

Prof. dr hab. inż. Jacek Rumiński
Politechnika Gdańska,
Wydział Elektroniki, Telekomunikacji i
Informatyki
ul. G. Narutowicza 11/12, 80-233 Gdańsk
email: jacek.ruminski@pg.edu.pl

Gdańsk, 9.09.2026

Recenzja rozprawy doktorskiej

mgr. inż. Jakuba Bednarka

zatytułowanej:

Composite neurosymbolic architectures for learning and reasoning from real and abstract data

Recenzja została przygotowana w odpowiedzi na pismo Dziekana Wydziału Informatyki i Telekomunikacji Politechniki Poznańskiej, prof. Mikołaja Morzy, informującego mnie, że zgodnie z uchwałą Rady Dyscypliny Informatyka Techniczna i Telekomunikacja Politechniki Poznańskiej, z dnia 30 czerwca 2026 roku, zostałem wskazany jako recenzent rozprawy doktorskiej Pana mgr. inż. Jakuba Bednarka, przygotowanej pod opieką promotora prof. Krzysztofa Krawca.

Rozprawa jest napisana w języku angielskim, dlatego cytowane fragmenty będą w niniejszej recenzji przywoływane w oryginale.

1. Problem badawczy i jego znaczenie

Doktorant postawił i zbadał trzy hipotezy:

Hipoteza H1 (s. 18): „H1. We hypothesize that a specialized perceptive module can successfully abstract raw, low-level sensory data acquired during robot-environment interaction into high-level, quantifiable features (e.g. symbolic properties) that are sufficiently meaningful and accurate to be directly utilized by the upstream decision-making and control systems to improve overall task performance.”

Hipoteza H2 (s. 60): „H2. We hypothesize that a neural network acting as an “Apprentice” can distill the complex, non-linear decision boundaries of an analytical “Oracle” solely from synthetic data. Furthermore, we posit that a policy learned from this high-level abstract representation captures the essential dynamics of the interaction sufficiently well to allow for direct, zero-shot transfer to the physical world, effectively bridging the gap between analytical rigor and real-time execution.”

Hipoteza H3 (s. 94): “H3. We hypothesize that the challenge of automatic fitting to abstract problems can be resolved by establishing a structural isomorphism between the embodied decision-making loop and the cognitive reasoning process. By elevating mechanical Sensing to symbolic perception and physical Acting to program synthesis, we postulate that a unified

neuro-symbolic architecture can utilize program execution traces as a training signal analogous to physical feedback, enabling the joint optimization of problem perception and solution strategy."

Każda z nich jest rozpatrywana kolejno w częściach I, II i III rozprawy.

Postawione i zbadane problemy badawcze mają zarówno znaczenie poznawcze, jak i praktyczne, w szczególności w odniesieniu do architektur neurosymbolicznych. Ciekawe i praktyczne eksperymenty z wykorzystaniem robotów pokazują nie tylko aspekty klasyfikacji podłoża, ale również zadania związane z efektywnym sterowaniem robotem.

2. Wkład autora

Za kluczowe osiągnięcia Doktoranta uważam:

