

## Zjazd Polskiego Porozumienia na rzecz Rozwoju Sztucznej Inteligencji 2018

Piotr Skrzypczyński

### Wykład: *Sztuczna inteligencja i uczenie maszynowe w robotyce i systemach autonomicznych: AI/ML w robotyce, robotyka w AI/ML*

Celem krótkiego wykładu, poprzedzającego **Panel 3** poświęcony AI w robotyce i systemach autonomicznych oraz powiązanim zastosowaniom, było pokazanie roli uczenia maszynowego oraz wybranych innych aspektów AI we współczesnej robotyce, a także roli, jaką odegrać może robotyka w rozwoju sztucznej inteligencji i jej aplikacji. Plan wykładu obejmował cztery główne zagadnienia:

- Związki robotyki ze sztuczną inteligencją.
- Dlaczego robotyka potrzebuje AI/ML?
- Czy AI/ML potrzebuje robotyki?
- Kierunki wspólnego rozwoju.

Na wstępie współczesna robotyka została scharakteryzowana jako dyscyplina naukowa ściśle powiązana z informatyką. Wskazano na długą drogę wspólnego rozwoju i wzajemnych inspiracji między czerpiącą z kilku różnych źródeł i kształtującą się jako odrębna dyscyplina nauki robotyką, a "Good Old-Fashioned Artificial Intelligence", czyli symboliczną AI, systemami ekspertowymi, algorytmami planowania i reprezentacji wiedzy. Jako najważniejszy przykład tych wczesnych wzajemnych powiązań przedstawiona robota "Shakey" [1], który został stworzony w SRI International przy udziale Nilsa Nilssona i Petera Harta.

Następnie scharakteryzowany został zakres najważniejszych zastosowań sztucznej inteligencji we współczesnej robotyce, obejmujący metody planowania ruchów i działań [2,3], zbieranie oraz interpretację danych o środowisku prowadzące do powstania modelu świata robota [4,5] oraz klasyczne metody uczenia (np. uczenie ze wzmocnieniem [6]). Zwrócono uwagę na specyficzne problemy, które ujawniają się podczas aplikacji metod AI w robotyce, takie jak konieczność przeszukiwania wielowymiarowych przestrzeni rozwiązań ("curse of dimensionality") oraz stale obecny problem reprezentacji i uwzględniania we wnioskowaniu niepewności rzeczywistych danych. Podano kilka przykładów aplikacji robotów autonomicznych, które zakończyły się sukcesem dzięki umiejętnemu wykorzystaniu osiągnięć AI, a szczególnie probabilistycznej reprezentacji wiedzy i uczenia maszynowego. Przykładów takich dostarczyły między innymi konkursy DARPA "Grand Challenge", "Urban Challenge" i "Robotics Challenge" (DRC) oraz "Amazon Picking Challenge", świadczący o zainteresowaniu wielkiej korporacji rozwojem robotyki opartej na AI [7].

