



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Uczenie maszynowe

Przedmiot

Kierunek studiów

Sztuczna inteligencja

Studia w zakresie (specjalność)

Poziom studiów

pierwszego stopnia

Forma studiów

stacjonarne

Rok/semestr

2/4

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

angielski

Wymagalność

obligatoryjny

Liczba godzin

Wykład

30

Laboratoria

0

Inne (np. online)

Ćwiczenia

30

Projekty/seminaria

Liczba punktów ECTS

5

Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:

prof. Jerzy Stefanowski

e-mail: jerzy.stefanowski@put.poznan.pl

tel: +48 61 665 2933

Wydział Informatyki i Telekomunikacji

Piotrowo 2, 60-965 Poznań

Odpowiedzialny za przedmiot/wykładowca:

dr hab. inż. Izabela Szczęch

e-mail: izabela.szczech@put.poznan.pl

tel: +48 61 665 2930

Wydział Informatyki i Telekomunikacji

Piotrowo 2, 60-965 Poznań

Wymagania wstępne

Podstawowa wiedza z zakresu: rachunku różniczkowego, algebry liniowej, rachunku prawdopodobieństwa i statystyki, algorytmów i struktur danych. Student powinien również umieć samodzielnie wyszukiwać informacje i wykazywać chęć do pracy w zespole.

Cel przedmiotu

Przedstawienie podstawowych metod i algorytmów uczenia maszynowego. Ze względu na koordynację z zakresem innych kursów równoległych, szczególny nacisk położony jest na uczenie nadzorowane i metody w zakresie uczenia reprezentacji symbolicznych z przykładów, uczenie statystyczne, złożone modele predykcyjne oraz zasady eksperymentalnej oceny klasyfikatorów i modeli predykcyjnych.



Ponadto na zajęciach studenci powinni zdobyć praktyczne doświadczenia w rozwiązywaniu zadań klasyfikacyjnych.

Przedmiotowe efekty uczenia się

Wiedza

Studenci:

K1st_W3: posiadają ugruntowaną wiedzę z zakresu podstawowych problemów informatyki z zakresu uczenia maszynowego i analizy danych

K1st_W4: znają i rozumieją podstawowe techniki, metody, algorytmy i narzędzia wykorzystywane do rozwiązywania problemów komputerowych oraz problemów uczenia maszynowego, w tym drzewa decyzyjne, reguły, modele uczenia opartego na podobieństwach, podejścia probabilistyczne, modele liniowe, regresję/klasyfikację, SVM i klasyfikatory złożone

K1st_W5: mają podstawową wiedzę o kluczowych kierunkach i najważniejszych sukcesach uczenia maszynowego rozumianego jako niezbędną poddziedzinę informatyki, korzystająca z dorobku innych dyscyplin naukowych i dostarczająca rozwiązań o dużej sile oddziaływania praktycznego; znają historię i najnowsze trendy w uczeniu maszynowym

Umiejętności

Studenci:

K1st_U1: potrafią zbierać informacje z wielu źródeł, analizować je, interpretować i syntetyzować, a także uzasadniać swoje poglądy, zwłaszcza w kontekście uczenia maszynowego

K1st_U3: potrafią formułować i rozwiązywać złożone problemy uczenia maszynowego z zakresu informatyki, a w szczególności sztucznej inteligencji, stosując odpowiednio dobrane metody, takie jak klasyfikacja, regresja, uczenie oparte na podobieństwach, klasyfikatory Bayesa, maszyny wektorów nośnych, klasyfikatory złożone

K1st_U4: potrafią sprawnie planować i przeprowadzać eksperymenty, w tym komputerowe pomiary i symulacje, interpretować uzyskane wyniki i wyciągać wnioski na podstawie wyników eksperymentów w kontekście zadań uczenia maszynowego

K1st_U7: potrafią przeprowadzić krytyczną analizę i ocenę funkcjonowania metod uczenia maszynowego

K1st_U8: potrafią zaprojektować - na podstawie wcześniej zdefiniowanej specyfikacji - i stworzyć system informatyczny wykorzystujący uczenie maszynowe, najpierw wybierając, a następnie wykorzystując dostępne metody, techniki i narzędzia komputerowe (w tym języki programowania)

