SYLABUS

DOTYCZY CYKLU KSZTAŁCENIA 2026/2027 - 2029/2030

Rok akademicki 2027/2028

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	*podstawy sztucznej inteligencji*
Kod przedmiotu*	
Nazwa jednostki prowadzącej kierunek	*Instytut Informatyki, Wydział Nauk Ścisłych i Technicznych*
Nazwa jednostki realizującej przedmiot	*Instytut Informatyki, Wydział Nauk Ścisłych i Technicznych*
Kierunek studiów	*sztuczna inteligencja*
Poziom studiów	*studia I stopnia*
Profil	*ogólnoakademicki*
Forma studiów	*stacjonarne*
Rok i semestr/y studiów	*rok II, semestr 3*
Rodzaj przedmiotu	*przedmiot kierunkowy*
Język wykładowy	*polski*
Koordynator	*dr Wojciech Rząsa*
Imię i nazwisko osoby prowadzącej / osób prowadzących	*dr Wojciech Rząsa*

***** - *opcjonalnie, zgodnie z ustaleniami w Jednostce*

1.1.Formy zajęć dydaktycznych, wymiar godzin i punktów ECTS

Semestr (nr)	Wykł.	Ćw.	Konw.	Lab.	Sem.	ZP	Prakt.	Inne (jakie?)	**Liczba pkt. ECTS**
3	30	15		30					6

1.2. Sposób realizacji zajęć

zajęcia w formie tradycyjnej

1.3 Forma zaliczenia przedmiotu (z toku)

wykład – egzamin, ćwiczenia – zaliczenie z oceną, laboratoria – zaliczenie z oceną

2.WYMAGANIA WSTĘPNE

- Znajomość wybranych zagadnień logiki matematycznej: rachunek zdań, dowodzenie tautologii, reguły poprawnego wnioskowania
- Umiejętność zapisu problemów w postaci funkcji boolowskich i ich przekształcania
- Wiedza i umiejętności wymagane na przedmiocie algorytmy i struktury danych cz.1
- Umiejętność programowania w języku Python

3. CELE, EFEKTY UCZENIA SIĘ, TREŚCI PROGRAMOWE I STOSOWANE METODY DYDAKTYCZNE

3.1 Cele przedmiotu

C1	Znajomość przez studentów zarysu historii rozwoju sztucznej inteligencji, jej wybranych osiągnięć i współczesnych wyzwań
C2	Znajomość przez studentów etycznych aspektów rozwoju sztucznej inteligencji
C3	Znajomość i umiejętność stosowania przez studentów wybranych algorytmów wyszukiwania: najkrótszych ścieżek w grafie, optymalnych strategii w grach
C4	Znajomość przez studentów różnych rodzajów uczenia maszynowego i schematów odkrywania wiedzy z danych, rozumienie i umiejętność stosowania wybranych algorytmów z zakresu preprocessingu, uczenia nadzorowanego i nienadzorowanego a także metryk oceny jakości zbudowanych modeli
C5	Znajomość i rozumienie podstawowych pojęć z zakresu teorii zbiorów rozmytych i zbiorów przybliżonych
C6	Nabycie umiejętności projektowania, analizowania i symulacji algorytmów wyszukiwania i budowy modeli
C7	Nabycie sprawności w programowaniu w języku Python, w tym stosowania funkcji bibliotecznych Numpy i Scikit-learn

