

SYLABUS
DOTYCZY CYKLU KSZTAŁCENIA 2023-2027
 Rok akademicki 2024/2025 i 2025/2026

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>sztuczna inteligencja</i>
Kod przedmiotu	
Nazwa jednostki prowadzącej kierunek	<i>Instytut Informatyki, Kolegium Nauk Przyrodniczych</i>
Nazwa jednostki realizującej przedmiot	<i>Instytut Informatyki, Kolegium Nauk Przyrodniczych</i>
Kierunek studiów	<i>informatyka</i>
Poziom studiów	<i>studia inżynierskie I-go stopnia</i>
Profil	<i>ogólnoakademicki</i>
Forma studiów	<i>stacjonarne</i>
Rok i semestr studiów	<i>rok II i III, semestr 4 i 5</i>
Rodzaj przedmiotu	<i>przedmiot kierunkowy</i>
Język wykładowy	<i>polski</i>
Koordynator	<i>dr Zbigniew Gomółka</i>
Imię i nazwisko osoby prowadzącej / osób prowadzących	<i>dr Zbigniew Gomółka, dr Wojciech Rząsa, mgr inż. Marcin Mrukowicz</i>

1.1. Formy zajęć dydaktycznych, wymiar godzin i punktów ECTS

Semestr (nr)	Wykł.	Ćw.	Konw.	Lab.	Sem.	ZP	Prakt.	Inne (jakie?)	Liczba pkt ECTS
4	20	20		12					4
5	15			15					2

1.2. Sposób realizacji zajęć

zajęcia w formie tradycyjnej

1.3 Forma zaliczenia przedmiotu (z toku)

semestr 4: egzamin

semestr 5: zaliczenie z oceną

2. WYMAGANIA WSTĘPNE

Wiedza i umiejętności wymagane na zaliczenie przedmiotów statystyka opisowa, algorytmy i struktury danych, programowanie w języku Python.

3. CELE, EFEKTY UCZENIA SIĘ, TREŚCI PROGRAMOWE I STOSOWANE METODY DYDAKTYCZNE**3.1 Cele przedmiotu**

C ₁	Przedstawienie dwóch paradygmatów sztucznej inteligencji: słabej i mocnej sztucznej inteligencji. Zwrócenie uwagi na problemy prawne i etyczne związane z szybkim rozwojem sztucznej inteligencji.
C ₂	Zaznajomienie studentów z zagadnieniem uczenia maszynowego i jego czterema rodzajami: uczeniem nienadzorowanym, uczeniem nadzorowanym, uczeniem częściowo nadzorowanym, uczeniem ze wzmocnieniem; pokazanie działania przykładowych algorytmów reprezentujących nienadzorowane i nadzorowane uczenie się.
C ₃	Przedstawienie przykładowych klasycznych algorytmów zaliczanych do sztucznej inteligencji: algorytmów wyszukiwania optymalnej ścieżki oraz Minimax.
C ₄	Nauczenie studentów korzystania ze sztucznych sieci neuronowych w rodzajach uczenia maszynowego.

3.2 Efekty uczenia się

EK (efekt uczenia się)	Treść efektu uczenia się zdefiniowanego dla przedmiotu	Odniesienie do efektów kierunkowych
EK_01	Student zna pojęcia z zakresu uczenia maszynowego, rozumie na czym polegają różne typy uczenia oraz schematy uczenia i weryfikacji jakości wyuczonej wiedzy. Zna przykładowe techniki i algorytmy z zakresu uczenia nadzorowanego i nienadzorowanego, gier dwuosobowych oraz z zakresu wyboru optymalnej ścieżki.	K_Wo3, K_Wo4
EK_02	Student zna przykładowe typy sztucznych sieci neuronowych: perceptron, SOM	K_Wo4
EK_03	Student w znacznym stopniu poprawnie symuluje działanie wybranych algorytmów z zakresu uczenia nienadzorowanego, nadzorowanego, wyboru optymalnej ścieżki, Minimax.	K_Uo2
EK_04	Student potrafi dostosować implementację poznanego algorytmu do problemu i rozwiązać ten problem.	K_Uo1, K_Uo2, K_Uo3
EK_05	Student jest gotów do szanowania dorobku informatyki w zakresie sztucznej inteligencji.	K_Ko5

3.3 Treści programowe**A. Problematyka wykładu**

Część 1 (semestr 4)
Znaczenie pojęć: dane, informacja, wiedza, inteligencja, sztuczna inteligencja, system informacyjny, system decyzyjny, baza transakcji
Nadzorowane uczenie się: definicja, przykłady, klasyfikator (moduł indukcji wiedzy + moduł

stosowania wiedzy), schematy uczenia się: uczenie jednokrotne train & test, uczenie z walidacją train, validate & test, uczenie przyrostowe test then train, uczenie wielokrotne n-krotna walidacja krzyżowa
Uczenie nadzorowane oparte na rozkładach prawdopodobieństw – naiwny klasyfikator Bayesa
Uczenie nadzorowane oparte na pojęciu odległości – algorytm k najbliższych sąsiadów
Uczenie nienadzorowane oparte na pojęciu odległości – algorytmy k średnich i grupowania aglomeracyjnego
Uczenie nienadzorowane – algorytm Apriori od odkrywania zbiorów częstych
Uczenie ze wzmocnieniem i częściowo nadzorowane – omówienie istoty tych rodzajów uczenia
Gry dwuosobowe – algorytm Minimax i Minimax z przycinaniem alfa-beta
Problemy decyzyjne – wyszukiwanie optymalnych ścieżek: algorytm Dijkstry, algorytm A*
Prawne i etyczne dylematy sztucznej inteligencji
Część 2 (semestr 5)
Sieci neuronowe uczone metodami nadzorowanymi.
Sieci samoorganizujące się i struktury hybrydowe
Uczenie głębokie.