W trzeciej części wykładu zaprezentowane zostały wybrane nowe możliwości jakie daje uczenie maszynowe oraz zwiększenie dostępności danych treningowych. Przedstawiony został zwięzły przegląd najpopularniejszych obszarów zastosowań uczenia maszynowego w robotyce oraz innych systemach autonomicznych (np. *self-driving cars*) wraz z typowymi dla tych obszarów paradygmatami uczenia maszynowego. Skoncentrowano się na znajdującym coraz więcej zastosowań paradygmacie uczenia głębokiego (*deep learning*), głównie z wykorzystaniem konwolucyjnych sieci neuronowych. Przedstawiono trzy obszary, w których uczenie maszynowe w robotyce wyróżnia się na tle ogólnych zastosowań ML, a robotyka stawia trudne wyzwania i jest polem do poszukiwania nowych rozwiązań. Pierwszy z tych obszarów to metody uczenia, gdzie "otwarty" świat działania robota autonomicznego stwarza konieczność zmierzenia się z problemami identyfikacji nieznanymi klasami [8] i uczenia inkrementalnego [9], a dane dostarczane przez sensory robota obciążone są niepewnością [10]. Jednocześnie robot ma możliwości aktywnego pozyskiwania wiedzy [11], choćby poprzez ruch sensora, czego nie wykorzystuje większość znanych metod uczenia. Obszar drugi to wnioskowanie o scenie, gdzie w przypadku robotyki przenikają się semantyka i geometria [12], gdyż robot musi działać w świecie trójwymiarowym, choć postrzega go często poprzez dwuwymiarowe obrazy [13,14]. Najważniejszą cechą robotów wyróżniającą je spośród wszystkich uczących się agentów (programowych) jest jednak posiadanie fizycznego "ciała". Robot jest agentem upostaciowionym (*embodied agent*), co skłania do analizowania przez algorytmy uczące się nie pojedynczych instancji informacji (np. odrębnych obrazów) lecz ich sekwencji, które mogą być rozpięte zarówno w czasie, jak i w przestrzeni [15]. Otwiera to nowe możliwości tworzenia metod uczenia wykorzystujących zależności i konteksty zbliżone do tych, które jak się wydaje leżą u podstaw ogromnych zdolności do generalizacji wiedzy i wyuczonej strategii działania (*policy*) jaką posiadają ludzie. Roboty wspierają zaawansowane metody uczenia dzięki możliwości interakcji ze światem zewnętrznym - prostym przykładem jest wizja aktywna, znacznie bardziej złożonym manipulacja z aktywnym badaniem zachowania się obiektów (przestawianie, popychanie) [16].

Na zakończenie wykładu, w kontekście specyficznych potrzeb i ograniczeń charakterystycznych dla robotyki, zaprezentowane zostały nowe koncepcje uczenia maszynowego aplikowane do systemów autonomicznych (np. *deep reinforcement learning* [17], koncepcja *interactive perception* [18]). W podsumowaniu wymienione zostały najważniejsze wyzwania praktyczne (aplikacyjne) współczesnej robotyki oraz związane z nimi otwarte problemy uczenia maszynowego. Zwrócono uwagę na mający kluczowe znaczenie

dla wdrażania w praktyce rozwiązań technicznych opartych na AI/ML problem *explainable AI* - wyniki działania AI w robotyce muszą być przewidywalne, a w niektórych zastosowaniach konieczna jest certyfikacja [19]. Ponadto sposób działania i podejmowane decyzje w systemie fizycznym (np. autonomiczny samochód) powinny być zrozumiałe dla ludzi. Kluczowe znaczenie dla rozwoju robotyki i systemów autonomicznych w ogólniejszym sensie ma też opracowanie efektywnych metod uczenia w symulacji i radzenia sobie z problemem *reality gap* [20], a także problem efektywnego uczenia na podstawie małej liczby przykładów (*one-shot learning*) [21] oraz generalizacji dla nieznanymi wcześniej klas lub przykładów (*zero-shot learning*) [22]. W praktycznych zastosowaniach układów fizycznych wykorzystujących ML preferowane jest uczenie nie nadzorowane lub uczenie na podstawie demonstracji dokonanej przez człowieka. Jako przykład obszaru robotyki, w którym postęp w tej dziedzinie ma fundamentalne znaczenie dla możliwości szerszego wdrażania podano roboty kooperacyjne. Są one postrzegane jako szansa robotyzacji w małych i średnich innowacyjnych przedsiębiorstwach, wpisując się w koncepcje "Industry 4.0", jednak szansę tę będzie można w pełni wykorzystać dopiero mając do dyspozycji narzędzia interaktywnego programowania dostępne dla personelu bez kwalifikacji technicznych. Narzędzia te muszą więc być oparte na uczeniu maszynowym [23].

