

Karta przedmiotu

Nazwa i kod przedmiotu	Uczenie maszynowe, PG_00063394						
Kierunek studiów	Nanotechnologia						
Data rozpoczęcia studiów	październik 2024 r.		Rok akademicki realizacji przedmiotu		2026/2027		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć		Grupa zajęć obowiązkowych z zakresu kierunku studiów Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	3		Język wykładowy		polski		
Semestr studiów	5		Liczba punktów ECTS		4.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Fizyki Technicznej i Matematyki Stosowanej -> Instytut Fizyki i Informatyki Stosowanej -> Zakład Fizyki Teoretycznej i Informatyki Kwantowej						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Paweł Syty				
	Prowadzący zajęcia z przedmiotu						
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		50.0	100
Cel przedmiotu	Celem przedmiotu jest zaznajomienie studentów z zagadnieniami (algorytmami, narzędziami, technikami) uczenia maszynowego (w tym elementami uczenia głębokiego), głównie z wykorzystaniem sieci neuronowych (w tym sieci spłotowych), a także z metodami programowania wybranych metod oraz praktycznym wykorzystaniem gotowych narzędzi.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K6_U03] posiada umiejętność programowania w wybranym języku oraz stosowania wybranych pakietów oprogramowania.		Student potrafi zaimplementować podstawowe algorytmy uczenia maszynowego w języku Python. Student potrafi wykorzystać gotowe biblioteki programistyczne i pakiety obliczeniowe do realizacji zaawansowanych obliczeń z dziedziny uczenia maszynowego.		[SU1] Ocena realizacji zadania [SU4] Ocena umiejętności korzystania z metod i narzędzi [SU5] Ocena umiejętności zaprezentowania wyników realizacji zadania		
	[K6_W02] ma systematyczną wiedzę z zakresu matematyki wyższej, obejmującą analizę matematyczną, algebrę liniową z elementami geometrii, metody numeryczne, podstawy rachunku prawdopodobieństwa.		Student zna i rozumie podstawowe algorytmy uczenia maszynowego. Student potrafi wybrać odpowiedni algorytm do danego zadania.		[SW1] Ocena wiedzy faktograficznej [SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym		
	[K6_W04] ma wiedzę o narzędziach informatycznych (procesorach tekstu, arkuszach kalkulacyjnych, itd.), tworzeniu prezentacji multimedialnych oraz programowaniu i grafice komputerowej.		Student zna i rozumie podstawowe zastosowania wybranych narzędzi uczenia maszynowego.		[SW1] Ocena wiedzy faktograficznej		