1. Wykazanie, że architektury sieci spłotowych mogą skutecznie wyodrębniać dyskretne klasy terenu (np. „żwir”, „beton”) z wejściowych sygnałów wysokiej częstotliwości rejestrowanych przez sensory siły i momentu obrotowego robota przy wystąpieniu szumu.
2. Wykazanie, że dostarczanie informacji istotnych dla określonego zadania, pochodzących z komponentu neuronowego, pozwala osiągnąć dobrą jakość lokalizacji w wymagającym środowisku, a komponent sensoryczny zdolny do przetwarzania złożonych danych dotyczących interakcji fizycznych można włączyć do większego systemu decyzyjnego.
3. Wykazanie, że wielowymiarowe rozmaitości decyzyjne rozważanych w pracy zadań (np. dla Quadratic Programming based Model Predictive Control) można aproksymować za pomocą spłotowej sieci neuronowej. W szczególności zaproponowanie i wstępna weryfikacja tego, że strategia Apprentice skraca czas wnioskowania z rzędu sekund (dla modelu slow-Oracle) do milisekund, umożliwiając sterowanie nogami robota w czasie rzeczywistym.
4. Wykazanie, że strategie wytrenowane w całości na syntetycznych mapach wysokościowych i uproszczonych modelach fizycznych mogły sterować fizycznym robotem ANYmal, a sieć neuronowa nie musiała doświadczać fizyki świata rzeczywistego, lecz mogła wykorzystywać struktury fizyki dostarczanej przez symulator (bezstratny transfer).
5. Zaproponowanie i weryfikacja architektury TransCoda do rozwiązywania nowych syntetycznych zadań ARC i potwierdzenie, że rozumowanie logiczne można traktować jako problem optymalizacji trajektorii, strukturalnie identyczny z planowaniem ścieżki robota. W analizowanym zadaniu decyzyjnym moduł percepcji (symbolic Sensing) wyodrębnia cechy siatki, a solver (symbolic Acting) syntetyzuje program.
6. Zaproponowanie rozwiązania i weryfikacja, że symulacja logiczna (wykonywanie kodu) zapewnia sygnał zwrotny wystarczająco bogaty i ograniczający, jak w symulacji fizycznej, umożliwiając agentowi samodzielną korektę. Umożliwiając agentowi generowanie własnych zadań syntetycznych i uczenie się na podstawie śladów wykonania, system aktywnie

nawiguje w przestrzeni rozwiązań, iteracyjnie zbliżając się do zadania docelowego poprzez rozwiązywanie sekwencji problemów pośrednich.

Doktorant wskazał w rozprawie, że część propozycji i wyników opisanych w rozprawie została wcześniej opublikowana w wieloautorskich publikacjach powiązanych z poszczególnymi rozdziałami pracy doktorskiej. Wskazał 12 publikacji (m.in. za 140 i 100 punktów MNiSW). Doktorant jest pierwszym autorem w ponad połowie tych publikacji.

Podsumowując, na podstawie rozprawy oraz kluczowych publikacji związanych z tematyką rozprawy, których Doktorant jest pierwszym autorem, stwierdzam, że można wystarczająco wyróżnić indywidualny wkład autora w realizację badań i wskazanych osiągnięć. Niemniej na poczet przyszłej, potencjalnej dyskusji warto, aby Doktorant doprecyzował, co stanowił jego własny wkład w tej części osiągnięć powiązanych z publikacjami współautorskimi, których Doktorant nie jest pierwszym autorem.

3. Poprawność

W tej części recenzji odnoszę się szczegółowo do treści rozprawy, wskazując w wybranych miejscach ewentualne uwagi krytyczne i/lub pytania.

Doktorant podzielił rozprawę na trzy tematyczne części, w których (poza rozdziałami wprowadzającymi i podsumowującymi) przedstawił po dwa rozdziały omawiające osiągnięcia na podstawie wcześniej opublikowanych artykułów.

W części pierwszej (rozdziały 3 i 4) Doktorant skupił się na zagadnieniach związanych ze źródłem danych symbolicznych (Sensing).

Doktorant (wraz z współautorami artykułu źródłowego) zaproponował metody klasyfikacji terenu wykorzystujące dane z czujników siły/momentu obrotowego robotów czworonożnych i sześcionożnych. Zbadał modele RNN, CNN i FCN wraz z propozycją deskryptora wyznaczanego z danych po transformacji Fouriera (FFT) dla wektorów wejściowych o zmiennej długości (zbiór PUT). Deskryptor wyznacza 9 wartości na podstawie składowych widmowych.

