



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wprowadzenie do sztucznej inteligencji [S1SI1E>WdSI]

### Przedmiot

Kierunek studiów

Sztuczna inteligencja/Artificial Intelligence

Rok/Semestr

1/1

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

angielski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

### Liczba godzin

Wykład

15

Laboratorium

15

Inne (np. online)

0

Ćwiczenia

0

Projekty/seminaria

0

### Liczba punktów ECTS

3,00

### Koordynatorzy

dr hab. inż. Miłosz Kadziński prof. PP  
milosz.kadzinski@put.poznan.pl

### Wykładowcy

dr hab. inż. Miłosz Kadziński prof. PP  
milosz.kadzinski@put.poznan.pl

dr inż. Krzysztof Martyn  
krzysztof.martyn@put.poznan.pl

dr inż. Michał Tomczyk  
michal.tomczyk@put.poznan.pl

### Wymagania wstępne

Podstawowa wiedza matematyczna ze szkoły średniej. Podstawowe umiejętności programowania w języku Python, rozwijane na równoległe prowadzonym kursie z Wprowadzenia do programowania.

### Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z głównymi trendami Sztucznej Inteligencji (SI). Trendy te obejmują eksplorację danych, uczenie maszynowe, optymalizację, analizę decyzji oraz sieci neuronowe. Studenci poznają podstawowe metody, techniki oraz algorytmy dla każdej z wymienionych dziedzin, by następnie wykorzystywać je do rozwiązywania rzeczywistych problemów. Podejmowane na przedmiocie tematy będą następnie szczegółowo omawiane podczas przedmiotów oferowanych na drugim i trzecim roku studiów na kierunku Sztuczna Inteligencja.

### Przedmiotowe efekty uczenia się

#### Wiedza:

K1st\_W3: ma uporządkowaną wiedzę teoretyczną dotyczącą kluczowych zagadnień informatyki z zakresu sztucznej inteligencji w tym m.in. eksploracji danych, uczenia maszynowego, optymalizacji oraz analizy decyzji

K1st\_W4: zna i rozumie podstawowe techniki, metody, algorytmy oraz narzędzia wykorzystywane w procesie rozwiązywania zadań informatycznych oraz problemów sztucznej inteligencji, w tym m.in. do grupowania, klasyfikacji, optymalizacji oraz wspomaganie decyzji

K1st\_W5: ma podstawową wiedzę o istotnych kierunkach rozwoju i najważniejszych osiągnięciach sztucznej inteligencji rozumianej jako istotna dziedzina informatyki czerpiąca z osiągnięć innych dyscyplin naukowych oraz dostarczająca dla nich rozwiązań o potencjale praktycznym; zna historię i aktualne trendy w sztucznej inteligencji

#### Umiejętności:

K1st\_U3: potrafi formułować i rozwiązywać złożone problemy dotyczące eksploracji danych, optymalizacji oraz podejmowania decyzji, stosując odpowiednio dobrane metody takie jak algorytmy grupowania, techniki klasyfikacji, podejścia do optymalizacji, metody przeszukiwania grafu lub narzędzia analizy decyzji

K1st\_U4: potrafi zaplanować i przeprowadzić eksperymenty, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki oraz wyciągać z nich wnioski w kontekście problemów eksploracji danych, uczenia maszynowego oraz problemów decyzyjnych wymagających znalezienia optymalnego rozwiązania lub podzbioru najbardziej preferowanych rozwiązań

K1st\_U9: ma umiejętność prostej adaptacji istniejących oraz formułowania i implementacji nowych algorytmów w języku Python, w tym algorytmów typowych dla różnych nurtów sztucznej inteligencji takich jak eksploracja danych, uczenie maszynowe, sztuczne sieci neuronowe, analiza decyzji lub optymalizacja

K1st\_U10: potrafi pozyskiwać, analizować i przetwarzać dane różnego typu, dokonywać ich syntezy do wiedzy i wniosków przydatnych do rozwiązywania szerokiego spektrum problemów decyzyjnych

K1st\_U11: potrafi wykorzystywać oraz adaptować modele zachowań inteligentnych (np. algorytmy ewolucyjne, sztuczne sieci neuronowe czy metody wspomaganie decyzji) oraz narzędzia informatyczne symulujące te zachowania

