



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Grafy w uczeniu maszynowym [S2SI1E>GUM]

Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

2/3

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

drugiego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obieralny

Liczba godzin

Wykład

15

Laboratorium

15

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

2,00

Koordynatorzy

dr Paweł Misiorek

pawel.misiorek@put.poznan.pl

Wykładowcy

Wymagania wstępne

Student rozpoczynający kurs powinien mieć podstawową wiedzę z matematyki, w szczególności z zakresu podstaw algebry liniowej, teorii prawdopodobieństwa oraz teorii grafów. Ponadto, powinien znać podstawowe pojęcia i zasady uczenia maszynowego, statystyki i analizy danych jak również powinien posiadać umiejętności programowania. Powinien być zdolny do samodzielnego pozyskiwania wiedzy z wskazanych źródeł, jak również gotowy do pracy w zespole.

Cel przedmiotu

Przedmiot ukierunkowany jest na poznanie grafowych technik eksploracji złożonych danych oraz ich zastosowań do rozwiązywania problemów uczenia maszynowego. W szczególności, wprowadzone zostanie pojęcie hipergrafu jako uogólnienie grafów - dla którego krawędzie mogą zawierać dowolną liczbę wierzchołków - pozwalające na dokładniejszą reprezentację sieci i struktur danych. Przedmiot obejmował będzie takie zagadnienia jak: podstawy grafowego i hipergrafowego modelowania, grafy i hipergrafy losowe i ich zastosowania, techniki badania sieci takie jak mierzenie centralności wierzchołków, znajdowanie kluczowych wierzchołków, znajdowanie społeczności, modularność, zanurzenia grafów i hipergrafów, podstawy grafowych sieci neuronowych oraz ich zastosowania.

Przedmiotowe efekty uczenia się

Wiedza

K2st_W3: ma zaawansowaną wiedzę szczegółową dotyczącą wybranych zagadnień z zakresu sztucznej inteligencji i dziedzin pokrewnych

K2st_W4: ma wiedzę o trendach rozwojowych i najistotniejszych nowych osiągnięciach informatyki i sztucznej inteligencji, oraz innych, wybranych, pokrewnych dyscyplin naukowych

Umiejętności

K2st_U1: 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_U3: potrafi planować i przeprowadzać eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski oraz formułować i weryfikować hipotezy związane ze złożonymi problemami inżynierskimi i prostymi problemami badawczymi

K2st_U5: potrafi — przy formułowaniu i rozwiązywaniu zadań inżynierskich — integrować wiedzę z różnych obszarów informatyki i sztucznej inteligencji (a w razie potrzeby także wiedzę z innych dyscyplin naukowych) oraz zastosować podejście systemowe, uwzględniające także aspekty pozatechniczne

K2st_U16: potrafi określić kierunki dalszego uczenia się i zrealizować proces samokształcenia, w tym innych osób

Kompetencje społeczne

K2st_K2: rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu informatyki i sztucznej inteligencji w rozwiązywaniu problemów badawczych i praktycznych

K2st_K4: ma świadomość potrzeby rozwijania dorobku zawodowego oraz przestrzegania zasad etyki zawodowej

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Efekty uczenia się weryfikowane są w następujący sposób:

Wykłady: Ocena na podstawie testu zaliczeniowego przeprowadzonego na ostatnim wykładzie. Test zawierał będzie kilka prostych zadań praktycznych oraz kilka teoretycznych pytań z zakresu wykładów (lista zagadnień obowiązujących na zaliczenie będzie dostarczona studentom na 2 tygodnie przed testem). Próg zaliczeniowy: 50%.

Laboratoria: Studenci na laboratoriach na bazie instrukcji wykonywać będą zestawy praktycznych zadań programistycznych a następnie oddawać je prowadzącemu do oceny w ciągu 2 tygodni. Każdy taki zestaw oceniany będzie w skali od 0.0 (brak rozwiązania) do 5.0 (pełne rozwiązanie). Ocena końcowa obliczana będzie jako średnia ocen cząstkowych.

Treści programowe

Program obejmuje techniki modelowania złożonych sieci z użyciem grafów i hipergrafów, w tym

- poznanie otwartych bibliotek do budowania, przetwarzania i wizualizacji grafów, - modele losowe dla grafów i hipergrafów,
- techniki budowy sieci syntetycznych z użyciem grafów,
- metody opisu charakterystyki grafu obejmujące miary centralności, korelacje stopni,
- wykrywanie i analizę społeczności, modularność grafów i hipergrafów,
- techniki zanurzenia grafów
- podstawy grafowych sieci neuronowych.
- przykłady praktycznych zastosowań grafów i hipergrafów w uczeniu maszynowym.

Tematyka zajęć

Program obejmuje teoretyczne (wykład) i praktyczne (laboratorium) aspekty następujących zagadnień:

- 1) Podstawy modelowania z użyciem grafów i hipergrafów. Otwarte biblioteki do budowania, przetwarzania i wizualizacji grafów (w tym iGraph, hypernetx, networkx).
- 2) Metody modelowania złożonych sieci. Modele grafu/hipergrafu losowego.
- 3) Budowa sieci syntetycznych z użyciem grafów i hipergrafów losowych.
- 4) Miara centralności wierzchołka w grafie, znajdowanie wierzchołków o wybranej charakterystyce w grafie, korelacja stopni.

- 5) Wykrywanie i analiza społeczności, w tym społeczności nakładających się, modularność grafów i hipergrafów.
- 6) Zanurzenia grafów. Metody oceny jakości zanurzeń.
- 7) Podstawy grafowych sieci neuronowych (GNN).
- 8) Przykłady zastosowań grafów w uczeniu maszynowym (czyszczenie, wstępne przetwarzanie danych, ważność cech, predykcja połączeń, klasyfikacja węzłów sieci, klasyfikacja sieci).

Metody dydaktyczne

Wykłady: prezentacje multimedialne, demonstracje przykładów wraz z rozwiązaniami, analiza przykładowego kodu rozwiązań.

Laboratoria: praktyczne zadania, głównie programistyczne (z użyciem skryptów języka Python oraz otwartych bibliotek), dyskusja nad przykładowymi rozwiązaniami, praca zespołowa.

Literatura

Podstawowa:

Bogumił Kamiński, Paweł Prałat, François Théberge: Mining Complex Networks, Chapman and Hall/CRC, 2021.

William L. Hamilton, Graph Representation Learning, Morgan & Claypool Publishers, 2020. (https://www.cs.mcgill.ca/~wlh/grl_book/)

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

Uzupełniająca:

Albert-László Barabási, Network Science, Cambridge University Press, 2017.

M. Newman. Networks. Oxford University Press, 2018

A.N. Langville, C.D. Meyer. Google's PageRank and beyond: The science of search engine rankings. Princeton University Press, 2011

F. Chung, L. Lu, Complex Graphs and Networks, American Mathematical Society, 2006.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	50	2,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	30	1,00
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	20	1,00