



Karta przedmiotu

Nazwa i kod przedmiotu	Sieci samouczące się, PG_00054190						
Kierunek studiów	Informatyka						
Data rozpoczęcia studiów	luty 2024 r.		Rok akademicki realizacji przedmiotu		2024/2025		
Poziom kształcenia	II stopnia		Grupa zajęć		Grupa zajęć fakultatywnych Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	1		Język wykładowy		polski		
Semestr studiów	2		Liczba punktów ECTS		3.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydział Elektroniki, Telekomunikacji i Informatyki -> Katedra Systemów Multimedialnych						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Jerzy Dembski				
	Prowadzący zajęcia z przedmiotu		dr inż. Jerzy Dembski				
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	15.0	0.0	30.0	0.0	0.0	45
	W tym liczba godzin zajęć na odległość: 0.0						
Aktywność studenta i liczba godzin pracy	Aktywność studenta	Udział w zajęciach dydaktycznych, objętych planem studiów		Udział w konsultacjach		Praca własna studenta	RAZEM
	Liczba godzin pracy studenta	45		5.0		25.0	75
Cel przedmiotu	Celem przedmiotu jest przekazanie studentowi wiedzy w zakresie teoretycznych i praktycznych aspektów definiowania i projektowania sztucznych sieci neuronowych zdolnych do samodzielnego uczenia się rozwiązywania złożonych problemów decyzyjnych, w tym do aproksymacji funkcji użyteczności stanów lub akcji w uczeniu ze wzmocnieniem.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K7_W05] zna i rozumie w pogłębionym stopniu metody wspomaganie procesów i funkcji, specyficzne dla kierunku studiów		Student zna podstawowe definicje i zagadnienia związane z uczeniem ze wzmocnieniem i uczeniem sztucznych sieci neuronowych.		[SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym [SW1] Ocena wiedzy faktograficznej		
	[K7_U11] potrafi kierować pracą zespołu		Student potrafi podzielić złożone zadanie z użyciem sieci samouczącej się na podzadania oraz koordynować pracę członków zespołu realizujących poszczególne podzadania.		[SU1] Ocena realizacji zadania		
	[K7_U06] potrafi analizować działanie elementów, układów i systemów związanych z kierunkiem studiów oraz mierzyć ich parametry i badać charakterystyki techniczne, interpretować uzyskane wyniki i wyciągać wnioski		Student potrafi przełożyć wiedzę nabytą podczas wykładu i indywidualnych studiów nad dziedziną na zagadnienia praktyczne wymagające planowania eksperymentów i analizy wyników.		[SU3] Ocena umiejętności wykorzystania wiedzy uzyskanej w ramach przedmiotu [SU1] Ocena realizacji zadania		
	[K7_W03] zna i rozumie w pogłębionym stopniu budowę i zasady działania komponentów i systemów związanych z kierunkiem studiów, w tym teorie, metody i złożone zależności między nimi oraz wybrane zagadnienia szczegółowe – właściwe dla programu kształcenia		Student rozumie wieloetapowe procesy decyzyjne, proces decyzyjny Markowa oraz zagadnienia związane z metodami uczenia ze wzmocnieniem z neuronową aproksymacją funkcji użyteczności stanów lub akcji.		[SW1] Ocena wiedzy faktograficznej		

