

# Uczenie maszynowe - opis przedmiotu

Informacje ogólne	
Nazwa przedmiotu	Uczenie maszynowe
Kod przedmiotu	11.9-WE-INFD-UczenieMaszyn
Wydział	Wydział Nauk Inżynieryjno-Technicznych
Kierunek	Informatyka
Profil	ogólnoakademicki
Rodzaj studiów	drugiego stopnia z tyt. magistra inżyniera
Semestr rozpoczęcia	semestr zimowy 2021/2022

Informacje o przedmiocie	
Semestr	1
Liczba punktów ECTS do zdobycia	6
Typ przedmiotu	obowiązkowy
Język nauczania	polski
Sylabus opracował	• prof. dr hab. inż. Dariusz Uciński

Formy zajęć					
Forma zajęć	Liczba godzin w semestrze (stacjonarne)	Liczba godzin w tygodniu (stacjonarne)	Liczba godzin w semestrze (niestacjonarne)	Liczba godzin w tygodniu (niestacjonarne)	Forma zaliczenia
Wykład	30	2	18	1,2	Egzamin
Laboratorium	30	2	18	1,2	Zaliczenie na ocenę

## Cel przedmiotu

Zapoznanie studentów z pojęciem uczenia maszynowego oraz jego zastosowaniem do analizy dużych zbiorów danych w systemach ERP oraz nowoczesnych aplikacjach e-biznesowych.

Nauczenie studentów doboru odpowiednich technik uczenia maszynowego w zależności od skali rozpatrywanego problemu oraz rodzaju przeprowadzanej analizy (w czasie rzeczywistym, w trybie batch, przetwarzanie strumieni danych).

Nauczenie studentów pracy z wykorzystaniem nowoczesnych języków i platform ukierunkowanych na uczenie maszynowe, takich jak Python, R i JMP.

## Wymagania wstępne

Znajomość podstaw rachunku prawdopodobieństwa i statystyki

Znajomość metody numerycznych

Umiejętność programowania w języku Python

## Zakres tematyczny

Liniowe metody klasyfikacji: klasyfikacja pod nadzorem; liniowa analiza dyskryminacyjna; dyskryminacja w oparciu o regresję liniową i logistyczną; diagnostyka modelu.

Klasyfikacja w oparciu o rozkłady prawdopodobieństwa: klasyfikator bayesowski i metoda największej wiarygodności; optymalność reguły Bayesa; praktyczna konstrukcja klasyfikatorów.

Klasyfikacja w oparciu o nieparametryczną estymację rozkładów prawdopodobieństwa: estymacja rozkładów w klasach; metoda najbliższych sąsiadów.

Drzewa klasyfikacyjne i rodziny klasyfikatorów: reguły podziału; reguły przycinania drzew; algorytmy bagging i boosting; lasy losowe.

Analiza regresji: globalne modele parametryczne; regresja nieparametryczna; efekty losowe i liniowe modele mieszane.

Uogólnienia metod liniowych: dyskryminacja elastyczna; maszyny wektorów podpierających.

Metody rzutowania i detekcja zmiennych ukrytych: systemy uczące się bez nadzoru; analiza składowych głównych; analiza czynnikowa; skalowanie wielowymiarowe.

Analiza skupień: metody kombinatoryczne; metody hierarchiczne.

Deep learning: głębokie sieci jednokierunkowe; regularyzacja; sieci splotowe; sieci rekurencyjne i rekursywne.

## Metody kształcenia

wykład konwencjonalny, dyskusja, wykład problemowy, ćwiczenia laboratoryjne, praca w zespole

## Efekty uczenia się i metody weryfikacji osiągnięcia efektów uczenia się

Opis efektu	Symbol efekty	Metody weryfikacji	Forma zajęć
-------------	---------------	--------------------	-------------