## Literatura

- [1] R. Fikes, P. E. Hart, N. J. Nilsson, "Learning and executing generalized robot plans". *Artificial Intelligence*, 3(4), 1972.
- [2] D. Belter, P. Łabęcki, P. Skrzypczyński, "Adaptive motion planning for autonomous rough terrain traversal with a walking robot". *Journal of Field Robotics*, 33(3), 2016.
- [3] S. Tonneau et al., "An efficient acyclic contact planner for multiped robots". *IEEE Transactions on Robotics*, 34(3), 2018.
- [4] S. Thrun, "Learning metric-topological maps for indoor mobile robot navigation". *Artificial Intelligence*, 99(1), 1998.
- [5] C. Cadena et al., "Past, present, and future of simultaneous localization and mapping: Toward the robust-perception age", *IEEE Transactions on Robotics*, 32(6), 2016.
- [6] J. Kober, J. Peters, "Reinforcement learning in robotics: A survey", In: *Learning Motor Skills*. STAR, Vol 97, Springer, 2014.
- [7] C. Eppner et al., "Lessons from the Amazon Picking Challenge: Four aspects of building robotic systems", *International Joint Conference on Artificial Intelligence*, Melbourne, 2017.
- [8] W. Scheirer et al., "Toward open set recognition". *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(7), 2013.
- [9] G. Csurka, "Domain adaptation for visual applications: A comprehensive survey", *arXiv preprint*, 2017.
- [10] Y. Gal, Z. Ghahramani, "Dropout as a Bayesian approximation: Representing model uncertainty in deep learning", *International Conference on Machine Learning*, 2016.
- [11] F. Dayoub, N. Sunderhauf, P. Corke, "Episode-based, active learning with Bayesian neural networks". *CVPR Workshop on Deep Learning for Robotic Vision*, 2017.
- [12] D. Lin, S. Fidler, R. Urtasun, "Holistic scene understanding for 3D object detection with RGBD cameras". *IEEE International Conference on Computer Vision*, 2013.
- [13] X. Yan, J. Yang, E. Yumer, Y. Guo, H. Lee, "Perspective transformer nets: Learning single-view 3D object reconstruction without 3D supervision". *NIPS*, 2016.
- [14] S. Pillai, J. Leonard, "Monocular SLAM supported object recognition", *Robotics: Science and Systems*, 2015.
- [15] N. Atanasov, B. Sankaran, J. Le Ny, G. J. Pappas, K. Daniilidis, "Nonmyopic view planning for active object classification and pose estimation". *IEEE Transactions on Robotics*, 30(5), 2014.
- [16] D. Holz et al., "Active recognition and manipulation for mobile robot bin picking". In: *Gearing Up and Accelerating Crossfertilization between Academic and Industrial Robotics Research in Europe*, STAR Vol. 94, Springer, 2014.
- [17] T. P. Lillicrap et al., "Continuous control with deep reinforcement learning". *CoRR*, abs/1509.02971, 2015
- [18] J. Bohg et al., "Interactive perception: Leveraging action in perception and perception in action", *IEEE Transactions on Robotics*, 33(6), 2017.
- [19] S. Wachter, B. Mittelstadt, L. Floridi, "Transparent, explainable, and accountable AI for robotics", *Science Robotics*, 2(6), 2017.
- [20] D. Belter, P. Skrzypczyński, "A biologically inspired approach to feasible gait learning for a hexapod robot", *International Journal of Applied Mathematics and Computer Science*, 20(1), 2010
- [21] L. Fei-Fei, R. Fergus, P. Perona, "One-shot learning of object categories". *IEEE Trans. Pattern Analysis and Machine Intelligence*, 28(4), 2006.
- [22] Y. Guo et al., "Zero-shot learning with transferred samples", *IEEE Transactions on Image Processing*, 26(7), 2017.
- [23] M. Kopicki et al., "One shot learning and generation of dexterous grasps for novel objects". *International Journal of Robotics Research*, 35(8), 2016.