



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Teoria Uczenia Maszynowego [S2S1E>TUM]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

1/1

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

15

Laboratorium

0

Inne

0

Ćwiczenia

15

Projekty/seminaria

0

Liczba punktów ECTS

3,00

Koordynatorzy

dr hab. inż. Wojciech Kotłowski prof. PP
wojciech.kotlowski@put.poznan.pl

Wykładowcy

Wymagania wstępne

Student rozpoczynający przedmiot powinien posiadać podstawową wiedzę na temat rachunku prawdopodobieństwa (aksjomaty i własności miary prawdopodobieństwa, zmienne losowe dyskretne i ciągłe, momenty zmiennych losowych, wielowymiarowe zmienne losowe, nierówności probabilistyczne: Markowa i Czebyszewa), statystyki matematycznej (problemy estymacji parametrów, regresji), oraz uczenia maszynowego (przeuczenie, walidacja systemów uczących, modele liniowe, boosting, sieci neuronowe) oraz umiejętność rozwiązywania podstawowych problemów tych dziedzin. W zakresie kompetencji społecznych student musi rozumieć znaczenie wykorzystywania najnowszej wiedzy z zakresu informatyki w rozwiązywaniu problemów badawczych, a także prezentować takie postawy jak uczciwość, odpowiedzialność, wytrwałość, ciekawość poznawcza, kreatywność, kultura osobista, szacunek do innych ludzi.

Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z najważniejszymi wynikami w dziedzinie teorii uczenia maszynowego. Zajęcia wykładowe skupiają się na omówieniu podstaw statystycznej teorii uczenia (sformułowanie problemu uczenia, elementy statystycznej teorii decyzji, minimalizacja ryzyka empirycznego, teoria uogólnienia, przetarg obciążenia/wariancji) oraz teorii uczenia przyrostowego (predykcje z ekspertami, przyrostowa optymalizacja wypukła).

Przedmiotowe efekty uczenia się

Wiedza 1. Ma uporządkowaną i podbudowaną teoretycznie wiedzę ogólną związaną z kluczowymi zagadnieniami z zakresu uczenia maszynowego [K2st_W2]

2. Ma zaawansowaną wiedzę szczegółową dotyczącą teoretycznych podstaw uczenia maszynowego [K2st_W3]

3. Ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach informatyki i statystyki [K2st_W4]

4. Zna zaawansowane metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań inżynierskich i prowadzeniu prac badawczych w obszarze teorii uczenia maszynowego [K2st_W6]

Umiejętności 1. Potrafi pozyskiwać informacje z literatury, baz danych oraz innych źródeł (w języku polskim i angielskim), integrować je, dokonywać ich interpretacji i krytycznej oceny, wyciągać wnioski oraz formułować i wyczerpująco uzasadniać opinie [K2st_U1]

2. Potrafi wykorzystać do formułowania i rozwiązywania zadań z zakresu teorii uczenia maszynowego metody analityczne, symulacyjne oraz eksperymentalne [K2st_U4]

3. Potrafi — przy formułowaniu i rozwiązywaniu zadań uczenia maszynowego — integrować wiedzę z różnych obszarów informatyki (a w razie potrzeby także wiedzę z innych dyscyplin naukowych) oraz zastosować podejście systemowe, uwzględniające także aspekty pozatechniczne [K2st_U5]

4. Potrafi ocenić przydatność i możliwość wykorzystania nowych osiągnięć (metod i narzędzi) z dziedziny teorii uczenia maszynowego [K2st_U6]

5. Potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania informatyczne dotyczące teorii uczenia maszynowego [K2st_U10]

6. Potrafi określić kierunki dalszego uczenia się i zrealizować proces samokształcenia, w tym innych osób [K2st_U16]

Kompetencje społeczne 1. Rozumie, że w informatyce wiedza i umiejętności bardzo szybko stają się przestarzałe [K2st_K1]

2. Rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu teorii uczenia maszynowego w rozwiązywaniu problemów badawczych i praktycznych [K2st_K2]

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

1. W zakresie wykładów:

- ocena wiedzy i umiejętności na zaliczeniowym teście pisemnym zawierającym zadania problemowe w formie otwartej i/lub testu wielokrotnego wyboru;

- omówienie wyników testu.

2. W zakresie ćwiczeń:

- ocena ciągła, na każdym zajęciach w formie krótkich pytań o charakterze testowym lub otwartym,

- uzyskiwanie punktów dodatkowych za aktywność w trakcie zajęć ćwiczeniowych,

- uzyskiwanie punktów dodatkowych poprzez omówienie i prezentację artykułów naukowych;

W zakresie zarówno wykładów, jak i ćwiczeń, stosuje się następującą skalę ocen: powyżej 50% - dostateczny, 60% - dostateczny plus, 70% - dobry, 80% - dobry plus, 90% - bardzo dobry.

