

Uczenie maszynowe - opis przedmiotu

Informacje ogólne	
Nazwa przedmiotu	Uczenie maszynowe
Kod przedmiotu	11.9-WE-INF-D-UczenieMaszyn
Wydział	Wydział Informatyki, Elektrotechniki i Automatyki
Kierunek	Informatyka
Profil	ogólnoakademicki
Rodzaj studiów	drugiego stopnia z tyt. magistra inżyniera
Semestr rozpoczęcia	semestr zimowy 2018/2019

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 osiągania efektów uczenia się

Opis efektu	Symbole efektów	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	K_W09 K_W11	sprawdzian z progami punktowymi	Wykład
Student potrafi wykorzystać modele i algorytmy uczenia maszynowego w budowie systemów informatycznych i podczas tworzenia oprogramowania.	K_W09 K_W11	projekt	Laboratorium
Student posiada wiedzę na temat różnych paradygmatów, metod i algorytmów uczenia maszynowego.	K_W12	sprawdzian z progami punktowymi	Wykład
Student orientuje się w aktualnym stanie oraz trendach rozwojowych metod uczenia maszynowego w kontekście ich zastosowań w informatyce i technice.	K_W09 K_W12	sprawdzian z progami punktowymi	Wykład
Student potrafi ocenić przydatność różnych paradygmatów, metod uczenia maszynowego oraz związanych z nimi środowisk programistycznych do rozwiązywania problemów praktycznych.	K_W09 K_W11	projekt	Laboratorium
Student zna podstawowe techniki uczenia maszynowego wykorzystywane podczas analizy danych.	K_W08 K_W12 K_U01 K_U05	sprawdzian z progami punktowymi	Wykład

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

Literatura uzupełniająca

Uwagi

Zmodyfikowane przez prof. dr hab. inż. Dariusz Uciński (ostatnia modyfikacja: 28-04-2018 12:18)

Wygenerowano automatycznie z systemu SyllabUZ