

SYLABUS
DOTYCZY CYKLU KSZTAŁCENIA 2025/2026-2028/2029
ROK AKADEMICKI 2027/2028

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>Sztuczne sieci neuronowe i uczenie głębokie</i>
Kod przedmiotu*	
nazwa jednostki prowadzącej kierunek	<i>Instytut Informatyki, Wydział Nauk Ścisłych i Technicznych</i>
Nazwa jednostki realizującej przedmiot	<i>Instytut Informatyki, Wydział Nauk Ścisłych i Technicznych</i>
Kierunek studiów	<i>Informatyka i ekonometria</i>
Poziom studiów	<i>studia pierwszego stopnia</i>
Profil	<i>praktyczny</i>
Forma studiów	<i>studia stacjonarne</i>
Rok i semestr/y studiów	<i>rok III, sem. V</i>
Rodzaj przedmiotu	<i>przedmiot specjalnościowy</i>
Język wykładowy	<i>polski</i>
Koordynator	<i>dr Zbigniew Gomółka</i>
Imię i nazwisko osoby prowadzącej / osób prowadzących	

1.1. Formy zajęć dydaktycznych, wymiar godzin i punktów ECTS

Semestr (nr)	Wykł.	Ćw.	Konw.	Lab.	Sem.	ZP	Prakt.	Inne (jakie?)	Liczba pkt. ECTS
5	15			30		15			4

1.2. Sposób realizacji zajęć

☒ zajęcia w formie tradycyjnej

☐ zajęcia realizowane z wykorzystaniem metod i technik kształcenia na odległość

1.3. Forma zaliczenia przedmiotu (z toku) (egzamin, zaliczenie z oceną, zaliczenie bez oceny)

Egzamin

2. WYMAGANIA WSTĘPNE

Podstawowa znajomość matematyki stosowanej, w szczególności statystyki opisowej, algebry liniowej i funkcji wielu zmiennych. Umiejętność programowania w języku Matlab/Python. Znajomość podstaw uczenia maszynowego, w tym nadzorowanego i nienadzorowanego.

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

3.1 Cele przedmiotu

C ₁	Przedstawienie zaawansowanych metod uczenia maszynowego i sztucznych sieci neuronowych, w tym sieci nadzorowanych, samoorganizujących się i głębokich.
C ₂	Nauczenie studentów projektowania, trenowania i oceny modeli neuronowych oraz wykorzystywania ich do rozwiązywania praktycznych problemów analizy danych.

3.2. Efekty uczenia się dla przedmiotu

EK (efekt uczenia się)	Treść efektu uczenia się zdefiniowanego dla przedmiotu	Odniesienie do efektów kierunkowych
EK_01	Student potrafi przygotować dane i zastosować wybrane metody uczenia maszynowego oraz sieci neuronowych do rozwiązania problemu klasyfikacji, regresji lub klasteryzacji.	K_W02, K_W03, K_U02, K_U03, K_U14
EK_02	Student potrafi dobrać i uzasadnić wybór modelu ML/ANN do określonego zadania oraz ocenić jego skuteczność, możliwości i ograniczenia.	K_W03, K_U05, K_U14
EK_03	Student potrafi zaplanować i przeprowadzić eksperymenty numeryczne obejmujące trenowanie sieci neuronowych, strojenie hiperparametrów oraz porównanie różnych modeli.	K_U02, K_U07, K_U14
EK_04	Student potrafi interpretować wyniki działania modeli ML/ANN, wyciągać wnioski oraz proponować ulepszenia architektury lub metod uczenia.	K_U02, K_U05, K_U14

3.3. Treści programowe

A. Problematyka wykładów

Wprowadzenie do sieci neuronowych i ich rola w uczeniu maszynowym
Trenowanie sieci neuronowych
Sieci neuronowe uczone metodami nadzorowanymi – modele klasyczne
Sieci samoorganizujące się (SOM) i uczenie nienadzorowane
Architektury hybrydowe i łączenie metod ML z sieciami neuronowymi
Wprowadzenie do uczenia głębokiego
Modele pretrenowane i współczesne zastosowania sieci neuronowych

