

Karta przedmiotu

Nazwa i kod przedmiotu	Metody optymalizacji, PG_00060231						
Kierunek studiów	Fizyka Techniczna						
Data rozpoczęcia studiów	październik 2023 r.		Rok akademicki realizacji przedmiotu		2025/2026		
Poziom kształcenia	I stopnia - inżynierskie		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	3		Język wykładowy		polski		
Semestr studiów	6		Liczba punktów ECTS		6.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		egzamin		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Fizyki Technicznej i Matematyki Stosowanej -> Instytut Fizyki i Informatyki Stosowanej -> Zakład Fizyki Zderzeń Elektronowych						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr Maciej Kuna				
	Prowadzący zajęcia z przedmiotu						
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	0.0	30.0	0.0	0.0	60
	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	60		5.0		85.0	150
Cel przedmiotu	Celem wykładu jest przedstawienie klasycznych i wywodzących się z uczenia maszynowego metod optymalizacji w sposób umożliwiający szybkie zaimplementowanie ich pod postacią odpowiednich algorytmów. Omówione są na wykładzie współczesne algorytmy optymalizujące z położeniem nacisku na ich inspirację w fizyce i biologii.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K6_K01] Rozumie potrzebę uczenia się przez całe życie oraz potrzebę podnoszenia kompetencji zawodowych i osobistych. Potrafi inspirować i organizować proces uczenia się innych osób.		Student jest świadomy zmian w nowoczesnej optymalizacji.		[SK5] Ocena umiejętności rozwiązywania problemów występujących w praktyce		
	[K6_W03] Posiada uporządkowaną wiedzę w zakresie matematyki wyższej, obejmującą algebrę, analizę, probabilistykę i metody numeryczne, w stopniu umożliwiającym wykorzystanie do podstawowego opisu, zrozumienia i modelowania zjawisk fizycznych i niektórych procesów technicznych.		Student rozumie jak zastosować narzędzia analizy matematycznej i algebry do oceny modelowania zjawisk.		[SW2] Ocena wiedzy zawartej w prezentacji		
	[K6_U04] Potrafi planować i przeprowadzać eksperymenty, krytycznie analizować ich wyniki, wyciągać wnioski i formułować opinie. Posiada doświadczenie w pracy laboratoryjnej.		Student zna metody algorytmiczne weryfikowania i analizy danych.		[SU4] Ocena umiejętności korzystania z metod i narzędzi		

Treści przedmiotu	Treści przedmiotu - wykład Matematyczne podstawy optymalizacji. Numeryczna algebra liniowa. Normy wektorów, operacje na wektorach i macierzach. Analiza matematyczna. Warunki istnienia ekstremów funkcji jednej oraz wielu zmiennych i metody ich sprawdzenia. Metody znajdowania pochodnych. Klasyczne metody optymalizacji. Algorytmy optymalizacji funkcji jednej zmiennej: dzielenia przedziału na połowę, złotego podziału, liczb Fiboncciego, Newtona-Raphsona i siecznych. Algorytmy optymalizacji funkcji wielu zmiennych: hipersześcienna, Nelder-Meada, kierunków sprzężonych, Cauchy'ego, Newtona. Zagadnienia optymalizacyjne w uczeniu maszynowym: Regresja liniowa, gradientu prostego, regresja wielomianowa, regularyzowane modele liniowe, regresja logistyczna, liniowa i nieliniowa regresja SVM, drzewa decyzyjne, uczenie zespołowe w tym lasy losowe, redukcja wymiarowości, uczenie głębokich sieci neuronowych. Treści przedmiotu - laboratoria PyCharm: IDE do tworzenia oprogramowania w Pythonie Regresja liniowa Rozkład według wartości wartości osobliwych (SVD) i pseudoodwrotność macierzy Optymalizacja z wykorzystaniem warunków KKT Scikit-learn Nieliniowa SVM (zmiana jąder i parametrów jądra) Uczenie zespołowe - agregacja Uczenie zespołowe - klasyfikator głosowania (głosowanie twarde i miękkie) Analiza PCA jądra z wykorzystaniem radialnych funkcji bazowych Sieci neuronowe: Stochastyczny spadek wzdłuż gradientu, Momentum, RMSprop, AdaGrad, Adam Tensorflow Keras: API funkcjonalne Uczenie Q, Generatywne sieci przeciwstawne		
Wymagania wstępne i dodatkowe			
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	Zaliczenie laboratorium	50.0%	50.0%
	Kolokwium	50.0%	50.0%
Zalecana lista lektur	Podstawowa lista lektur	1. A. Geron - Uzenie maszynowe z użyciem Scikit-Learn i TensorFlow, 2 wydanie Helion, 2020 2. Singiresu S.Rao Engineering Optymalization - Theory and Practie, Wiley 2009. 3. Findestein. Metody obliczeniowe optymalizacji, PWN, 1977 4. R.Wieczorkowski, Z. Zieliński, Komputerowe generatory liczb losowych, WNT, 1997 5. X. Yang. Engineering Optimization - An Introduction With Metaheuristic Applications, Wiley, 2010	
	Uzupełniająca lista lektur	1. K.Kukuła, Badania Operacyjne w przykładach i zadaniach, PWN 2011 2. M. Wahde, Biologically Inspired Optimization Methods - An Introduction (WIT, 2008) 3. S. Luke, Essentials of Metaheuristics, Lulu, second edition, available at http://cs.gmu.edu/sean/book/metaheuristics/ 4. G. Rozenberg, Handbook of Natural Computing, Springer 2012 5. T.Weise Global Optimization Algorithms Theory and Application , http://www.it-weise.de/, 2013	
	Adresy eZasobów		
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Zastosowanie regresji liniowej do otymalizacji danych. Regularyzowanie modeli liniowych. Liniowa i nieliniowa regresja SVM. Uczenie głębokich sieci neuronowych.		
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy		

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.