B. Problematyka ćwiczeń audytoryjnych

Część 1 (semestr 4)
Symulacje działania algorytmów uczenia nadzorowanego: algorytmu kNN, naiwnego klasyfikatora Bayesa
Symulacja działania algorytmów k-średnich i grupowania aglomeracyjnego
Wyznaczanie maksymalnych zbiorów częstych algorytmem Apriori
Symulacja działania algorytmu Minimax i Minimax z przycinaniem alfa-beta
Symulacja działania algorytmu Dijkstry i A* na planszy (w wersjach z pustą planszą, z planszą zawierającą przeszkody, w wersji z poruszającym się punktem docelowym)

C. Problematyka ćwiczeń laboratoryjnych

Część 1 (semestr 4)
Korzystanie z bibliotecznych implementacji poznanych algorytmów
Projekt i wykonanie aplikacji implementującej (lub modyfikującej implementację) algorytm Minimax do zadanej gry dwuosobowej klasy kółko-krzyżyk
Część 2 (semestr 5)
Rozwiązywanie problemów separowalnych liniowo
Rozwiązywanie problemów nieseparowalnych liniowo
Wykorzystanie pretrenowanych modeli sieci głębokich
Rozwiązywanie problemów klasyfikacji danych

3.4 Metody dydaktyczne

Wykład: wykład problemowy/wykład z prezentacją multimedialną.

Ćwiczenia audytoryjne: symulacja działania algorytmów metodą „tablicową”.

Ćwiczenia laboratoryjne: implementowanie algorytmów, korzystanie z gotowych implementacji do rozwiązywania zadań.

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	egzamin	wykład
EK_02	test wiedzy	wykład
EK_03	kolokwia	ćwiczenia
EK_04	projekt, sprawozdania	ćwiczenia
EK_05	obserwacja w trakcie zajęć, projekt, sprawozdania	ćwiczenia, laboratoria

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Część 1 (semestr 4)

Zaliczenie wykładu (weryfikacja osiągnięcia efektu EK_01): na podstawie egzaminu z zagadnień omówionych na wykładzie.

Aby zdać egzamin należy zdobyć co najmniej 50% możliwych do zdobycia punktów z każdego z dwóch jego komponentów – komponentu uczenia maszynowego oraz komponentu algorytmów gier dwuosobowych i podejmowania decyzji.

Zaliczenie ćwiczeń audytoryjnych

- weryfikacja efektu EK_03: na podstawie oceny z dwóch kolokwiów. Każda z tych składowych musi być oceną pozytywną, a ich wpływ na ocenę końcową jest taki sam.

Aby zaliczyć kolokwium 1 należy wykazać się umiejętnością stosowania „na kartce” poznanych algorytmów z uczenia maszynowego

Aby zaliczyć kolokwium 2 należy wykazać się umiejętnością stosowania „na kartce” poznanych algorytmów z zakresu gier dwuosobowych i podejmowania decyzji.

- weryfikacja efektu EK_05: na podstawie aktywności w trakcie zajęć.

Zaliczenie ćwiczeń laboratoryjnych (weryfikacja efektu EK_04): na podstawie wykonanej implementacji lub modyfikacji gotowej implementacji a) algorytmu uczenia maszynowego, b) algorytmu Minimax.

Część 2 (semestr 5)

Zaliczenie wykładu (weryfikacja efektu EK_02): na podstawie testu wiedzy z zagadnień omówionych na wykładzie.

Zaliczenie ćwiczeń laboratoryjnych (weryfikacja osiągnięcia efektów EK_04 i EK_05): na podstawie sprawozdań z wykonanych ćwiczeń.

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

Forma aktywności	Średnia liczba godzin na zrealizowanie aktywności
Godziny kontaktowe wynikające z harmonogramu studiów	82
Inne z udziałem nauczyciela (udział w konsultacjach, egzaminie)	5
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	70
SUMA GODZIN	157
SUMARYCZNA LICZBA PUNKTÓW ECTS	6

6. PRAKTYKI ZAWODOWE W RAMACH PRZEDMIOTU

wymiar godzinowy	-
zasady i formy odbywania praktyk	-

7. LITERATURA

Literatura podstawowa: 1. Artificial Intelligence. A modern approach: S. Russell, P. Norvig, Prentice Hall 2003 2. Flasiński M.: Wstęp do sztucznej inteligencji. Wydawnictwo Naukowe PWN, Warszawa, 2011. 3. Rutkowski L.: Metody i techniki sztucznej inteligencji. Wydawnictwo Naukowe PWN, Warszawa, 2005. 4. Materiały do cz. 1 wykładów: W. Rząsa, skrypt 2022
Literatura uzupełniająca: 1. Kisielewicz A.: Sztuczna inteligencja i logika. Wydawnictwa Naukowo-Techniczne, Warszawa, 2014. 2. Szeliga M.: Praktyczne uczenie maszynowe. Wydawnictwo Naukowe PWN, Warszawa, 2019. 3. Data Mining: A Knowledge Discovery Approach: K. Cios, W. Pedrycz, R. Swiniarski, L. Kurgan, Springer 2007