3.2 Efekty uczenia się dla przedmiotu

EK (efekt uczenia się)	Treść efektu uczenia się zdefiniowanego dla przedmiotu	Odniesienie do efektów kierunkowych [1]
EK_01	koncepcje słabej i silnej sztucznej inteligencji, rozróżnia symboliczną AI od inteligencji obliczeniowej, zna zarys rozwoju AI oraz aktualne obszary jej zastosowań, wyzwania, problemy i możliwości stosowania i rozwoju AI	K_W04
EK_02	wybrane algorytmy przeszukiwania i ich przykładowe zastosowania	K_W04
EK_03	etapy procesu odkrywania wiedzy z danych i ich specyfikę a także różne techniki wstępnego przygotowania danych do analizy / do uczenia maszynowego	K_W04, K_W05
EK_04	szczegółowo kilka algorytmów reprezentujących różne rodzaje analizy danych oraz uczenia maszynowego, w tym rozumie znaczenie ich hiperparametrów	K_W05
EK_05	rozumie podstawy teorii definiowania pojęć nieostrych lub niepewnych (np. zbiorów rozmytych, zbiorów przybliżonych) i zna koncepcje ich wykorzystania w problemach uczenia nadzorowanego lub nienadzorowanego	K_W04, K_W05
EK_06	analizować i modyfikować poznane algorytmy AI	K_U04
EK_07	stosować biblioteczne implementacje algorytmów AI oraz samodzielnie implementować nowe	K_U04

[1] W przypadku ścieżki kształcenia prowadzącej do uzyskania kwalifikacji nauczycielskich uwzględnić również efekty uczenia się ze standardów kształcenia przygotowującego do wykonywania zawodu nauczyciela.

EK_08	dobierać poznane algorytmy AI do różnych problemów (oczywistych i nietypowych) a następnie przeprowadzić walidację, analizę błędów i ocenę jakości działania modelu	K_U05

3.3 Treści programowe

A. Problematyka wykładu

Pojęcie sztucznej inteligencji (koncepcja słabej i silnej sztucznej inteligencji) historia rozwoju
Uczenie maszynowe – pojęcia podstawowe: formaty danych, rodzaje uczenia maszynowego, schematy uczenia, miary jakości uczenia (funkcje kosztu) i metody ich optymalizacji, błędy metodyki uczenia (wyciek danych, przeuczenie, niedouczenie)
Techniki preprocesingu – ustalenie skal pomiarowych wartości atrybutów, normalizacja, standaryzacja, dyskretyzacja, identyfikacja wartości / obiektów odstających, obsługa wartości brakujących, redukcja / ekstrakcja atrybutów
Niepewność i niekompletność danych – teorie: ewidencji, zbiorów rozmytych, zbiorów przybliżonych
Algorytmy uczenia nadzorowanego: kNN, ID3, C4.5 i CART, LEM2, MLEM2, naiwny klasyfikator Bayesa,
Algorytmy uczenia nienadzorowanego: analiza skupień (k-means i jego odmiany: fuzzy k-means, EM; DBscan), analiza koszykowa, systemy rekomendacji
Algorytmy wyszukiwania i optymalizacji w problemach wspomagania decyzji i grach: Minimax (bez i z przycinaniem alfa-beta), algorytm Dijkstry, algorytm A*
Etyczny aspekt rozwoju sztucznej inteligencji - wyzwania, zagrożenia

B. Problematyka ćwiczeń

Skale pomiarowe i podstawowe parametry statystyczne
Preprocessing: normalizacja, standaryzacja, dyskretyzacja
Wyznaczanie podstawowych pojęć z teorii zbiorów rozmytych i przybliżonych
Analiza i symulacja algorytmów C4.5, CART, naiwny klasyfikator Bayesa, kNN, MLEM2
Analiza i symulacja algorytmu k-means i EM
Analiza i symulacja algorytmów Minimax (w tym z modyfikacjami), Dijkstry, A*, Monte Carlo Tree Search

C. Problematyka laboratoriów

Wstęp do eksploracji danych: ładowanie i preprocessing danych, podział danych na treningowe i testowe, stosowanie sprawdziany krzyżowego, zapoznanie z API scikit-learn, obliczanie miar jakości uczenia nadzorowanego i nienadzorowanego, poznanie gotowych implementacji podstawowych algorytmów
Samodzielna implementacja algorytmów kNN, NB
Samodzielna implementacja drzewa decyzyjnego typu CART za pomocą algorytmu rekurencyjnego
Samodzielna implementacja algorytmów k-means oraz fuzzy c-means
Samodzielna implementacja algorytmów Dijkstry i A* (z różnymi modyfikacjami) wraz z zastosowaniem ich do rozwiązywania znajdywania optymalnych ścieżek w praktycznych zastosowaniach
Samodzielna implementacja algorytmu mini-max (z różnymi modyfikacjami) dla powszechnie znanej dwuosobowej gry planszowej