P1. *Proszę o informacje, czy i jak zmieniają się wartości składowych deskryptora, gdy zmienia się liczba danych wejściowych, na podstawie których wyznaczane jest widmo. Czy przy tej samej częstotliwości próbkowania i różnej liczbie próbek w czasie nie będzie różnicy w rozdzielczości w dziedzinie częstotliwości, co może mieć wpływ na wartości wyznaczone według wzoru 3.1?*

Dla zbioru PUT (zmiennej długości) uzyskano niskie wartości dokładności dla modelu RNN, czego oczekiwano. Niemniej Doktorant wykazał, że zarówno dla zbioru ETHZ (RNN i CNN), jak i zbioru PUT (FCN) uzyskał lepsze rezultaty niż dla referencyjnie najlepszej metody tradycyjnej (SVM). Brak informacji o porównaniu wyników z innymi modelami, np. modelami typu transformer. W najlepszym przypadku różnica w dokładności wynosi nawet 18%.

Doktorant przedstawił również algorytm lokalizacji haptycznej dla robotów czworonożnych oparty na sekwencyjnych metodach Monte Carlo (ang. Haptic Sequential Monte Carlo Localization). Algorytm ten może łączyć informacje geometryczne (w przestrzeni 2,5D lub 3D) oraz semantykę terenu w celu lokalizacji obiektu na podstawie wcześniejszej mapy. W pracy wykorzystuje się proste propozycje sieci neuronowych (CNN/GRU) do klasyfikacji terenu. Przeprowadzono bardzo ciekawe eksperymenty (np. zilustrowane na rys. 4.6, 4.10). Badano również osiem rodzajów podłoża (eksperyment 3).

Doktorant, wspólnie ze współautorami, wykazał, że możliwe jest zmniejszenie błędu lokalizacji do 10 cm poprzez wykorzystanie wyłącznie informacji geometrycznych (niezdegenerowany teren zawierający zbocza). Zaproponowana metoda okazała się także skuteczna, gdy robot sondował powierzchnie pionowe, mierząc swoje otoczenie w pełnym 3D. Ponadto Doktorant przedstawił wyniki średniego błędu położenia wynoszącego 20 cm dla terenu o różnych klasach i o różnej geometrii.

Szkoda, że nie przedstawiono analizy ilościowej ani dyskusji w porównaniu z szerszą grupą metod wykorzystywanych przez innych autorów w podobnych badaniach.

W części drugiej (rozdziały 7 i 8) Doktorant skupił się na zagadnieniach destylacji wiedzy w proponowanym podejściu Oracle-Apprentice w aspektach sterowania (Acting).

Doktorant badał skuteczność specyficznie definiowanych danych syntetycznych jako informacji generowanych przez modele analityczne – wystarczającego substytutu do uczenia się zasad. Dane syntetyczne określa się jako symulowane odczyty czujników oraz skodyfikowany wynik „powolnej Wyroczni” (ang. „slow Oracle”). W ujęciu Oracle-Apprentice, wyrocznia jest rozumiana jako analog do zaproponowanego przez Kahneman’a systemu numer dwa, a uczeń traktowany jest jako szybki (podatny na błędy) system numer jeden. Celem w podejściu Doktoranta jest dystylacja wiedzy z modelu analitycznego (system 2) do zestawu wyznaczanych zasad (system 1). Dane w takim ujęciu reprezentują wyidealizowaną fizykę, ograniczenia i zależności interakcji robot–otoczenie. Podstawowym założeniem jest to, że problem, jeśli zostanie zdefiniowany na wystarczająco wysokim poziomie abstrakcji, może zostać w pełni odzwierciedlony przez model syntetyczny.