Treści programowe

1. Formalne przedstawienie problemu uczenia: statystyczny model problemu uczenia, funkcja straty, ryzyko, klasyfikator Bayesowski, elementy statystycznej teorii decyzji, podstawowe problemy uczenia się z danych.

2. Ryzyko empiryczne, minimalizacja ryzyka empirycznego, błąd uogólnienia, błąd estymacji i aproksymacji, twierdzenie No-Free-Lunch, podstawowe nierówności probabilistyczne (nierówność Markowa, nierówność Czebyszewa, nierówność Boole'a, nierówność Hoeffdinga), wyprowadzenie ograniczenia na błąd uogólnienia dla skończonej klasy funkcji, model PAC.

3. Jednostajna zbieżność w obrębie klasy funkcji predykcyjnych, złożoność Rademachera, funkcja

wzrostu.

4. Wymiar Vapnika-Chervonenkisa (VC) i podstawowe twierdzenie o uczeniu się, wymiar VC dla popularnych klas funkcji.

5. Klasyfikacja liniowa, metody SVM, metody boosting, zastępcze wypukłe funkcje straty.

6. Uczenie się przyrostowe, minimalizacja żalu, problem predykcji z ekspertami, algorytmy Follow-the-Leader i Hedge, ograniczenia na żal, optymalne algorytmy.

7. Przyrostowa optymalizacja wypukła, algorytm stochastycznego spadku wzdłuż gradientu (SGD), analiza gwarancji na żal dla algorytmu SGD.

Tematyka zajęć

1. Formalne przedstawienie problemu uczenia: statystyczny model problemu uczenia, funkcja straty, ryzyko, klasyfikator Bayesowski, elementy statystycznej teorii decyzji, podstawowe problemy uczenia się z danych.

2. Ryzyko empiryczne, minimalizacja ryzyka empirycznego, błąd uogólnienia, błąd estymacji i aproksymacji, twierdzenie No-Free-Lunch, podstawowe nierówności probabilistyczne (nierówność Markowa, nierówność Czebyszewa, nierówność Boole'a, nierówność Hoeffdinga), wyprowadzenie ograniczenia na błąd uogólnienia dla skończonej klasy funkcji, model PAC.

3. Jednostajna zbieżność w obrębie klasy funkcji predykcyjnych, złożoność Rademachera, funkcja wzrostu.

4. Wymiar Vapnika-Chervonenkisa (VC) i podstawowe twierdzenie o uczeniu się, wymiar VC dla popularnych klas funkcji.

5. Klasyfikacja liniowa, metody SVM, metody boosting, zastępcze wypukłe funkcje straty.

6. Uczenie się przyrostowe, minimalizacja żalu, problem predykcji z ekspertami, algorytmy Follow-the-Leader i Hedge, ograniczenia na żal, optymalne algorytmy.

7. Przyrostowa optymalizacja wypukła, algorytm stochastycznego spadku wzdłuż gradientu (SGD), analiza gwarancji na żal dla algorytmu SGD.

Metody dydaktyczne

1. Wykład: prezentacja multimedialna, ilustrowana przykładami podawanymi na tablicy, ćwiczenia praktyczne (m. in. obliczeniowe na tablicy).

2. Ćwiczenia: rozwiązywanie zadań i problemów związanych z omówioną na wykładzie treścią.

Literatura

Podstawowa

1. S. Shalev-Shwartz and S. Ben-David. Understanding Machine Learning: From Theory to Algorithms. Cambridge University Press, 2014

2. Yaser S. Abu-Mostafa, Malik Magdon-Ismail, Hsuan-Tien Lin: Learning From Data. AMLBook, 2012.

3. Mehryar Mohri, Afshin Rostamizadeh, Ameet Talwalkar: Foundations of Machine Learning, MIT Press, 2012.

4. Elad Hazan: Introduction to Online Convex Optimization. Foundations and Trends® in Optimization, Vol. 2, no. 3-4, pp 157-325.

Uzupełniająca

1. O. Bousquet, S. Boucheron, and G. Lugosi: Introduction to statistical learning theory. Advanced Lectures on Machine Learning, pp. 169-207. Springer Berlin Heidelberg, 2004.

2. L. Devroye, L. Györfi, and G. Lugosi: A Probabilistic Theory of Pattern Recognition. Springer, 1996.

3. M. Anthony and P.L. Bartlett, Neural Network Learning: Theoretical Foundations. Cambridge University Press, 1999.

4. V.N. Vapnik: Statistical Learning Theory. Wiley-Interscience, 1998.

5. T. Hastie, R. Tibshirani, J. Friedman: Elements of Statistical Learning. Springer, 2017.

5. N. Cesa-Bianchi and G. Lugosi: Prediction Learning and Games. Cambridge University Press, 2006.

6. M. Kempka, W. Kotłowski, M. K. Warmuth: Adaptive scale-invariant online algorithms for learning linear models. International Conference on Machine Learning (ICML), 2019.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	75	3,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	30	1,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwiiw/egzaminu, wykonanie projektu)	45	1,50