POLITECHNIKA GDAŃSKA

Karta przedmiotu

Nazwa i kod przedmiotu	Uczenie maszynowe, PG_00064483		
Kierunek studiów	Informatyka		
Data rozpoczęcia studiów	luty 2026 r.	Rok akademicki realizacji przedmiotu	2025/2026
Poziom kształcenia	II stopnia	Grupa zajęć	Grupa zajęć fakultatywnych Grupa zajęć specjalnościowych 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	1	Liczba punktów ECTS	3.0
Profil kształcenia	ogólnoakademicki	Forma zaliczenia	egzamin
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Elektroniki, Telekomunikacji i Informatyki -> Katedra Inżynierii Biomedycznej		
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot	prof. dr hab. inż. Jacek Rumiński	
	Prowadzący zajęcia z przedmiotu	mgr inż. Natalia Szarwińska mgr inż. Szymon Zaporowski prof. dr hab. inż. Jacek Rumiński	

Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	0.0	15.0	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	6.0	24.0	75

Cel przedmiotu	Celem przedmiotu jest zdobycie przez studentów wiedzy i umiejętności w zakresie algorytmów uczenia maszynowego, metod wstępnego przetwarzania danych oraz metryk i metod postępowania w ocenie wyników stosowanych algorytmów i modeli.

Efekty uczenia się przedmiotu	Efekt kierunkowy	Efekt z przedmiotu	Sposób weryfikacji i oceny efektu
	[K7_W04] zna i rozumie w pogłębionym stopniu zasady, metody i techniki programowania oraz zasady tworzenia oprogramowania komputerów albo programowania urządzeń lub sterowników wykorzystujących mikroprocesory albo inne elementy lub układy programowalne, specyficznych dla kierunku studiów, a także organizację pracy systemów wykorzystujących komputery lub te urządzenia	Efektem procesu uczenia jest zdobycie przez studenta wiedzy w zakresie implementacji lub wykorzystania bibliotek programistycznych dotyczących praktycznego zastosowania algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych w szczególności w zastosowaniach biomedycznych, bezpieczeństwa osób, prewencji zdrowia, itd.	[SW1] Ocena wiedzy faktograficznej
	[K7_W01] zna i rozumie w pogłębionym stopniu matematykę w zakresie niezbędnym do formułowania i rozwiązywania złożonych zagadnień związanych z kierunkiem studiów	Efektem procesu uczenia jest zdobycie przez studenta wiedzy w zakresie rozumienia definicji algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych.	[SW1] Ocena wiedzy faktograficznej
	[K7_U12] potrafi w pogłębionym stopniu analizować działanie elementów, układów i systemów związanych z kierunkiem studiów oraz mierzyć ich parametry i badać charakterystyki techniczne, a także planować i przeprowadzać eksperymenty związane z kierunkiem studiów, w tym symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski	Efektem procesu uczenia jest zdobycie przez studenta umiejętności przeprowadzenia eksperymentu uczenia maszynowego wraz z interpretacją wyników uczenia maszynowego.	[SU1] Ocena realizacji zadania
	[K7_U01] potrafi wykorzystywać posiadaną wiedzę matematyczną przy formułowaniu i rozwiązywaniu złożonych i nietypowych problemów związanych z kierunkiem studiów, poprzez: – właściwy dobór informacji źródłowych oraz dokonywanie ich krytycznej analizy, syntezy oraz twórczej interpretacji i prezentacji tych informacji, – zastosowanie właściwych metod i narzędzi	Efektem procesu uczenia jest zdobycie przez studenta umiejętności praktycznego zastosowania algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych w szczególności w zastosowaniach biomedycznych, bezpieczeństwa osób, prewencji zdrowia, itd.	[SU1] Ocena realizacji zadania

Treści przedmiotu	Wprowadzenie do uczenia maszynowego (czym jest uczenie maszynowe, klasyfikacje metod uczenia maszynowego) Metody pozyskiwania i przygotowywania danych: oczyszczanie danych, transformacje danych, standaryzacja i normalizacja danych Metody pozyskiwania i przygotowywania danych: integracja i redukcja danych Metody redukcji wielowymiarowości (m.in. PCA, ICA, itp.) Metody reprezentacji danych dla potrzeb uczenia maszynowego Proces pozyskiwania wiedzy z danych Metody generacji charakterystyk uogólniających Metody indukcji reguł i parametry oceny reguł Metody klasyfikacji (wprowadzenie) i metody oceny jakości klasyfikacji (miary, itp.) Metody klasyfikacji nadzorowanej (drzewa decyzyjne, lasy losowe) Metody klasyfikacji nadzorowanej (od Bayesa do klasyfikacji minimalno-odległościowej) Metody klasyfikacji nadzorowanej (SVM) Metody klasyfikacji nienadzorowanej (k-means, ISO-DATA, itp.) Metody optymalizacji charakterystyka Metody optymalizacji metody gradientowe Regresja liniowa Regresja logistyczna Sztuczne sieci neuronowe wprowadzenie, perceptron, uczenie Sztuczne sieci neuronowe MLP, funkcje aktywacji, uczenie cz.1. Sztuczne sieci neuronowe MLP cz.2.
Wymagania wstępne i dodatkowe	- zna podstawy algebry liniowej, analizy matematycznej oraz rachunku prawdopodobieństwa z uwzględnieniem twierdzenia Bayesa - zna podstawy inżynierii oprogramowania (cykl życia oprogramowania, projektowanie oprogramowania, testowanie, itp.). - zna podstawy metod analizy danych - zna podstawy języka Python - potrafi projektować i modelować obiektowo - potrafi wykorzystywać bazy danych
Sposoby i kryteria oceniania osiąganych efektów uczenia się	

Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
Laboratorium	50.0%	50.0%
Zadania domowe	50.0%	10.0%
Egzamin	50.0%	40.0%

Zalecana lista lektur	Podstawowa lista lektur	Deisenroth Marc Peter, Mathematics for Machine Learning, Cambridge University Press, 2020 Sebastian Raschka, Vahid Mirjalili, Python Machine Learning, Packt Publishing, 2019. Aurélien Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems O'Reilly Media; 2nd edition, 2019.
	Uzupełniająca lista lektur	Chris A. Mattmann , Machine Learning with TensorFlow, Second Edition, Manning, 2020
	Adresy eZasobów	Adresy na platformie eNauczanie:
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania		
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy	

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.