Doktorant zaproponował także metodę wyboru punktów podparcia dla czworonożnego robota kroczącego, bazującą na próbie emulowania dokładnego, ale powolnego modelu analitycznego (system 2) przez sieć neuronową (system 1). Rozważany w części eksperymentalnej model analityczny (ocena mapy wejściowej) składa się z pięciu kolejnych kroków, definiujących ograniczenia i obejmujących: zakres kinematyczny, samozderzenie, zderzenia z podłożem, margines kinematyczny, koszt związany z lokalnym ukształtowaniem terenu. W proponowanym podejściu sieć neuronowa ocenia fragmenty terenu i sprawdza wszystkie ograniczenia w jednym kroku. Według deklaracji Doktoranta uzyskał on skrócenie czasu wnioskowania przy satysfakcjonującej imitacji modelu analitycznego, tak aby robot mógł efektywnie działać w czasie rzeczywistym. W proponowanym rozwiązaniu robot unika stawiania stóp na stromych zboczach (krawędziach).

Niestety, wyniki przedstawione w tej części rozprawy są bardzo ograniczone. Brak szczegółowych informacji o zakresie eksperymentów (ile dla danej kategorii), o prezentacji

szczegółowych wyników ilościowych oraz o analizie statystycznej lub uogólniającej w odniesieniu do stanu wiedzy.

Doktorant zaproponował również oryginalną metodę wyboru punktów podparcia dla robotów nożnych wyposażonych w pasywne, elastyczne stopy (SoftFoot-Q). Metoda wykorzystuje sieć neuronową (Efficient Residual Factorized ConvNet, ERF + Markov Random Fields, MRF), która emuluje model analityczny uwzględniający zestaw ograniczeń fizycznych i mapę wysokości do generacji mapy kosztów, uwzględniając kolizje między nogą a terenem. Zaproponowano funkcję kosztu, która oblicza, jak stopa może dostosować się do określonego fragmentu terenu, co potencjalnie zmniejsza czasochłonność akwizycji danych. Zaproponowana sieć neuronowa jest wykorzystywana online do wyboru punktów podparcia czworonożnego robota ANYmal na różnych przeszkodach. W rezultacie robot unika ryzykownych konfiguracji i wybiera punkty oparcia zapewniające stabilne podparcie. Doktorant zbadał trzy konfiguracje sieci neuronowych: ERF z domyślną funkcją straty dla segmentacji (Belter et al., 2019), ERF z ważeniem różnicy oraz MRF zastosowaną do ERF z wagą różnicową. Dla konfiguracji MRF+ERF uzyskał najlepszy wynik dokładności, o 0,63% wyższy niż dla ERF z ważeniem różnicy. Czy jest to jednak wynik przypadkowo lepszy? Czy różne konfiguracje treningu dla ERF mogły dać lepsze wyniki? Nie znalazłem w rozprawie szczegółowej analizy w tym zakresie.

W zakresie tej części, na poczet potencjalnej dyskusji, chciałbym zadać następujące pytania Doktorantowi:

P2. *W algorytmie 2 (s. 81) Doktorant wykorzystał pojedynczy współczynnik skalowania s względem sumy $(\Phi + \Psi)$. Czy badał sumę ważoną, np. $(\Phi + \lambda\Psi)$, uwzględniając kompromis pomiędzy wynikiem ERF a wygładzaniem przez MRF?*

P3. *Ile eksperymentów (w jakich konfiguracjach) przeprowadził Doktorant w celu generalizacji wniosków o znaczącej poprawie wyników ilościowych dla MRF+ERF, szczególnie w odniesieniu do stanu wiedzy?*

W części trzeciej (rozdziały 10 i 11) Doktorant skupił się na adaptacji pętli sensoryczno-motorycznej do przestrzeni abstrakcyjnej w zagadnieniach rozwiązywania zadań łączących aspekty symboliczne z sieciami neuronowymi. Symboliczne działanie polega m.in. na tym, że model neuronowy generuje formalne instrukcje, a zewnętrzny wykonawca realizuje je zgodnie z regułami logiki lub programu, przez co problem zmienia swój stan krok po kroku aż do rozwiązania.

