari 100k;
- eksperymentalne wykazanie kluczowego wpływu randomizacji wizualnej w symulatorze jazdy autonomicznej (CARLA) na możliwość skutecznego transferu nauczonych modeli do świata rzeczywistych pojazdów;
- wykazanie, że większy zestaw danych o niższej jakości może być w uczeniu maszynowym w domenie samochodów autonomicznych bardziej korzystny niż mniejszy zestaw danych o wyższej jakości;

- sformułowanie problemu symulacji jazdy autonomicznej jako problemu uczenia maszynowego, którego celem jest generowanie epizodów jazdy które są zarówno realistyczne, jak i reagują na zachowanie symulowanego pojazdu;
- demonstracja nowego, gradientowego uczenia się w podejściu *imitation learning* dla ruchu miejskiego na podstawie dużego zbioru rzeczywistych demonstracji;
- oryginalne połączenie uczenia maszynowego i ręcznie zaprojektowanego systemu do sterowania samochodem autonomicznym, które zapewnia gwarancje bezpieczeństwa;
- nowy system nawigacji (LM-Nav), który łączy w sobie pre-trenowane modele języka i modele nawigacji wizyjnej ze sterowaniem wizyjnym w kierunku celu, uzyskując wykonywalne plany bez konieczności uczenia komponentów lub dostrajania w środowisku docelowym.

Zauważone niedoskonałości dysertacji dotyczą przede wszystkim dość powierzchownego opisu osiągnięć w zwartej części rozprawy. Brak tam odniesień do niektórych z artykułów stanowiących podstawę rozprawy co utrudnia identyfikację oryginalnego wkładu doktoranta. Jest to istotne szczególnie wobec współautorskiego charakteru wszystkich artykułów oraz faktu, że mgr Błażej Osiński identyfikowany jest jako pierwszy/główny autor tylko w trzech z siedmiu prac (1, 2 i 7 według układu rozprawy). Oczekuję, że podczas obrony doktorant jednoznacznie określi oryginalne elementy swojego autorstwa pojawiające się w pozostałych artykułach i odniesie je do celu rozprawy - poprawy efektywności wykorzystania danych w uczeniu maszynowym. Pewne wątpliwości można mieć także co do próby rozszerzonego zarysowania tła badań podjętej w zwartej części rozprawy. O ile związane wprowadzenie problematyki autonomicznych samochodów trafnie koncentruje się na braku wdrożeń pomimo intensywnych badań i problemach wynikających z masowego charakteru danych i prób potrzebnych do weryfikacji bezpiecznej jazdy, o tyle wprowadzenie do problemu przenoszenia wyuczonych zachowań z symulacji do rzeczywistości pomija istotne aspekty problemu. Takim aspektem jest randomizacja, którą Autor uważa za element nowatorski w swojej pracy z symulatorem CARLA, a która w nieco innym kontekście była używana już w pracach z lat 90 dotyczących syntezy sterowników robotów za pomocą metod ewolucyjnych (N. Jakobi, "Running across the reality gap: Octopod locomotion evolved in a minimal simulation," in *Evolutionary Robotics*, O. Husbands and J. Meyer, Eds. Berlin, Germany: Springer-Verlag, 1998).

1.3. Zagadnienia dyskusyjne

Poniższe uwagi dotyczą wybranych kwestii poruszonych w rozprawie. Oczekuję komentarza doktoranta dotyczącego tych uwag.

1. W artykule "What data do we need for training an AV motion planner?" dane o obniżonej jakości generowane są sztucznie poprzez modyfikację informacji otrzymywanych z rzeczywistych sensorów pojazdu. Informacje modyfikowane są co do zasięgu, pola widzenia oraz błędów pozycji i orientacji wykrywanych obiektów (innych agentów). Przedstawione wyniki badań prowadzą do wniosku, że zastąpienie "lepszyc" danych z bardziej kosztownych sensorów większą ilością danych o słabszej jakości jest nie tylko możliwe, ale poprawia wyniki treningu modelu opartego na ChaufferNet. Czy wnioski te można przenieść na sytuację użycia rzeczywistych "tańszych" sensorów, które mogą działać na innych zasadach fizycznych (np. różne skanery laserowe, sonary), generując np. istotnie więcej danych odstających lub różnego rodzaju artefakty?
2. W artykule "Simulation-Based Reinforcement Learning for Real-World Autonomous Driving" jako jeden z kluczowych komponentów proponowanego rozwiązania, zapewniających skuteczne pokonanie reality gap opisano randomizację warunków wizualnych w symulatorze CARLA. Można jednak zauważyć, że w świecie rzeczywistym zmiana warunków atmosferycznych powodująca zmiany wizualne, np. deszcz lub mgła wpływa też na zachowanie się pojazdu na drodze (wilgotna

nawierzchnia). Można też zaobserwować zmiany w zachowaniu innych agentów (mniejsza prędkość jazdy, mniej pieszych). Czy randomizacja tych zmiennych/parametrów i/lub powiązanie ich w sposób symulujący świat rzeczywisty mogą mieć istotne znaczenie dla problemu sim2real?

