



Karta przedmiotu

Nazwa i kod przedmiotu	Uczenie maszynowe w języku Python, PG_00066699						
Kierunek studiów	Fizyka Techniczna						
Data rozpoczęcia studiów	luty 2027 r.	Rok akademicki realizacji przedmiotu			2026/2027		
Poziom kształcenia	II stopnia	Grupa zajęć			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			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. Paweł Syty					
	Prowadzący zajęcia z przedmiotu	dr inż. Paweł Syty					
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		2.0		18.0	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
	[K7_U02] potrafi programować w wybranym języku na poziomie zaawansowanym oraz stosować pakiety oprogramowania specjalistycznego.	Student potrafi tworzyć zaawansowane kody źródłowe w języku Python z wykorzystaniem wybranych bibliotek i innych specjalistycznych narzędzi.	[SU1] Ocena realizacji zadania [SU4] Ocena umiejętności korzystania z metod i narzędzi
	[K7_W04] posiada pogłębioną znajomość metod matematycznych, numerycznych i symulacyjnych stosowanych przy opisie i modelowaniu zjawisk fizycznych.	Student posiada pogłębioną znajomość wybranych metod matematycznych, statystycznych, metod numerycznych i symulacyjnych niezbędnych do modelowania zjawisk fizycznych z wykorzystaniem uczenia maszynowego..	[SW1] Ocena wiedzy faktograficznej [SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym
	[K7_K01] jest gotów do nieustannego uzupełniania eksperckiej wiedzy z zakresu fizyki i nauk pokrewnych, w tym informatyki stosowanej lub fizyki stosowanej i fotowoltaiki, krytycznej oceny tej wiedzy oraz uznawania jej znaczenia w rozwiązywaniu problemów praktycznych i poznawczych.	Student jest gotów do samodzielnego poszerzania i aktualizowania wiedzy z zakresu uczenia maszynowego, sztucznej inteligencji i metod obliczeniowych w języku Python, krytycznej oceny stosowanych algorytmów i narzędzi oraz dostrzegania ich znaczenia w rozwiązywaniu problemów praktycznych, badawczych i inżynierskich.	[SK5] Ocena umiejętności rozwiązywania problemów występujących w praktyce [SK2] Ocena postępów pracy [SK1] Ocena umiejętności pracy w grupie
	[K7_U05] potrafi samodzielnie lub w zespole, w tym jako jego lider, planować i przeprowadzać zaawansowane obliczenia teoretyczne, badania eksperymentalne i symulacje komputerowe w celu rozwiązania złożonych i nietypowych problemów naukowych i inżynierskich, krytycznie analizować ich wyniki, wyciągać wnioski i formułować umotywowane opinie.	Student potrafi samodzielnie lub w zespole projektować, implementować i oceniać modele uczenia maszynowego w języku Python, przeprowadzać eksperymenty obliczeniowe z wykorzystaniem rzeczywistych danych, krytycznie analizować uzyskane wyniki oraz dobierać odpowiednie metody i narzędzia do rozwiązywania złożonych problemów naukowych i inżynierskich.	[SU3] Ocena umiejętności wykorzystania wiedzy uzyskanej w ramach przedmiotu [SU1] Ocena realizacji zadania [SU4] Ocena umiejętności korzystania z metod i narzędzi

Treści przedmiotu	<p>Treści przedmiotu - laboratoria Język Python</p> <p>1. Typy danych i operacje na nich. Instrukcja warunkowa. Różne rodzaje pętli. Wyjątki. Listy, krotki, słowniki.</p> <p>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.</p> <p>3. Analiza danych pochodzących z wybranego zbioru. Wczytanie obserwacji dla wybranych zmiennych. Sprawdzenie wybranych 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.</p> <p>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.</p> <p>6. Pakiet scikit-learn i preprocessing. Model wielomianowy. Generowanie nowych cech. Redukcja zmiennych modelu - kryterium Schwarza (BIC - Bayesian Information Criterion). Działanie modelu wielomianowego w praktyce.</p> <p>7. 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).</p> <p>8. 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.</p> <p>9. Pakiety XGBoost, LightGBM - jako przykłady uczenia ze wzmocnieniem.</p> <p>10. Wprowadzenie do sieci neuronowych z wykorzystaniem TensorFlow i PyTorch.</p>								
Wymagania wstępne i dodatkowe	Podstawowe umiejętności programowania w wybranym obiektowym języku. Podstawowa wiedza z rachunku prawdopodobieństwa i statystyki.								
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table border="1" data-bbox="448 1272 794 1368"> <thead> <tr> <th>Sposób oceniania (składowe)</th> <th>Próg zaliczeniowy</th> <th>Składowa oceny końcowej</th> </tr> </thead> <tbody> <tr> <td>Raport z analizy i modelowania wybranego zbioru danych</td> <td>60.0%</td> <td>100.0%</td> </tr> </tbody> </table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	Raport z analizy i modelowania wybranego zbioru danych	60.0%	100.0%		
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	<p>1. Mark Lutz, Python. Wprowadzenie. Wydanie VI, Helion, 2025</p> <p>2. Marek Gągolewski, Maciej Bartoszek, Anna Cena, "Przetwarzanie i analiza danych w języku Python", PWN, 2016</p> <p>3. Python. Machine learning i deep learning. Biblioteki scikit-learn i TensorFlow 2. Wydanie III, 2021</p> <p>4. Wes McKinney, Python w analizie danych. Przetwarzanie danych za pomocą pakietów pandas i NumPy oraz środowiska Jupyter. Wydanie III, Helion, 2023</p> <p>5. Aurélien Géron, "Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III", Helion, 2023</p>							

	Uzupełniająca lista lektur	<p>1. Tomasz Jaśniewski, "Python. Zbiór zadań z rozwiązaniami", Helion, 2024</p> <p>2. Alberto Boschetti, Luca Massaron, "Python. Podstawy nauki o danych.", Helion, 2017</p>
	Adresy eZasobów	
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	<p>Wytyczne do stworzenia raportu:</p> <ol style="list-style-type: none"> 1. Tytuł raportu 2. Wstęp - motywacja, cele 3. Opis danych - struktura zbiorów, opis zmiennych, pochodzenie 4. Opis procesu przygotowywania danych do analizy - kolejne kroki 5. Analiza danych - przyjęte założenia, krótki opis metod i obranej metodologii analizy 6. Modelowanie danych - przyjęte założenia, krótki opis metod i obranej metodologii budowania modeli 7. Rezultaty, wnioski i ich dyskusja <p>Raport, wraz ze wszystkimi kodami, należy umieścić w wybranym repozytorium (np. GitLab, GitHub).</p>	
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy	

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.