K1st_U9: potrafią adaptować istniejące algorytmy oraz formułować i wdrażać nowe algorytmy typowe dla różnych nurtów uczenia maszynowego, wykorzystując m.in. narzędzia: Weka, Python

K1st_U10: potrafią wyszukiwać, analizować i przekształcać różne rodzaje danych oraz przeprowadzać syntezę danych w celu uzyskania wiedzy i wniosków przydatnych w rozwiązywaniu różnorodnych problemów związanych z uczeniem maszynowym



K1st_U11: potrafią adaptować i wykorzystywać modele inteligentnych zachowań (np. modele predykcyjne) oraz narzędzia komputerowe symulujące takie zachowania

K1st_U16: potrafi planować i realizować własne uczenie się przez całe życie oraz zna możliwości dalszego kształcenia (studia II stopnia)

Kompetencje społeczne

Studenci:

K1st_K1: rozumieją, że w informatyce ze szczególnym uwzględnieniem uczenia maszynowego wiedza i umiejętności bardzo szybko stają się przestarzałe, dostrzegając przy tym potrzebę ciągłego kształcenia oraz podnoszenia własnych kompetencji

K1st_K2: mają świadomość istotności wiedzy i badań naukowych związanych z informatyką i uczeniem maszynowym w rozwiązywaniu praktycznych problemów o kluczowym znaczeniu dla funkcjonowania jednostek, firm, organizacji oraz całego społeczeństwa w takich przykładowych obszarach zastosowań jak transport, ochrona zdrowia, edukacja, bezpieczeństwo publiczne czy rozrywka

K1st_K3: znają przykłady wadliwie działających systemów wykorzystujących uczenie maszynowe, które doprowadziły do strat ekonomicznych, społecznych lub środowiskowych

K1st_K5: potrafią myśleć i działać w sposób przedsiębiorczy, m.in. znajdując komercyjne zastosowania dla tworzonych systemów uczenia maszynowego, mając na uwadze nie tylko korzyści ekonomiczne, ale również aspekty prawne i społeczne

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykłady: pisemny egzamin obejmująca pytania wielokrotnego wyboru, pytania z krótką odpowiedzią i mikroproblemy do rozwiązania. Do zaliczenia wymagane jest co najmniej 50% punktów.

Ćwiczenia: zaliczenie na podstawie rozwiązywania przez studentów zadań teoretycznych i praktycznych. Zadania rozwiązywane indywidualnie lub w grupach, na zajęciach lub jako praca domowa, do zaliczenia co najmniej 50% punktów.

Treści programowe

Kurs obejmuje następujące tematy: Podstawy nadzorowanego uczenia się; Drzewa klasyfikacyjne; Indukcja reguł; Ocena modeli predykcyjnych; Uczenie się oparte na podobieństwie (klasyfikatory minimalno-odległościowe); Podejścia probabilistyczne - klasyfikatory Bayesa; Modele liniowe; Regresja logistyczna; Maszyny wektorów nośnych; Zespoły klasyfikatorów; Częściowo nadzorowane i aktywne uczenie się.

Metody dydaktyczne

Wykłady: prezentacje multimedialne, zadania rozwiązywane na tablicy, dyskusja.



Ćwiczenia: prezentacje multimedialne, quizy, burza mózgów, rozwiązywanie ilustracyjnych przykładów na tablicy i w Wece, dyskusja na temat wybranych metod.

Literatura

Podstawowa

Tom Mitchell, Machine learning, McGraw Hill, 1997.

Machine learning: The Art and Science of Algorithms that Make Sense of Data. Peter A. Flach. Caambridge Press 2012.

Uczenie maszynowe i sieci neuronowe. K.Krawiec, J.Stefanowski, Wyd. Politechniki Poznańskiej, 2004

Uzupełniająca

Machine Learning and Data Mining. I Kononenko., M. Kukar. Horwood Publishing, 2007.

Understanding Machine Learning. Shai Ben-David, Shai Shalev-Shwartz, Cambridge Univ. Press 2014.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,0
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	60	2,5
Praca własna studenta (studia literaturowe, przygotowanie do ćwiczeń, przygotowanie do zaliczenia, wykonanie projektu) ¹	65	2,5

¹ niepotrzebne skreślić lub dopisać inne czynności