



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Uczenie maszynowe

Przedmiot

Kierunek studiów

Informatyka

Studia w zakresie (specjalność)

Inteligentne technologie informatyczne

Poziom studiów

drugiego stopnia

Forma studiów

stacjonarne

Rok/semestr

1/1

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

polski

Wymagalność

obligatoryjny

Liczba godzin

Wykład

30

Laboratoria

30

Inne (np. online)

Ćwiczenia

Projekty/seminaria

Liczba punktów ECTS

5

Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:
dr hab. inż. Jerzy Stefanowski, prof. PP email:
Jerzy.Stefanowski@cs.put.poznan.pl tel: 61
6652933

Odpowiedzialny za przedmiot/wykładowca:

Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać podstawową wiedzę ze sztucznej inteligencji, rachunku prawdopodobieństwa, statystyki matematycznej, algebry wektorów i macierzy. Podstawowe umiejętności programistyczne (wykorzystanie języka Python i wybranych bibliotek) oraz umiejętność pozyskiwania informacji ze wskazanych źródeł.

Cel przedmiotu

- Przekazanie studentom podstawowej wiedzy na temat tworzenia i praktycznego stosowania systemów automatycznego uczenia się z przykładów (zarówno w zakresie symbolicznych metod, nieparametrycznych (np. k-NN), statystycznych jak i zespołów modeli predykcyjnych).
- Rozwijanie u studentów umiejętności rozwiązywania problemów wymagających użycia algorytmów uczących się zasad działania systemu informatycznego albo robota na podstawie analizy i uogólnienia zapisu doświadczenia w postaci przykładów.



3. Nabycie powyższych umiejętności poprzez rozwiązywanie na ćwiczeniach laboratoryjnych praktycznych zadań klasyfikacji nadzorowanej oraz nienadzorowanej.

4. Kształtowanie u studentów umiejętności przeprowadzanie eksperymentów z danymi dot. powyższych zadań przy wykorzystaniu różnorodnych gotowych narzędzi programistycznych.

Przedmiotowe efekty uczenia się

Wiedza

Ma uporządkowaną, podbudowaną teoretycznie wiedzę ogólną w zakresie systemów uczących się, (K2st_W2) ma szczegółową wiedzę związaną z wybranymi zagadnieniami, takimi jak: klasyfikacja nadzorowana, metody konstruowania klasyfikatorów oraz predykcji, metod ich oceny eksperymentalnej; podstawy uczenia nienadzorowanego sieci neuronowych, klasyfikatorów złożonych, uczenie aktywne z danych częściowo-etykietowanych (K2st_W3) ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach w dziedzinach uczenia maszynowego (K2st_W4) zna podstawowe metody, techniki i narzędzia stosowane przy rozwiązywaniu złożonych zadań z zastosowaniem algorytmów uczących się (K2st_W6)

Umiejętności

Potrafi pozyskiwać informacje nt. systemów uczących się 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) potrafi wykorzystać do formułowania i rozwiązywania zadań inżynierskich i prostych problemów badawczych metody klasyfikacji nadzorowanej, predykcji zmiennej liczbowej oraz grupowania danych. (K2st_U4) potrafi - przy formułowaniu i rozwiązywaniu zadań inżynierskich - integrować wiedzę z różnych obszarów Informatyki powiązanych z uczeniem maszynowym, analizą i eksploracją danych (K2st_U5) potrafi ocenić zalety i ograniczenia wybranych algorytmów uczących się i ich implementacji w zależności od charakterystyki zadania. (K2st_U6) potrafi - stosując m.in. koncepcyjnie nowe metody - rozwiązywać złożone zadania informatyczne z zakresu uczenia maszynowego (K2st_U10) potrafi określić kierunki dalszego uczenia się i zrealizować proces samokształcenia - w szczególności w zakresie wykorzystania algorytmów uczących się do eksploracji danych oraz możliwości użycia jako części inteligentnych systemów wspomagania decyzji (K2st_U16)