Treści przedmiotu	<p>1. Omówienie zasad prowadzenia wykładu i laboratorium. Omówienie katalogu pojęć i podstaw matematycznych niezbędnych do przyswojenia zagadnień poruszanych podczas wykładu.</p> <p>2 Omówienie koncepcji uczenia ze wzmacnianiem. Różnice i możliwości w stosunku do metod nadzorowanych i nienadzorowanych. Przykłady typowych zastosowań i ograniczenia.</p> <p>3 Podstawy uczenia ze wzmacnianiem. Wprowadzenie pojęć wykorzystywanych w uczeniu ze wzmacnianiem. Wprowadzenie do zasad gromadzenia doświadczenia i wiedzy w uczeniu ze wzmacnianiem.</p> <p>4 Omówienie procesu decyzyjnego Markova</p> <p>5 Omówienie maksymalnego zwrotu (Return) i oczekiwanego zwrotu (Value function)</p> <p>6 Omówienie równania Bellmana</p> <p>7 Omówienie procesu uczenia ze wzmacnianiem. Prediction problem vs Control problem.</p> <p>8 Techniki uczenia ze wzmacnianiem cz. I. Dylemat Explore-Exploit. Metoda Epsilon-Greedy. Przykłady zastosowań i ograniczenia.</p> <p>9 Techniki uczenia ze wzmacnianiem cz II. Metoda Monte Carlo. Metody Temporal-Difference. Metoda Q-Learning. Przykłady zastosowań i ograniczenia.</p> <p>10 Definicja zagadnienia praktycznego do rozwiązania z wykorzystaniem uczenia ze wzmacnianiem.</p> <p>11 Dobór optymalnego modelu uczenia ze wzmacnianiem do rozwiązywanego zagadnienia praktycznego. Definicja agenta, środowiska i epizodu. Definicja stanu i akcji. Definicja nagrody.</p> <p>12 Dobór optymalnego modelu sztucznej sieci neuronowej do rozwiązywanego zagadnienia praktycznego. Rodzaje warstw w sieciach neuronowych. Rodzaje architektur sieci neuronowych. Funkcje aktywacji. Funkcje straty. Dane wejściowe i wyjściowe. <i>(W uczeniu ze wzmacnianiem nie ma stałego zbioru uczącego i typowe techniki dla uczenia nadzorowanego nie zawsze się sprawdzają. W toku wykładu konieczne jest tu skupienie się na osiągnięciu jak najlepszych efektów uczenia (w tym wypadku poziomu gry sieci neuronowej), a to wymaga optymalizowania i po stronie samej sieci i po stronie algorytmów działania agenta. Sieci neuronowe i agenci zaczęłyby osiągać maksimum ich możliwości, a studenci zaczęliby zastanawiać się dlaczego. Warto wrócić do prezentowanej wcześniej matematyki, gdyż studenci znaczną rozumieć wynikające z niej implikacje.)</i></p> <p><i>Można skrócić wykłady w tym miejscu i dodać jeszcze jeden wykład, dotyczący nieprzewidywalności w przypadku długich epizodów. Można by przy tej okazji wpleść w wykład elementy teorii chaosu.</i></p> <p>13 Problemy uczenia sztucznych sieci neuronowych (przeuczanie, brak postępów). Zasady i techniki doboru optymalnej wielkości modelu. Zasady i techniki niwelujące problem przeuczania i poprawiające zdolność sieci neuronowej do generalizacji (Regularyzacja. Dropout). Zasady i techniki optymalizacji procesu uczenia.</p> <p>14 Podsumowanie. Omówienie i porównanie wyników projektów laboratoryjnych.</p> <p>15 Trendy i osiągnięcia światowe (DeepMind. OpenAI). Alternatywne metody samouczenia.</p>											
Wymagania wstępne i dodatkowe	<p>- znajomość algebry liniowej na poziomie podstawowym</p> <p>- znajomość teorii prawdopodobieństwa na poziomie podstawowym</p>											
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table border="1"> <tr> <td>Sposób oceniania (składowe)</td> <td>Próg zaliczeniowy</td> <td>Składowa oceny końcowej</td> </tr> <tr> <td>ocena z laboratorium</td> <td>60.0%</td> <td>50.0%</td> </tr> <tr> <td>ocena z wykładu</td> <td>60.0%</td> <td>50.0%</td> </tr> </table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	ocena z laboratorium	60.0%	50.0%	ocena z wykładu	60.0%	50.0%		
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej										
ocena z laboratorium	60.0%	50.0%										
ocena z wykładu	60.0%	50.0%										

Zalecana lista lektur	Podstawowa lista lektur	<p>Richard Sutton, Andrew G. Barto, Reinforcement Learning: An Introduction, MIT Press, Cambridge, MA, 2018. http://incompleteideas.net/book/the-book-2nd.html</p> <p>Paweł Cichosz, Systemy uczące się, Wydawnictwa Naukowo-Techniczne, Warszawa 2000, str. 712-792.</p> <p>Lillicrap, T.P., Hunt, J.J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D.: Continuous control with deep reinforcement learning. In: Bengio, Y., LeCun, Y. (eds.) ICLR (2016) Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A.A., Veness, J., Bellemare, M.G., Graves, A., Haderin, M., Fiedorowicz, M., Högström, A.K., Sutskever, I., Gruninger, G., et al.: Human-level control through deep reinforcement learning. nature 518(7540), 529-533 (2015)</p>
	Uzupełniająca lista lektur	<p>Silver, David; Hubert, Thomas; Schrittwieser, Julian; Antonoglou, Ioannis; Lai, Matthew; Guez, Arthur; Lanctot, Marc; Sifre, Laurent; Kumaran, Dharshan; Graepel, Thore; Lillicrap, Timothy; Simonyan, Karen; Hassabis, Demis (December 5, 2017). "Mastering Chess and Shogi by Self-Play with a General Reinforcement Learning Algorithm". arXiv:1712.01815</p>
	Adresy eZasobów	<p>Adresy na platformie eNauczanie:</p> <p>Sieci samouczące się - Moodle ID: 41336 https://enauczanie.pg.edu.pl/moodle/course/view.php?id=41336</p>
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	<p>Zrozumienie procesu decyzyjnego Markowa i idei równania Bellmana</p> <p>Osadzenie przykładowego problemu w modelu uczenia ze wzmocnieniem:</p> <p>dobór właściwej definicji stanu</p> <p>dobór właściwej definicji akcji</p> <p>dobór właściwej funkcji nagrody</p> <p>Zaprojektowanie architektury sieci neuronowej właściwej do analizowanego problemu:</p> <p>dobór ilości i typu warstw</p> <p>dobór funkcji aktywacji</p> <p>dobór funkcji straty</p> <p>Wyciąganie wniosków z procesu uczenia sieci:</p> <p>przeuczanie się sieci</p> <p>brak postępów uczenia</p> <p>Umiejętność tworzenia, uczenia i analizy modeli w systemie Tensorflow 2.x</p>	
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy	