

Karta przedmiotu

Nazwa i kod przedmiotu	Uczenie maszynowe, PG_00061911						
Kierunek studiów	Inżynieria materiałowa						
Data rozpoczęcia studiów	październik 2024 r.		Rok akademicki realizacji przedmiotu		2025/2026		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć		Grupa zajęć obowiązkowych z zakresu kierunku studiów		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	2		Język wykładowy		polski		
Semestr studiów	4		Liczba punktów ECTS		2.0		
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. Patryk Jasik				
	Prowadzący zajęcia z przedmiotu		dr inż. Patryk Jasik				
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	0.0	0.0	30.0	0.0	0.0	30
	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	30		5.0		15.0	50
Cel przedmiotu	Celem przedmiotu jest uczenie studentów praktycznego wykorzystywania języka Python w zakresie podstaw uczenia maszynowego.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K6_W01] ma wiedzę w zakresie wybranych działów matematyki niezbędną do formułowania i rozwiązywania zadań oraz opisu zjawisk mechanicznych, fizycznych i procesów chemicznych		Student wie jak tworzyć kody w języku Python z wykorzystaniem wiedzy z zakresu wybranych działów matematyki niezbędnych do formułowania i rozwiązywania zadań oraz opisu zjawisk mechanicznych, fizycznych i procesów chemicznych.		[SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym		
	[K6_U01] potrafi posłużyć się właściwie dobranymi metodami analitycznymi, symulacyjnymi oraz eksperymentalnymi i urządzeniami umożliwiającymi pomiar podstawowych wielkości charakteryzujących materiały oraz procesy technologiczne		Student przy użyciu języka Python potrafi posłużyć się właściwie dobranymi metodami analitycznymi, symulacyjnymi i uczenia maszynowego.		[SU1] Ocena realizacji zadania		
	[K6_U03] potrafi dokonać krytycznej analizy sposobu funkcjonowania i ocenić — zwłaszcza w powiązaniu z inżynierią materiałową — istniejące rozwiązania techniczne, w szczególności urządzenia, obiekty, systemy, procesy		Przy użyciu języka Python i metod uczenia maszynowego, student potrafi dokonać krytycznej analizy sposobu funkcjonowania i ocenić istniejące rozwiązania techniczne.		[SU1] Ocena realizacji zadania		

Treści przedmiotu	Treści przedmiotu - laboratoria		
	1. Podstawowe typy danych i operacje na nich. Instrukcja warunkowa. Różne rodzaje pętli. Wyjątki. Listy, krotki, słowniki. 2. Funkcje. Funkcja z argumentem opcjonalnym. Moduły. Stworzenie własnego modułu i wykorzystanie go. Zapis/odczyt danych do/z plików. Pliki YAML. Klasy i obiekty. Wstęp do wielowątkowości. 3. Analiza danych pochodzących z wybranego zbioru. Wczytanie obserwacji dla wybranych zmiennych. Sprawdzenie podstawowych statystyk dla poszczególnych zmiennych. Wykreślenie histogramów. Identyfikacja zmiennych, w których występują potencjalnie błędne dane (obserwacje) lub braki danych. Naprawa danych. Obliczenie unormowanych korelacji pomiędzy poszczególnymi zmiennymi. Przeprowadzenie regresji liniowej dla wybranych zmiennych, wraz z wykresami. 4. Pakiet scikit-learn i model regresji liniowej. Współczynnik determinacji R^2, MSE, MAE. Podział zbioru danych na część treningową i testową. Predykcja wartości przy użyciu stworzonego modelu. 5. Pakiet scikit-learn i preprocessing. Model wielomianowy. Generowanie nowych cech. Redukcja zmiennych modelu - kryterium Schwarza (BIC - Bayesian Information Criterion). Działanie modelu wielomianowego w praktyce. 6. Pakiet scikit-learn, metoda k-najbliższych sąsiadów, drzewa decyzyjne i lasy losowe. Problem klasyfikacyjny. Wybór cech - predyktory i zmienna celu. Parametry modelu. Ocena jakości modelu - macierz pomyłek, czułość, swoistość, precyzja, dokładność, krzywa ROC, krzywa LIFT. Walidacja krzyżowa: k-krotna, n-krotna i Monte-Carlo (bootstrap). 7. Pakiet scikit-learn i algorytm k-średnich jako przypadek uczenia się bez nadzoru. Analiza skupień - klasteryzacja. Parametry modelu. Indeks Fowlkesa-Mallowsa, czyli zgodność między dwoma podziałami zbioru na skupienia. Analiza głównych składowych - PCA. 8. Pakiety XGBoost, LightGBM - jako przykłady uczenia ze wzmocnieniem. 9. Wprowadzenie do sieci neuronowych z wykorzystaniem TensorFlow i PyTorch.		
Wymagania wstępne i dodatkowe	Podstawowe umiejętności programowania w wybranym języku. Podstawowa wiedza z rachunku prawdopodobieństwa i statystyki.		
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	Raport z analizy i modelowania wybranego zbioru danych	60.0%	100.0%
Zalecana lista lektur	Podstawowa lista lektur	1. Mark Lutz, "Python. Wprowadzenie. Wydanie V", Helion 2. Marek Gągolewski, Maciej Bartoszek, Anna Cena, "Przetwarzanie i analiza danych w języku Python", PWN 3. Sebastian Raschka, "Python. Uczenie maszynowe", Helion 4. Wes McKinney, Python w analizie danych. Przetwarzanie danych za pomocą pakietów pandas i NumPy oraz środowiska Jupyter. Wydanie III, Helion 5. Aurélien Géron, "Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III", Helion	
	Uzupełniająca lista lektur	1. Tomasz Jaśniewski, "Python. Zbiór zadań z rozwiązaniami", Helion 2. Alberto Boschetti, Luca Massaron, "Python. Podstawy nauki o danych.", Helion	
	Adresy eZasobów		
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Wytyczne do stworzenia raportu:1. Tytuł raportu2. Wstęp - motywacja, cele3. Opis danych - struktura zbiorów, opis zmiennych, pochodzenie4. Opis procesu przygotowywania danych do analizy - kolejne kroki5. Analiza danych - przyjęte założenia, krótki opis metod i obranej metodologii analizy6. Modelowanie danych - przyjęte założenia, krótki opis metod i obranej metodologii budowania modeli7. Rezultaty, wnioski i ich dyskusjaRaport, wraz ze wszystkimi kodami, należy umieścić w wybranym repozytorium (np. GitLab, GitHub).		
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy		

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.