

Machine learning - opis przedmiotu

Informacje ogólne	
Nazwa przedmiotu	Machine learning
Kod przedmiotu	11.9-WE-INFD-MachLear-Er
Wydział	Wydział Informatyki, Elektrotechniki i Automatyki
Kierunek	Informatyka
Profil	ogólnoakademicki
Rodzaj studiów	Program Erasmus drugiego stopnia
Semestr rozpoczęcia	semestr zimowy 2021/2022

Informacje o przedmiocie	
Semestr	1
Liczba punktów ECTS do zdobycia	6
Typ przedmiotu	obowiązkowy
Język nauczania	angielski
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	-	-	Egzamin
Laboratorium	30	2	-	-	Zaliczenie na ocenę

Cel przedmiotu

- Familiarize students with the concept of machine learning and its applications to the analysis of large data sets included in social media, ERP systems and modern e-business applications.
- Teach students how to select the appropriate data analysis techniques depending on the scale of the problem under consideration and the type of analysis (real-time, batch mode, data stream processing).
- Teach students to work using modern programming languages and platforms directed towards machine learning, such as Python, R and JMP.

Wymagania wstępne

- Fundamentals of probability and engineering statistics
- Basics of numerical methods
- Basic programming skills in Python

Zakres tematyczny

Linear classification methods: supervised classification; linear discriminant analysis; discrimination based on linear regression and logistic regression; model diagnostics.

Classification based on probability distributions: Bayesian classifier and maximum likelihood; optimality of the Bayes rule; practical synthesis of classifiers.

Classification based on nonparametric estimation of probability distributions: estimation of distributions within classes; nearest neighbor rule.

Decision trees and families of classifiers: partition rules; trimming rules; algorithms of bagging and boosting; random forests.

Regression analysis: global parametric models; nonparametric regression; random effects and mixed linear models.

Generalizations of linear methods: elastic discrimination; support vector machines.

Projection methods and detection of hidden variables: unsupervised learning systems; principal component analysis; factor analysis; multidimensional scaling.

Cluster analysis: combinatorial methods; hierarchical methods.

Deep learning: unidirectional deep networks; regularization; convolution networks; recurrent networks.

Metody kształcenia

conventional lecture, discussion, laboratory classes

Efekty uczenia się i metody weryfikacji osiągnięcia efektów uczenia się

Opis efektu	Symbole efektów	Metody weryfikacji	Forma zajęć
The student has the knowledge of linear algebra, probability, statistics and numerical methods required to model machine learning problems		egzamin - ustny, opisowy, testowy i inne	Wykład

Opis efektu	Symbole efektów	Metody weryfikacji	Forma zajęć
The student can apply machine learning models and algorithms in building IT systems and software.		- bieżąca kontrola na zajęciach - sprawdzian - wykonanie sprawozdań laboratoryjnych	Laboratorium
The students has the knowledge of various paradigms, methods and algorithms of machine learning.		egzamin - ustny, opisowy, testowy i inne	Wykład
The students is familiar with the state-of-the-art and current trends of machine learning for computer science and engineering.		sprawdzian z progami punktowymi	Wykład
The students can assess the usefulness of various paradigms and methods of machine learning, as well as related programming environments to solve practical problems.		- bieżąca kontrola na zajęciach - sprawdzian - wykonanie sprawozdań laboratoryjnych	Laboratorium
The students knows basics machine learning techniques used in data analysis.		- bieżąca kontrola na zajęciach - egzamin - ustny, opisowy, testowy i inne - sprawdzian - wykonanie sprawozdań laboratoryjnych	- Wykład - Laboratorium

Warunki zaliczenia

- Lecture - the passing criterion is a sufficient mark from the final exam.
- Laboratory - the passing criterion are positive marks for all laboratory exercises.
- Final mark components = lecture: 50% + laboratory: 50%

Literatura podstawowa

- Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani: *An Introduction to Statistical Learning with Applications in R*, Springer, 2013
- Trevor Hastie, Robert Tibshirani, Jerome Friedman: *The Elements of Statistical Learning. Data Mining, Inference, and Prediction. Second Edition*, Springer, 2009
- Ian Goodfellow, Yoshua Bengio, Aaron Courville: *Deep Learning*. MIT Press, Warszawa, 2016
- Brian Steele, John Chandler, Swarna Reddy: *Algorithms for Data Science*, Springer, 2016

Literatura uzupełniająca

Uwagi

Zmodyfikowane przez prof. dr hab. inż. Dariusz Uciński (ostatnia modyfikacja: 14-07-2021 21:47)

Wygenerowano automatycznie z systemu SylabUZ