Treści przedmiotu	Wykład
	1. Historia i definicja uczenia maszynowego. Omówienie zastosowań uczenia maszynowego. Podział metod uczenia maszynowego. Rola danych i ich jakości w uczeniu maszynowym. Przygotowywanie danych do procesu uczenia. Wstęp do języka Python. 2. Wiedza niedoskonała w uczeniu maszynowym. Metody radzenia sobie z niedoskonałością wiedzy. Wnioskowanie bayesowskie. Logika rozmyta. 3. Podstawy biologiczne sztucznych sieci neuronowych. Układ nerwowy zwierząt i człowieka – podział i funkcje. Odbiór i przetwarzanie bodźców przez mózg. Neuron budowa, systematyka. Przejawy życiowe neuronów. Pamięć. Dyskusja możliwości i ograniczeń związanych z odwzorowywaniem układów biologicznych w postaci sztucznych systemów. 4. Historia i podstawy sieci neuronowych. Podstawowy model komórki nerwowej perceptron prosty i jego właściwości. Perceptron prosty jako uogólnienie regresji liniowej. Podstawowe metody uczenia perceptronu. Ograniczenia pojedynczego perceptronu. Łączenie perceptronów w większe struktury. Podstawowa klasyfikacja architektur sztucznych sieci neuronowych. Wstępna klasyfikacja zastosowań sieci neuronowych. Cechy sztucznych sieci neuronowych predestynujące je do zastosowań we współczesnym świecie. 5. Sieci jednokierunkowe jednowarstwowe. Budowa, metody uczenia, zastosowania, ograniczenia. Mapa wag. Hiperparametry. Metryki. Kodowanie danych. 6. Sieci jednokierunkowe wielowarstwowe. Budowa, metody uczenia, zastosowania, ograniczenia. Więcej o metodach uczenia sieci metoda propagacji wstecznej, metoda momentum (w tym metoda Nesterova). Omówienie wybranych optymalizatorów (SGD, RMSprop, Adam). Inicjalizacja modelu. Funkcje aktywacji. 7. Zdolność uogólniania sieci neuronowej. Miary zdolności uogólniania. Twierdzenie Kołmogorowa. Zbiór uczący (treningowy), walidujący i testowy. Przeuczenie i niedouczenie sieci. Metody regularyzacji. Dobór optymalnej architektury sieci. Proces redukcji wymiaru sieci. Warstwy Dropout. 8. Sieci splotowe. Budowa, metody uczenia, zastosowania, ograniczenia. Operacja splotu (konwolucja). Warstwy łączące (pooling). Filtry. Biblioteka OpenCV. Metody i architektury sieci neuronowych do rozpoznawania obrazów. Sieci typu Lenet, VGGNet. Klasyfikacja wieloetykietowa. Augmentacja danych. 9. Sieci autoasocjacyjne. Transfer learning. Walidacja krzyżowa. Elementy wyjaśnialnej sztucznej inteligencji. 10. Sieci rekurencyjne. Budowa, metody uczenia, zastosowania, ograniczenia. Pamięci asocjacyjne. Komórki LSTM i GRU. 11. Strategie gier dwuosobowych. Algorytm MINIMAX. Funkcja heurystyczna. Przycinanie alfa-beta. Idea self-play. 12. Automaty komórkowe ze szczególnym uwzględnieniem ich zastosowania w uczeniu maszynowym. 13. Pozostałe metody uczenia maszynowego: k-najbliższych sąsiadów, maszyna wektorów nośnych (SVM), drzewo decyzyjne, las losowy, algorytmy ewolucyjne, liniowe modele mieszane. Metody zespołowe (ensemble). 14. Elementy uczenia nienadzorowanego. Analiza skupień. Algorytm centroidów (k-means). Analiza szeregów czasowych. Algorytm k-shape i DTW (Dynamic Time Warping). 15. Elementy języka Prolog. Zapis predykatów. Wnioskowanie wstecz i w przód.
	Laboratorium Podczas zajęć studenci realizują szereg zadań programistycznych związanych z zagadnieniami

	omawianymi na wykładzie. Dodatkowo wykonują jeden większy projekt związany z wybraną przez siebie tematyką związaną z uczeniem maszynowym.		
Wymagania wstępne i dodatkowe	Znajomość podstaw analizy matematycznej i algebry. Znajomość podstaw programowania.		
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	ocena realizacji zadań programistycznych	50.0%	50.0%
	kolokwium zaliczeniowe	50.0%	50.0%
Zalecana lista lektur	Podstawowa lista lektur	Daniel T. Larose, Metody i modele eksploracji danych, PWN 2022 Aurélien Géron, Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow, Wydanie 2, Helion 2023 Robert Johansson Matematyczny Python. Obliczenia naukowe i analiza danych z użyciem NumPy, SciPy i Matplotlib, Helion 2021 Sebastian Raschka, Vahid Mirjalili Python. Machine learning i deep learning. Biblioteki scikit-learn i TensorFlow 2, Helion 2021 Aileen Nielsen, Szeregi czasowe. Praktyczna analiza i predykcja z wykorzystaniem statystyki i uczenia maszynowego, Helion 2020	
	Uzupełniająca lista lektur	Joel Grus, Data science od podstaw. Analiza danych w Pythonie, Helion 2020 Dokumentacja pakietów Keras i Tensorflow	
	Adresy eZasobów		
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Omówienie metod przygotowania danych dla uczenia maszynowego. Implementacja sieci neuronowej do automatycznej klasyfikacji zdjęć SEM.		
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy		

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.