Kompetencje społeczne

Rozumie, że przy tworzeniu inteligentnych systemów z możliwościami uczenia się z przykładów nabyta wiedza i umiejętności wymagają dalszego kształcenia się z uwagi na dynamiczny rozwój dziedziny (K2st_K1) zna przykłady rozwiązań systemów uczących się i rozumie ich ograniczenia (K2st_K2)

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Ocena - przedmiot zgodnie z program specjalności kończy się egzaminem :

a) w zakresie wykładów: na podstawie odpowiedzi na pytania dotyczące materiału omówionego na poprzednich wykładach - realizowana poprzez test pisemny (egzaminacyjny) - pytań otwartych albo w



formie testu wielokrotnego wyboru - test może liczyć od około 7 do kilkunastu takich pytań w zależności od ich formy,

b) w zakresie laboratoriów: na podstawie oceny bieżącego postępu realizacji zadań - ćwiczenia przygotowane w postaci instrukcji udostępnionych studentom, przygotowanych samodzielnych raportów z rozwiązań powyższych zadań. Ponadto ocenę przygotowania studenta do niektórych sesji zajęć laboratoryjnych (sprawdzian wejściowy) i ocenianie ciągłe, na każdych zajęciach (odpowiedzi ustne) - premiowanie przyrostu umiejętności posługiwania się poznanymi zasadami i metodami oraz narzędziami programowymi, Ocenę sprawozdania przygotowującego częściowo w trakcie zajęć, a częściowo po ich zakończeniu; ocena ta obejmuje także umiejętność pracy w zespole - jeśli ćwiczenie byłoby wykonywane w zespołach 2 osobowych.

Treści programowe

Pojęcia podstawowe z zakresu maszynowego uczenia się (ang. machine learning). Nadzorowane uczenie się pojęć i klasyfikacji. Kryteria oceny systemów klasyfikujących: miary oraz metody ich eksperymentalnej oceny. Indukcja drzew decyzyjnych (także jako tzw. drzew regresji). Zjawisko przeuczenia algorytmu i sposoby jego unikania. Indukcja reguł decyzyjnych. Algorytmy z rodziny k-NN wykorzystujące bazę wcześniej zapamiętanych przykładów Klasyfikacja bayesowska. Zasada minimalnej długości kodu opisu. Metoda wektorów wspierających SVM oraz inne metody z funkcjami jądrowymi. Algorytmy uczenia nienadzorowanego z mieszaninami gausowskimi EM. Uczenie nienadzorowane sieci neuronowych - Sieci Kohonena (topologie LVQ i SOM, zastosowania WEBSOM). Sieć z funkcjami o symetrii kołowej (RBF). Indukcyjne programowanie logiczne. Algorytmiczna teoria uczenia się. Systemy uczące się o zaawansowanej architekturze - zespoły klasyfikatorów oraz modeli regresyjnych. Idea aktywnego uczenia się oraz klasyfikacja częściowo nadzorowana.

Metody dydaktyczne

Wykład: prezentacja multimedialna, prezentacja ilustrowana przykładami podawanymi na tablicy, rozwiązywanie prostych zadań, demonstracja użycia wybranego oprogramowania. ćwiczenia laboratoryjne: rozwiązywanie zadań, ćwiczenia praktyczne wraz z ograniczonym programowaniem wykorzystującym wskazane biblioteki z implementacjami algorytmów, wykonywanie eksperymentów, dyskusja,

Literatura

Podstawowa

Machine Learning: The Art and Science of Algorithms that Make Sense of Data, P.Flach, Cambridge University Press, 2012.

Pattern recognition and machine learning. Ch. Bishop, Springer, 2006.

Systemy uczące się, P. Cichosz, WNT, Warszawa, 2000.

Uczenie maszynowe i sieci neuronowe, K.Krawiec, J.Stefanowski, Wydawnictwo PP, Poznań, 2004

Uzupełniająca

Statystyczne systemy uczące się. J.Koronacki, J.Ćwik, EXIT, Warszawa 2008



Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	130	5,0
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	70	3,0
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu) ¹	50	2,0

¹ niepotrzebne skreślić lub dopisać inne czynności