Opis efektu	Symbole efektów	Metody weryfikacji	Forma zajęć
Student ma wiedzę w zakresie algebry liniowej, rachunku prawdopodobieństwa, statystyki i metod numerycznych niezbędną do modelowania problemów uczenia maszynowego	<ul style="list-style-type: none"> <li>• <a href="#">K_W09</a></li> <li>• <a href="#">K_W11</a></li> </ul>	<ul style="list-style-type: none"> <li>• egzamin - ustny, opisowy, testowy i inne</li> </ul>	<ul style="list-style-type: none"> <li>• Wykład</li> </ul>
Student potrafi wykorzystać modele i algorytmy uczenia maszynowego w budowie systemów informatycznych i podczas tworzenia oprogramowania.	<ul style="list-style-type: none"> <li>• <a href="#">K_W09</a></li> <li>• <a href="#">K_W11</a></li> </ul>	<ul style="list-style-type: none"> <li>• bieżąca kontrola na zajęciach</li> <li>• sprawdzian</li> <li>• wykonanie sprawozdań laboratoryjnych</li> </ul>	<ul style="list-style-type: none"> <li>• Laboratorium</li> </ul>
Student posiada wiedzę na temat różnych paradygmatów, metod i algorytmów uczenia maszynowego.	<ul style="list-style-type: none"> <li>• <a href="#">K_W12</a></li> </ul>	<ul style="list-style-type: none"> <li>• egzamin - ustny, opisowy, testowy i inne</li> </ul>	<ul style="list-style-type: none"> <li>• Wykład</li> </ul>
Student orientuje się w aktualnym stanie oraz trendach rozwojowych metod uczenia maszynowego w kontekście ich zastosowań w informatyce i technice.	<ul style="list-style-type: none"> <li>• <a href="#">K_W09</a></li> <li>• <a href="#">K_W12</a></li> </ul>	<ul style="list-style-type: none"> <li>• sprawdzian z progami punktowymi</li> </ul>	<ul style="list-style-type: none"> <li>• Wykład</li> </ul>
Student potrafi ocenić przydatność różnych paradygmatów, metod uczenia maszynowego oraz związanych z nimi środowisk programistycznych do rozwiązywania problemów praktycznych.	<ul style="list-style-type: none"> <li>• <a href="#">K_W09</a></li> <li>• <a href="#">K_W11</a></li> </ul>	<ul style="list-style-type: none"> <li>• bieżąca kontrola na zajęciach</li> <li>• sprawdzian</li> <li>• wykonanie sprawozdań laboratoryjnych</li> </ul>	<ul style="list-style-type: none"> <li>• Laboratorium</li> </ul>
Student zna podstawowe techniki uczenia maszynowego wykorzystywane podczas analizy danych.	<ul style="list-style-type: none"> <li>• <a href="#">K_W08</a></li> <li>• <a href="#">K_W12</a></li> <li>• <a href="#">K_U01</a></li> <li>• <a href="#">K_U05</a></li> </ul>	<ul style="list-style-type: none"> <li>• bieżąca kontrola na zajęciach</li> <li>• egzamin - ustny, opisowy, testowy i inne</li> <li>• sprawdzian</li> <li>• wykonanie sprawozdań laboratoryjnych</li> </ul>	<ul style="list-style-type: none"> <li>• Wykład</li> <li>• Laboratorium</li> </ul>

## Warunki zaliczenia

Wykład - warunkiem zaliczenia jest uzyskanie pozytywnej oceny z egzaminu przeprowadzonego w formie zaproponowanej przez prowadzącego

Laboratorium - warunkiem zaliczenia jest uzyskanie ocen pozytywnych z wszystkich ćwiczeń laboratoryjnych

Składowe oceny końcowej = wykład: 50% + laboratorium: 50%

## Literatura podstawowa

1. Jacek Koronacki, Jan Ćwik: *Statystyczne systemy uczące się. Wydanie drugie*, EXIT, Warszawa, 2007
2. Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani: *An Introduction to Statistical Learning with Applications in R*, Springer, 2013
3. Trevor Hastie, Robert Tibshirani, Jerome Friedman: *The Elements of Statistical Learning. Data Mining, Inference, and Prediction. Second Edition*, Springer, 2009
4. Ian Goodfellow, Yoshua Bengio, Aaron Courville: *Deep Learning. Systemy uczące się*, PWN, Warszawa, 2018
5. Brian Steele, John Chandler, Swarna Reddy: *Algorithms for Data Science*, Springer, 2016
6. Aurélien Géron, *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow*, Wydanie II, Helion, Warszawa, 2020

## Literatura uzupełniająca

## Uwagi

Zmodyfikowane przez prof. dr hab. inż. Dariusz Uciński (ostatnia modyfikacja: 26-04-2021 14:31)

Wygenerowano automatycznie z systemu SyllabUZ