

Machine learning - course description

General information	
Course name	Machine learning
Course ID	11.9-WE-INF-D-UczenieMaszyn
Faculty	Faculty of Computer Science, Electrical Engineering and Automatics
Field of study	Computer Science
Education profile	academic
Level of studies	Second-cycle studies leading to MSc degree
Beginning semester	winter term 2019/2020

Course information	
Semester	1
ECTS credits to win	6
Course type	obligatory
Teaching language	polish
Author of syllabus	prof. dr hab. inż. Dariusz Uciński

Classes forms					
The class form	Hours per semester (full-time)	Hours per week (full-time)	Hours per semester (part-time)	Hours per week (part-time)	Form of assignment
Lecture	30	2	18	1,2	Exam
Laboratory	30	2	18	1,2	Credit with grade

Aim of the course

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.

Prerequisites

Znajomość podstaw rachunku prawdopodobieństwa i statystyki

Znajomość metody numerycznych

Umiejętność programowania w języku Python

Scope

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.

Teaching methods

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

Learning outcomes and methods of theirs verification

Outcome description	Outcome symbols	Methods of verification	The class form
---------------------	-----------------	-------------------------	----------------

Outcome description	Outcome symbols	Methods of verification	The class form
Student ma wiedzę w zakresie algebry liniowej, rachunku prawdopodobieństwa, statystyki i metod numerycznych niezbędną do modelowania problemów uczenia maszynowego	• K_W09 • K_W11	• an exam - oral, descriptive, test and other	• Lecture
Student potrafi wykorzystać modele i algorytmy uczenia maszynowego w budowie systemów informatycznych i podczas tworzenia oprogramowania.	• K_W09 • K_W11	• a quiz • an ongoing monitoring during classes • carrying out laboratory reports	• Laboratory
Student posiada wiedzę na temat różnych paradygmatów, metod i algorytmów uczenia maszynowego.	• K_W12	• an exam - oral, descriptive, test and other	• Lecture
Student orientuje się w aktualnym stanie oraz trendach rozwojowych metod uczenia maszynowego w kontekście ich zastosowań w informatyce i technice.	• K_W09 • K_W12	• a test with score scale	• Lecture
Student potrafi ocenić przydatność różnych paradygmatów, metod uczenia maszynowego oraz związanych z nimi środowisk programistycznych do rozwiązywania problemów praktycznych.	• K_W09 • K_W11	• a quiz • an ongoing monitoring during classes • carrying out laboratory reports	• Laboratory
Student zna podstawowe techniki uczenia maszynowego wykorzystywane podczas analizy danych.	• K_W08 • K_W12 • K_U01 • K_U05	• a quiz • an exam - oral, descriptive, test and other • an ongoing monitoring during classes • carrying out laboratory reports	• Lecture • Laboratory

Assignment conditions

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%

Recommended reading

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

Further reading

Notes

Modified by prof. dr hab. inż. Dariusz Uciński (last modification: 06-05-2019 10:50)

Generated automatically from SyllabUZ computer system