



## 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 (np. online)

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/](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 |