Doktorant zaproponował podejście Structure-Aware Program Synthesis (SAPS) w syntezie wykonywalnych fragmentów kodu z krótkich opisów żądanej funkcjonalności w języku naturalnym (NL). Wykorzystano generyczne osadzenia słów i sekwencji z dekodernami podwójnie rekurencyjnymi trenowanymi na abstrakcyjnym drzewie składniowym (AST). Wykorzystano szereg modeli sieci neuronowych dla koderów, dekodeń, itd. Używanym językiem dziedzinowym jest AlgoLisp. Pojedynczy program składa się z zagnieżdżonej listy instrukcji oraz operandów trzech typów: string, boolowski i funkcyjny. Wykorzystany zbiór danych zawierał prawie 100000 przykładów (zbiór treningowy: 79214 przykładów, zbiór walidacyjny: 9352 i zbiór testowy: 10940).

Dla najlepszego wariantu modelu (SAPS VH Att), procent idealnie zszyntetyzowanych programów wyniósł 93,73% (zbiór walidacyjny) i 92,36% (zbiór testowy). W tabeli 11.3 Doktorant pokazał wyniki (procentowa liczba programów, które przeszły wszystkie testy) w porównaniu z innymi modelami, wskazując korzyść zaproponowanego podejścia. Doktorant wnioskuje, że metody takie jak SAPS mogą być stosowane w praktycznej syntezie krótkich fragmentów kodu, na przykład w programowaniu dla użytkowników końcowych.

Doktorant zaproponował także architekturę neurosymboliczną TransCoder, bazującą zarówno na neuronowej, jak i symbolicznej percepcji problemu. Celem jest wykrywanie istotnych wzorców w niskopoziomowej reprezentacji zadania i wywodzenie z nich struktur wyższego rzędu w szczególności do obsługi zadań z korpusu Abstract Reasoning Corpus (ARC).

W szczególności wkład autora obejmuje: (i) neurosymboliczną architekturę, która syntetyzuje programy poprawne składniowo pod względem konstrukcji, (ii) paradygmat „uczenia się na błędach” do generowania zadań syntetycznych o odpowiednim stopniu trudności, (iii) zaawansowany mechanizm percepcji do wnioskowania o małych rastrach o zmiennej wielkości oraz (iv) empiryczną ocenę ARC.

Ciekawym podejściem jest uczenie na błędach, tj. gdy generator generuje program p , który nie rozwiązuje zaprezentowanego zadania T , parowane są dane wejściowe z rzeczywistymi danymi wyjściowymi wygenerowanymi przez p i utworzone jest zadanie syntetyczne (T', p) dodawane jest do zbioru roboczego S rozwiązyanych zadań i do dalszego procedowania.

W szczególności uzyskane wyniki badań wskazują, że umiejętności nabyte podczas syntetycznych, łatwiejszych zadań przekładają się na efektywniejsze rozwiązywanie trudniejszych, oryginalnych zadań ARC.

Wprowadzenie mechanizmu generowania zadań bezpośrednio realizuje cel automatycznej konstrukcji przestrzeni problemów, a opracowany system implementuje mechanizm analizy błędów: identyfikuje próby syntezy, które nie osiągnęły pierwotnego celu, ale wygenerowały spójne wyniki, przyjmując je jako prawidłowe rozwiązania nowych, syntetycznych problemów. Tworzy to „refleksyjny gradient uczenia się” (ang. reflexive learning gradient), przesuwając paradygmat od pasywnego dopasowywania do aktywnej, generatywnej eksploracji danej dziedziny.

Podsumowując, stwierdzam, że przyjęte i zrealizowane metody badawcze są poprawne, właściwie zaprojektowane oraz eksperymentalnie zweryfikowane. Wadą rozprawy jest bardzo szeroki wachlarz tematyczny, w ramach którego podjęto szereg ciekawych wyzwań, które zostały zweryfikowane w bardzo wąskim zakresie z umiarkowanym odniesieniem do aktualnego stanu wiedzy (tj. znanych prac badawczych z ostatnich pięciu lat – więcej na ten temat w sekcji 4 niniejszej recenzji).