K1st\_U16: potrafi planować i realizować własne uczenie się przez całe życie oraz zna możliwości dalszego doksztalcania (studia II stopnia)

#### Kompetencje społeczne:

K1st\_K1: rozumie, że w informatyce ze szczególnym uwzględnieniem sztucznej inteligencji wiedza i umiejętności bardzo szybko stają się przestarzałe, dostrzegając przy tym potrzebę ciągłego doksztalcania oraz podnoszenia własnych kompetencji

K1st\_K2: ma świadomość istotności wiedzy i badań naukowych związanych z informatyką i sztuczną inteligencją 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: zna przykłady wadliwie działających systemów sztucznej inteligencji, które doprowadziły do strat ekonomicznych, społecznych lub środowiskowych

K1st\_K5: potrafi myśleć i działać w sposób przedsiębiorczy, m.in. znajdując komercyjne zastosowania dla tworzonych systemów sztucznej inteligencji, 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: zaliczenie przeprowadzone na ostatnim wykładzie. Studenci muszą rozwiązać zadania obliczeniowe dotyczące zagadnień prezentowanych na poszczególnych wykładach. Każde zadanie jest oceniane indywidualnie i za jego rozwiązanie przyznawana jest określona liczba punktów. Punkty są sumowane i następująca skala jest wykorzystywana do określenia oceny: <50% - 2.0, [50% , 60%) - 3.0, [60% , 70%) - 3.5, [70% , 80%) - 4.0, [80% , 90%) - 4.5, and [90% , 100%] - 5.0.

Laboratoria: Po każdym zajęciach, studenci rozwiązują zadania programistyczne i przedstawiają rozwiązania osobie prowadzącej laboratoria w ciągu dwóch tygodni. Każde zadanie jest oceniane na skali od 2.0 do 5.0. Ostateczna ocena jest obliczana jako średnia z ocen przyznanych za poszczególne zadania z zastrzeżeniem, że najgorsza ocena uzyskana w trakcie semestru nie jest brana pod uwagę.

## Treści programowe

Wprowadzenie do Sztucznej Inteligencji: Definicja SI. Główne dziedziny zastosowań oraz przykładowe zastosowania z ostatnich lat. Krótka historia SI oraz główne trendy rozwojowe.

Eksploracja danych z wykorzystaniem algorytmów grupowania: Eksploracja danych jako proces odkrywania wzorców w zbiorach danych. Grupowanie jako proces podziału zbiorów danych w interpretowalne podgrupy. Dlaczego grupowanie jest przydatne? Popularne zastosowania algorytmów grupowania. Grupowanie - podstawowe kroki. Reprezentacja obiektów - skupienie się na macierz użytkownik-strony. Popularne miary podobieństwa. Przegląd algorytmów grupowania. Algorytmy podziału: K-średnich i jego rozszerzenia. Algorytmy hierarchiczne: Aglomeracyjne Grupowanie Hierarchiczne.

Algorytmy klasyfikacji: Podstawy analizy tekstów oraz przetwarzania języka naturalnego. Typy problemów rozważanych w eksploracji danych. Przykład klasyfikacji tekstu. Jak zrealizować klasyfikację? Reprezentacja dokumentów tekstowych. Klasyfikacja oparta na odległości. Podobieństwo Jaccarda i miara kosinusowa. Klasyfikator Rocchio oraz k-Najbliższych Sąsiadów. Klasyfikacja Bayesowska z wygładzaniem. Jak ocenić model klasyfikujący? Rola zbiorów uczących, testowych oraz walidujących. Popularne miary takie jak jakość klasyfikacji, macierz pomyłek, dokładność, precyzja oraz miara F. Drzewa decyzyjne oraz przeuczenie: Przykłady zadań klasyfikacji. Drzewa decyzyjne: interpretacja, charakterystyka oraz wykorzystanie w klasyfikacji. ID3 jako sławny algorytm uczenia drzew decyzyjnych. Podstawy teorii informacji - zysk informacji oraz entropia warunkowa. Wykorzystanie współczynnika podziału oraz względnego zysku do wyboru najlepszego atrybutu w węźle drzewa. Zapobieganie przeuczeniu przez przycinanie drzew w trakcie lub po wzroście.

