



Karta przedmiotu

Nazwa i kod przedmiotu	Sieci samouczące się, PG_00054190						
Kierunek studiów	Informatyka						
Data rozpoczęcia studiów	luty 2023 r.	Rok akademicki realizacji przedmiotu			2023/2024		
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)	Od 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_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		
	[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.			[SU1] Ocena realizacji zadania [SU3] Ocena umiejętności wykorzystania wiedzy uzyskanej w ramach przedmiotu		
	[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_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.			[SW1] Ocena wiedzy faktograficznej [SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym			

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	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	ocena z wykładu	60.0%	50.0%
	ocena z laboratorium	60.0%	50.0%

Zalecana lista lektur	Podstawowa lista lektur	Richard Sutton, Andrew G. Barto, Reinforcement Learning: An Introduction, MIT Press, Cambridge, MA, 2018. http://incompleteideas.net/book/the-book-2nd.html Paweł Cichosz, Systemy uczące się, Wydawnictwa Naukowo-Techniczne, Warszawa 2000, str. 712-792. 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., Höglinger, G., Sprechler, A., Petersen, S., Nair, A., Kalchbrenner, J., Sutskever, I., Silver, D., LeCun, Y., Bengio, Y., et al.: Human-level control through deep reinforcement learning. nature 518(7540), 529-533 (2015)
	Uzupełniająca lista lektur	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
	Adresy eZasobów	Adresy na platformie eNauczanie:
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	