



POZNAN UNIVERSITY OF TECHNOLOGY

FACULTY OF COMPUTING AND TELECOMMUNICATIONS

Institute of Computing Science

DOCTORAL THESIS

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

mgr inż. Jakub Bednarek

Supervisor

prof. dr hab. inż. Krzysztof Krawiec

Poznań, 2026

Abstract

The scientific pursuit of artificial intelligence has historically alternated between two distinct paradigms: connectionist, which excels at intuitive pattern recognition but lacks casual transparency, and classical symbolic reasoning, which provides rigorous logical consistency but struggles with the stochasticity of the real world. To resolve this dichotomy, the thesis evaluates composite **neuro-symbolic architectures** designed to learn and reason in both empirical (real-world) and generative (abstract) domains.

At the core of this research is the hypothesis of **structural isomorphism**—the proposition that the underlying mechanisms required to transform physical signals into embodied actions are conceptually and structurally identical to those required to transform visual abstractions into logical programs. To validate this hypothesis, the thesis proposes a unified framework structured around three fundamental cognitive pillars: Sensing, Acting, and Problem Solving.

- **Sensing:** This domain frames Sensing as an active source of discrete symbolic data rather than a passive measurement tool. Deep learning models—employing convolutional and recurrent neural networks—are first introduced to classify and cluster terrain semantics (such as gravel, sand, and asphalt) directly from raw 6D force-torque time-series signals collected during legged locomotion. This perception layer is subsequently integrated into a real-time control loop through a haptic sequential Monte Carlo localization framework. Tested on the ANYmal robot platform, this haptic particle filter fuses symbolic terrain classes with geometric contact constraints against a prior map to bound odometry and yaw drift in vision-denied environments.
- **Acting:** To address the execution bottlenecks and sample inefficiency of traditional analytical solvers and reinforcement learning, a dual-agent **Oracle–Apprentice knowledge distillation framework** is developed. First applied to a quadruped equipped with rigid foot, a neural network (the Apprentice) is trained on synthetic elevation maps to map terrain geometry directly to foothold selection scores, internalizing the non-linear kinematic and collision constraints of a computationally intensive analytical planner (the Oracle). This architecture is then extended to a mechanically adaptive soft foot morphology, where the learned policy captures the non-linear soft-body deformation dynamics. This adaptation reduces planning times from seconds to milliseconds, demonstrating zero-shot transfer from synthetic data to physical hardware.
- **Problem Solving:** Transposing these principles to higher cognitive functions, the sensorimotor loop is applied directly to abstract workspaces. The technical baseline is established by proposing the Structure-Aware Program Synthesis framework, showing that a connectionist architecture can map natural language specifications into syntactically correct abstract syntax tree tokens without rule-based post-processing. This approach is then expanded into the TransCoder architecture to address the heterogeneous visual grid puzzles of the Abstract Reasoning Corpus. TransCoder couples raster self-attention encoders with a variational program generator operating over a rigid Domain Specific Language. This process is driven by a **task generation mechanism** utilizing a “learning from mistakes” paradigm. By re-contextualizing failed execution traces as successful solutions to newly synthesized tasks, the system establishes a learning gradient through self-simulation, serving as a cognitive counterpart to physical sensorimotor feedback.

This thesis validates **generative simulation** as a scalable substitute for large, human-annotated datasets. Integrating neural learning within structured symbolic boundaries—ranging from physical equations of motion to formal grammars—provides a pathway toward self-correcting agents capable of zero-shot generalization in real and abstract worlds.

More broadly, this work addresses the limitations of purely data-driven end-to-end learning. The resulting architecture grounds high-dimensional statistical pattern matching (System 1) within the symbolic structures of human reason (System 2). Because logical simulation yields a learning gradient comparable to physical feedback, reasoning functions here as a generalized form of action. These insights provide the motivation to surpass static training distributions, allowing autonomous neuro-symbolic agents to learn dynamically from execution errors across both physical and logical domains.

Streszczenie

Badania nad sztuczną inteligencją historycznie oscylowały między dwoma odrębnymi paradygmatami: koneksjonistycznym głębokim uczeniem, które doskonale radzi sobie z intuicyjnym rozpoznawaniem wzorców, lecz cierpi na brak przejrzystości przyczynowo-skutkowej, oraz klasycznym wnioskowaniem symbolicznym, zapewniającym spójność logiczną, lecz słabo radzącym sobie ze stochastyczną naturą świata rzeczywistego. Aby przełamać tę dychotomię, w niniejszej rozprawie poddano ocenie złożone **architektury neurosymboliczne**, zaprojektowane do jednoczesnego uczenia się i wnioskowania zarówno w domenach empirycznych (rzeczywistych), jak i generatywnych (abstrakcyjnych).

U podstaw podjętych badań leży hipoteza „**structural isomorphism**” (izomorfizmu strukturalnego)—założenie, że mechanizmy do transformacji sygnałów fizycznych w rzeczywiste akcje są koncepcyjnie i strukturalnie tożsame z mechanizmami mapowania wizualnych abstrakcji na programy logiczne. W celu weryfikacji tej hipotezy zaproponowano spójną strukturę systemu zorganizowaną wokół trzech fundamentalnych filarów kognitywnych: Sensing, Acting oraz Problem Solving.

- **Sensing:** W tej domenie Sensing przyjmuje funkcję źródła dyskretnych danych symbolicznych, zamiast pasywnego narzędzia pomiarowego. W pierwszej kolejności zostały zaprezentowane modele głębokiego uczenia, wykorzystujące konwolucyjne oraz rekurencyjne sieci neuronowe, w zadaniu klasyfikacji i klastrowania typów podłoża (takich jak żwir, piasek czy asfalt) bezpośrednio na podstawie surowych sześciowymiarowych szeregów czasowych sił i momentów obrotowych, rejestrowanych podczas ruchu robota kroczącego. Ta warstwa percepcji następnie zintegrowana została z pętlą sterowania w czasie rzeczywistym poprzez haptyczny algorytm lokalizacji oparty na sekwencyjnej metodzie Monte Carlo. Haptyczny filtr cząsteczkowy, przetestowany na platformie robotycznej ANYmal, integruje przewidywane klasy terenu z geometrycznymi ograniczeniami kontaktu w odniesieniu do znanej mapy terenów otoczenia, co pozwala skutecznie ograniczyć dryf odometrii oraz obrotu w warunkach całkowitego braku widoczności.
- **Acting:** Aby wyeliminować ograniczenia obliczeniowe oraz niską efektywność próbkowania tradycyjnych solverów analitycznych i uczenia ze wzmocnieniem, opracowano dwuagentowy schemat destylacji wiedzy **Oracle–Apprentice**. Początkowo—dla robota wyposażonego w sztywną stopę—sieć neuronowa (Apprentice) jest trenowana na syntetycznych mapach wysokości, ucząc się bezpośredniego mapowania geometrii terenu na natychmiastowy (ang. *single-shot*) wybór punktów podparcia. Proces ten pozwala na internalizację nieliniowych ograniczeń kinematycznych i kolizyjnych wymagającego obliczeniowo planisty analitycznego (Oracle). Architektura tę rozszerzono następnie na adaptacyjną morfologię deformowalnych stóp, gdzie wyuczona polityka sterowania skutecznie odtwarza złożoną, nieliniową dynamikę odkształceń. Podejście to redukuje czas planowania z rzędu sekund do poziomu milisekund, demonstrując transfer typu *zero-shot* z danych syntetycznych bezpośrednio na fizyczny sprzęt.
- **Problem Solving:** Przenosząc te zasady na wyższe funkcje kognitywne, pętla sensoryczno-motoryczna została zaadaptowana bezpośrednio do przestrzeni abstrakcyjnej. Początkowo, zaproponowano architekturę Structure-Aware Program Synthesis, pokazując, że czysto koneksjonistyczna architektura jest w stanie mapować specyfikacje wyrażone w języku naturalnym na strukturalnie poprawne drzewa składniowe bez potrzeby stosowania dodatkowych heurystyk naprawiających. Podejście to rozwinięto następnie w architekturze TransCoder, stworzonej z myślą o rozwiązywaniu heterogenicznych, wizualnych

zadań abstrakcyjnych, pochodzących ze zbioru Abstract Reasoning Corpus. TransCoder łączy rastrowe enkodery wykorzystujące mechanizm *self-attention* z wariacyjnym generatorem programów opierającym działanie o język dziedzinowy. Proces ten napędzany jest przez **mechanizm generowania zadań**, wykorzystujący paradygmat „uczenia się na błędach”. Poprzez zmianę kontekstu, błędnie rozwiązane zadania przedstawione zostały jako nowe syntetyczne zadania, za pomocą których system buduje gradient uczenia w drodze automatycznej symulacji—pełniąc rolę kognitywnego odpowiednika fizycznego sprzężenia zwrotnego.

Niniejsza praca weryfikuje **symulację generatywną** jako skalowalną alternatywę dla dużych, anotowanych przez człowieka zbiorów danych. Osadzenie uczenia neuronowego w sztywnych ramach symbolicznych—od fizycznych równań ruchu po gramatyki formalne—wytycza ścieżkę rozwoju w kierunku samokorygujących się agentów zdolnych do uogólniania wiedzy w świecie rzeczywistym i abstrakcyjnym.

W szerszym kontekście praca ta mierzy się z ograniczeniami czysto statystycznego uczenia w paradygmacie *end-to-end*. Wypracowana architektura osadza wysokowymiarowe, statystyczne rozpoznawanie wzorców (System 1) w strukturach symbolicznych ludzkiego rozumowania (System 2). Ponieważ symulacja logiczna generuje gradient uczenia porównywalny z fizycznym sprzężeniem zwrotnym, wnioskowanie funkcjonuje tutaj jako uogólniona forma podejmowania akcji. Wnioski te stanowią motywację pod przekroczenie ograniczeń statycznych rozkładów danych treningowych, umożliwiając autonomicznym agentom neurosymbolicznym dynamiczną naukę na błędach zarówno w domenie fizycznej, jak i logicznej.