B. Problematyka laboratorium

Wprowadzenie do środowiska uczenia sieci neuronowych
Klasyfikacja problemów liniowo separowalnych
Rozwiązywanie problemów nieseparowalnych
Propagacja wsteczna i optymalizacja
Rekuraryzacja i techniki zapobiegania przeuczeniu
Sieci samoorganizujące się (SOM) - implementacja podstawowa
SOM – interpretacja i zastosowania
Architektury hybrydowe - SOM + klasyfikator
Wprowadzenie do sieci głębokich
Zastosowania sieci konwolucyjnych (CNN) - podstawowe
Wykorzystanie modeli pretrenowanych - transfer learning
Ekstrakcja cech z modeli pretrenowanych
Klasyfikacja danych tabularnych z użyciem sieci neuronowych
Prezentacja projektów i analiza wyników

C. Problematyka zajęć projektowych

Analiza problemu z wykorzystaniem metod uczenia maszynowego lub sieci neuronowych
Przygotowanie i przetwarzanie danych
Projekt i implementacja wybranej architektury sieci neuronowej
Eksperymenty, testowanie i strojenie hiperparametrów
Opracowanie dokumentacji projektowej oraz prezentacja wyników

3.4. Metody dydaktyczne

Wykład: wykład z prezentacją multimedialną.

Laboratorium: symulacja metod uczenia maszynowego na stanowiskach komputerowych.

Projekt: projekt i implementacja wybranego narzędzia uczenia maszynowego.

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 wiedzy z zakresu metod ML i sieci neuronowych, analiza wyników zadań laboratoryjnych, ocena poprawności implementacji podstawowych modeli	wykład, laboratorium
EK_02	egzamin wiedzy z zakresu doboru modelu do problemu, analiza wyników zadań laboratoryjnych, projekt (dobór i uzasadnienie architektury), sprawozdania z laboratoriów, ocena jakości modeli i ich interpretacji	wykład, laboratorium, projekt
EK_03	projekt (plan eksperymentów, strojenie hiperparametrów), sprawozdania z laboratoriów, obserwacja w trakcie zajęć	laboratorium, projekt
EK_04	sprawozdania z laboratoriów (interpretacja wyników), projekt końcowy (wnioski, rekomendacje), prezentacja rezultatów	laboratorium, projekt

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie przedmiotu w semestrze 5 odbywa się na podstawie:
• zaliczenia laboratorium, obejmującego wykonanie wszystkich przewidzianych zadań oraz oddanie sprawozdań (weryfikacja EK_01, EK_02, EK_03, EK_04), • realizacji projektu końcowego, obejmującego przygotowanie modelu ML/ANN, przeprowadzenie eksperymentów oraz prezentację wyników (weryfikacja EK_02, EK_03, EK_04), • zdanie egzaminu (weryfikacja EK_01).
Wszystkie prace zaliczeniowe są punktowane. Uzyskane punkty odpowiadają skali: do 50% - ocena 2.0; od 51% do 69% - ocena 3.0; od 70% do 79% - ocena 3.5; od 80% do 87% - ocena 4.0; od 88% do 94% - ocena 4.5; od 95% do 100% - ocena 5.0.
Warunkiem uzyskania oceny pozytywnej jest spełnienie wszystkich wymagań cząstkowych.

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	60
Inne z udziałem nauczyciela akademickiego (udział w konsultacjach, egzaminie)	5
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	45
SUMA GODZIN	110
SUMARYCZNA LICZBA PUNKTÓW ECTS	4

6. PRAKTYKI ZAWODOWE W RAMACH PRZEDMIOTU

wymiar godzinowy	-
zasady i formy odbywania praktyk	-

7. LITERATURA

Literatura podstawowa:

1. Russell S., Norvig P. – Sztuczna inteligencja. Nowe spojrzenie. Tom 1, Wydawnictwo Helion, Gliwice, 2022.
2. Russell S., Norvig P. – Sztuczna inteligencja. Nowe spojrzenie. Tom 2, Wydawnictwo Helion, Gliwice, 2022.

Literatura uzupełniająca:

1. Engineering Applications of Hybrid Artificial Intelligence Tools, Gomolka et al, Special Issue: https://www.mdpi.com/journal/applsci/special_issues/ooF11J2BKE
2. Müller A. C., Guido S., Machine learning, Python i data science. Wprowadzenie, Helion, Gliwice, wyd. polskie 2021/2023.
3. Géron A., Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III, Helion, Gliwice, 2023.

Akceptacja Kierownika Jednostki lub osoby upoważnionej