4. Wiedza kandydata

W rozdziałach 2, 6, 10 Doktorant opisuje podstawowe zagadnienia związane z tematyką rozprawy, które stanowią wprowadzenie tematyczne do każdej z części rozprawy.

Przedstawia w nich syntetyczną wiedzę w zakresie tematyki wyraźnie związaną z dyscypliną informatyka techniczna i telekomunikacja.

W rozprawie oraz publikacjach Doktorant podejmuje i analizuje złożone zagadnienia związane z projektowaniem architektur modeli sieci neuronowych, przygotowaniem i podziałem danych, metodami przetwarzania wstępnego (m.in. definiowania nowych deskryptorów), definicją i wykorzystaniem metryk trenowania i testowania modeli, itd. Ponadto wyraźnie pokazał umiejętności techniczne związane z koniecznością implementacji architektur sieci neuronowych, procesu treningu, walidacji i testowania modeli, itd.

Cytowane są łącznie tylko dwie publikacje naukowe z lat 2025-2026 i są to publikacje własne Doktoranta. Trzy cytowane publikacje pochodzą z 2024 roku (w tym jedna własna). Ponadto cytowanych jest pięć pozycji z 2023 roku oraz dwie z 2022 roku. Oznacza to, że z ostatnich pięciu lat Doktorant cytuje jedynie 9 obcych prac. Uważam, że w dobie intensywnego rozwoju badań naukowych w tematyce rozprawy jest to zdecydowanie mało, co mogłoby świadczyć o umiarkowanej wiedzy Doktoranta na temat najnowszych osiągnięć naukowych w tematyce powiązanej z doktoratem. Przykładowo, tylko w tematyce ARC + synteza programów + neurosymboliczne reprezentacje + generowanie syntetycznych zadań znajdziemy wiele publikacji z lat 2024-2026, m.in. prezentowanych w ramach konferencji ICLR, NeurIPS, itd.

Niemniej, na podstawie rozprawy i publikacji Doktoranta mogę stwierdzić, że istnieją przesłanki do oceny, że kandydat posiada wystarczającą ogólną wiedzę w dyscyplinie informatyki technicznej i telekomunikacji.

5. Inne uwagi¹

Brak

6. Podsumowanie

Biorąc pod uwagę opinie zaprezentowane w poprzednich punktach i wymagania zdefiniowane przez art. 187 Ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (z późniejszymi zmianami)² moja ocena rozprawy pod względem trzech podstawowych kryteriów jest następująca:

A. Czy rozprawa zawiera oryginalne rozwiązanie problemu naukowego? (wybierz jedną opcję stawiając znak X)

☒	☐	☐	☐	☐
Zdecydowanie TAK	Raczej TAK	Trudno powiedzieć	Raczej NIE	Zdecydowanie NIE

B. Czy po przeczytaniu rozprawy zgadzasz się, że kandydat posiada ogólną wiedzę teoretyczną w dyscyplinie informatyka techniczna i telekomunikacja?

☐	☒	☐	☐	☐
--------------------------	-------------------------------------	--------------------------	--------------------------	--------------------------

¹ Opcjonalnie

² <http://isap.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20190000276>

<i>Zdecydowanie TAK</i>	<i>Raczej TAK</i>	<i>Trudno powiedzieć</i>	<i>Raczej NIE</i>	<i>Zdecydowanie NIE</i>
C. Czy kandydat posiada umiejętność samodzielnego prowadzenia pracy naukowej?				
☒	☐	☐	☐	☐
<i>Zdecydowanie TAK</i>	<i>Raczej TAK</i>	<i>Trudno powiedzieć</i>	<i>Raczej NIE</i>	<i>Zdecydowanie NIE</i>

Ze względu na wartościowe publikacje w zakresie opracowanych metod i wyników badań związanych z rozprawą, rozprawa potencjalnie może zostać wyróżniona. Jednak taką rekomendację pozostawiam sobie po uzyskaniu odpowiedzi na pytania w toku dalszego postępowania.

Podpis