Monte Carlo Tree Search

3.4 Metody dydaktyczne

Wykład: wykład problemowy, wykład z prezentacją multimedialną
Ćwiczenia: analiza tekstów z dyskusją, praca w grupach - rozwiązywanie zadań, dyskusja
Laboratorium: realizacja zadań programistycznych, metoda projektów

4. METODY I KRYTERIA OCENY

4.1 Sposoby weryfikacji efektów uczenia się

Symbol efektu	Metody oceny efektów uczenia się (np.: kolokwium, egzamin ustny, egzamin pisemny, projekt, sprawozdanie, obserwacja w trakcie zajęć)	Forma zajęć dydaktycznych (w, ćw, ...)
EK_ 01, EK_05	egzamin pisemny	wykład
EK_ 02 - EK_04	kolokwium, egzamin pisemny	ćwiczenia, wykład
EK_06, EK_08	kolokwium	ćwiczenia, laboratoria
EK_07	projekt	laboratoria

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie przedmiotu następuje na podstawie zaliczenia każdej z trzech jego form: wykładu, ćwiczeń, laboratoriów.

Zaliczenie wykładu następuje na podstawie pozytywnej oceny z egzaminu. Aby uzyskać pozytywną ocenę z egzaminu, należy zaliczyć efekt EK_01 oraz uzyskać ocenę co najmniej dostateczną z efektów EK_02 – EK_05. Ocena z egzaminu jest średnią z ocen z efektów EK_02 – EK_05.

Zaliczenie ćwiczeń następuje na podstawie ocen co najmniej dostatecznych z dwóch kolokwiów. Pierwsze kolokwium weryfikuje osiągnięcie efektów EK_04, EK_06, EK_08, a drugie – osiągnięcie efektów EK_02, EK_06. Ocena z ćwiczeń jest średnią z ocen z dwóch kolokwiów.

Zaliczenie laboratoriów następuje na podstawie ocen co najmniej dostatecznych z jednego kolokwium i jednego projektu. Kolokwium weryfikuje osiągnięcie efektu EK_07, a projekt – osiągnięcie efektów EK_07 – EK_08. Ocena z laboratoriów jest średnią z ocen z kolokwium i projektu.

5. CAŁKOWITY NAKŁAD PRACY STUDENTA POTRZEBNY DO OSIĄGNIĘCIA ZAŁOŻONYCH EFEKTÓW W GODZINACH ORAZ PUNKTACH ECTS

Forma aktywności	Średnia liczba godzin na zrealizowanie aktywności
Godziny z harmonogramu studiów	75
Inne z udziałem nauczyciela akademickiego (udział w konsultacjach, egzaminie)	5

Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	80
SUMA GODZIN	160
SUMARYCZNA LICZBA PUNKTÓW ECTS	**6**

** Należy uwzględnić, że 1 pkt ECTS odpowiada 25-30 godzin całkowitego nakładu pracy studenta.*

6. PRAKTYKI ZAWODOWE W RAMACH PRZEDMIOTU

wymiar godzinowy	–
zasady i formy odbywania praktyk	–

7. LITERATURA

Literatura podstawowa:

- Mariusz Flasiński: „Wstęp do sztucznej inteligencji", PWN S.A., 2011
- Stuart Russell, Peter Norvig: "Sztuczna inteligencja. Nowe spojrzenie", wydanie IV, t. 1-2, Helion S.A., 2023
- Dokumentacja Numpy i Scikit-learn

Literatura uzupełniająca:

- Rishal Hurbans: „Algorytmy sztucznej inteligencji. Ilustrowany przewodnik", Helion 2021
- Giuseppe Bonaccorso: „Algorytmy uczenia maszynowego. Zaawansowane techniki implementacji", Helion 2019