3. W jaki sposób stochastyczna natura dużego modelu języka, takiego jak GPT-3, wykorzystywanego w systemie LM-Nav, wpływa na niezawodność instrukcji języka naturalnego w kierowaniu nawigacją robotów? Biorąc pod uwagę możliwość wystąpienia błędów lub nieporozumień w generowaniu odpowiedzi, w jaki sposób system może skutecznie radzić sobie z takimi błędami podczas nawigacji w złożonych, rzeczywistych środowiskach? Jakie strategie lub zabezpieczenia można zastosować, aby zapewnić bezpieczne i dokładne interakcje między użytkownikami a robotami, biorąc pod uwagę poleganie na pre-trenowanych modelach?

2. Analiza strony formalnej rozprawy

2.1. Ocena układu pracy i redakcji manuskryptu

Recenzowana rozprawa doktorska została przygotowana w języku angielskim i jest to także język wszystkich siedmiu załączonych artykułów. Rozprawa obejmuje w kolejności: streszczenie w języku polskim, streszczenie w języku angielskim, spis treści, wykaz załączonych publikacji wraz z deklaracjami merytorycznego i procentowego udziału Autora rozprawy, sześć rozdziałów zasadniczych, podziękowania, bibliografię oraz kopie artykułów w postaci, w której zostały one opublikowane. Rozprawa liczy 129 ponumerowanych stron, przy czym od strony 37 są to załączone artykuły, mające własną numerację stron i lokalne bibliografie. Bibliografia zasadnicza (str. od 30 do 35) składa się z 64 pozycji, w tym stron internetowych. Spośród nich 43 zostały opublikowane w okresie ostatnich 5 lat (po roku 2018), co świadczy o bardzo dobrym osadzeniu rozprawy w aktualnym stanie badań w zakresie sztucznej inteligencji i robotyki. Cytowanych jest także kilka starszych prac, które pozwoliły Autorowi osadzić swoje badania w kontekście historii rozwoju metod uczenia maszynowego oraz robotyki. Bibliografia nie budzi zastrzeżeń od strony merytorycznej i cytowana jest właściwie. Niezrozumiałe jest jednak, że w bibliografii cytowane są tylko cztery prace współautorstwa B. Osińskiego ([14], [54], [57], [64]), chociaż Autor rozprawy odnosi się wielokrotnie do swoich osiągnięć w treści rozdziałów od 1 do 6. Utrudnia to jednoznaczne powiązanie artykułów stanowiących podstawę rozprawy z syntetycznym opisem w zwartej części manuskryptu. Ponadto, pozycje bibliografii nie zostały uporządkowane alfabetycznie, nie są też uporządkowane w kolejności cytowania, co jest mankamentem redakcji manuskryptu i utrudnia lekturę.

Układ rozprawy jest zasadniczo prawidłowy, chociaż w manuskrypcie, który otrzymałem kolejność załączonych artykułów nie pokrywa się z kolejnością deklarowaną na str. 9-10 (pozycja nr 3, "LM-Nav: Robotic navigation with large pre-trained models of language, vision, and action" jest załączona jako ostatnia). Manuskrypt jest starannie opracowany pod względem edytorskim i graficznym. Użyty w rozprawie język (angielski) i terminologia są właściwe dla poruszanej tematyki, zarówno w zakresie informatyki, jak i robotyki.


2.2. Uwagi szczegółowe

Zwarty tekst rozprawy jest zwięzły i poprawny pod względem stylistycznym. Podczas lektury manuskryptu nie zauważyłem istotnych błędów językowych. Także redakcja zasadniczej bibliografii jest staranna, poza brakiem uporządkowania pozycji. Zauważyć można jedynie pojedyncze błędy redakcyjne, jak w [41], wynikające zapewne z niewłaściwego wprowadzania pozycji do systemu BibTeX. Niektóre z cytowanych źródeł internetowych nie mają podanej daty ostatniego dostępu.

3. Konkluzja

Uważam, że recenzowana dysertacja Pana mgr Błażeja Osińskiego spełnia wymogi stawiane rozprawom doktorskim przez art. 187 ustawy z dnia 20 lipca 2018 r. – Prawo o szkolnictwie wyższym i nauce, ponieważ zawiera oryginalną koncepcję rozwiązania istotnych zagadnień w dziedzinach informatyki oraz robotyki. Rezultaty rozwijają istniejący stan wiedzy i mają znaczenie praktyczne, co wykazano eksperymentalnie dla zagadnienia autonomicznego prowadzenia samochodu w warunkach miejskich.

Uzyskane wyniki w wystarczającym stopniu dokumentują poprawność proponowanych koncepcji i opracowanych rozwiązań. Uwagi krytyczne sformułowane w treści recenzji, po części mające charakter dyskusyjny, nie umniejszają mojej pozytywnej oceny oryginalności i praktyczności przedstawionych rozwiązań. Sformułowanie problemu badawczego, zaproponowane oryginalne metody jego rozwiązania, sposób przeprowadzenia badań oraz zademonstrowana umiejętność formułowania wniosków świadczą o przygotowaniu doktoranta do pracy naukowej. Na tej podstawie wnioskuję o przyjęcie rozprawy doktorskiej mgr Błażeja Osińskiego i o dopuszczenie do jej publicznej obrony.



Podpis jest
prawidłowy

Dokument
podpisany przez
Piotr Skrzypczyński
Data: 2023.08.30
11:39:49 CEST

Piotr Skrzypczyński