Algorytmy ewolucyjne dla problemów optymalizacji: Przegląd algorytmów inspirowanych naturą. Problemy optymalizacji. Podstawy optymalizacji dyskretnej/kombinatorycznej. Problem plecakowy i jego rzeczywiste zastosowania. Problem komiwojażera i jego rzeczywiste zastosowanie. Algorytmy ewolucyjne jako meta-heurystyki. Reprezentacja rozwiązań. Mutacja, krzyżowanie oraz operatory selekcji. Obliczenie wartości funkcji przystosowania. Dlaczego algorytmy ewolucyjne są tak popularne? Wielokryteriowe wspomaganie decyzji: Problemy decyzyjne - warianty, kryteria oraz typów problemów decyzyjnych. Dominacja, Pareto optymalność oraz informacja preferencyjna. Relacja przewyższania jako jeden z popularnych modeli preferencji. Informacja preferencyjna wymagana w metodach ELECTRE. Konstrukcja relacji przewyższania w metodzie ELECTRE I poprzez realizację testów zgodności i niezgodności. Eksploatacja grafu relacji przewyższania poprzez wyznaczenie jądra grafu. Eliminacja cykli. Wprowadzenie do sztucznej sieci neuronowych: Historia i zastosowania sieci neuronowych. Inspiracje biologiczne, jednostki przetwarzające i wagi. Architektury sieci neuronowych. Najpopularniejsze funkcje aktywacji. Funkcje straty i błędu. Algorytm spadku gradientu. Algorytm propagacji wstecznej. Popularne rozszerzenia takie jak aktualizacja wsadowa oraz momentum. Zapobieganie przeuczeniu z wykorzystaniem warunków stopu, regularyzacji oraz wyciszenia. Podstawy sieci konwolucyjnych: warstwy, filtry, hiper-parametry, dlaczego działają w praktyce?

Algorytmu przeszukiwania: skupienie na problemie najkrótszej ścieżki i jego rzeczywistych zastosowaniach. Algorytmy przeszukiwania grafu. Algorytm Dijkstry. Algorytm A\* (A gwiazdka).

## Metody dydaktyczne

Wykład: slajdy multimedialne dotyczące różnych dziedzin Sztucznej Inteligencji, ilustrowane przykładami oraz zadania obliczeniowe, służące jako podsumowanie wykładu i przygotowanie do zaliczenia.

Laboratoria: rozwiązywanie zadań ilustrujących na tablicy, programowanie w języku Python, przeprowadzenie eksperymentów obliczeniowych, dyskusja wybranych metod, praca zespołowa.

## Literatura

Podstawowa

P. Stone et al., Artificial Intelligence and Life in 2030. One Hundred Year Study on Artificial Intelligence. Stanford, 2016.

Data Mining: Concepts and Techniques, 3rd Edition J. Han, M. Kamber, J. Pei, Morgan Kaufman, 2011.

Introduction to Machine Learning with Python: A Guide for Data Scientists, 1st Edition, A. Muller, S. Guido, O'Reilly Media, 2016.

An Overview of ELECTRE Methods and their Recent Extensions. J.R. Figueira, S. Greco, B. Roy, R. Słowiński, Journal of Multi-Criteria Decision Analysis, 20: 61-85, 2013.

Introduction to Evolutionary Computing, A. Eiben, J. Smith, Springer, 2003.

Convolutional Neural Networks for Visual Recognition - Module 1: Neural Networks, F.-F. Li, 2020 (<https://cs231n.github.io/>).

Uzupełniająca

Principles of Data Mining (Adaptive Computation and Machine Learning), 1st Edition, D. Hand, H. Mannila, P. Smyth, A Bradford Book, 2001.

Convolutional Neural Networks for Visual Recognition - Module 2: Convolutional Neural Networks, F.-F. Li, 2020 (<https://cs231n.github.io/>).

Cormen, Thomas H.; Leiserson, Charles E.; Rivest, Ronald L.; Stein, Clifford (2001). "Section 24.3: Dijkstra's algorithm". Introduction to Algorithms (Second ed.). MIT Press and McGraw–Hill. pp. 595–601.

### 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 kolokwίων/egzaminu, wykonanie projektu)	45	1,50