

SYLABUS

DOTYCZY CYKLU KSZTAŁCENIA 2025-2029

Rok akademicki 2027/2028

1. PODSTAWOWE INFORMACJE O PRZEDMIOIE

Nazwa przedmiotu	Sztuczne sieci neuronowe i uczenie głębokie
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	Informatyka i ekonometria
Poziom studiów	studia pierwszego stopnia
Profil	praktyczny
Forma studiów	studia stacjonarne
Rok i semestr/y studiów	rok III, sem. V
Rodzaj przedmiotu	przedmiot specjalnościowy
Język wykładowy	polski
Koordinator	dr Zbigniew Gomółka
Imię i nazwisko osoby prowadzącej / osób prowadzących	

* -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
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.
----------------	--

C2	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_Wo2, K_Wo3, K_Uo2, K_Uo3, K_U14
EK_02	Student potrafi dobrać i uzasadnić wybór modelu ML/ANN do określonego zadania oraz ocenić jego skuteczność, możliwości i ograniczenia.	K_Wo3, K_Uo5, K_U14
EK_03	Student potrafi zaplanować i przeprowadzić eksperymenty numeryczne obejmujące trenowanie sieci neuronowych, strojenie hiperparametrów oraz porównanie różnych modeli.	K_Uo2, K_Uo7, K_U14
EK_04	Student potrafi interpretować wyniki działania modeli ML/ANN, wyciągać wnioski oraz proponować ulepszenia architektury lub metod uczenia.	K_Uo2, K_Uo5, 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	Sprawdzian wiedzy z zakresu metod ML i sieci neuronowych, analiza wyników zadań laboratoryjnych, ocena poprawności implementacji podstawowych modeli	wykład, laboratorium
EK_02	projekt (dobór i uzasadnienie architektury), sprawozdania z laboratoriów, ocena jakości modeli i ich interpretacji	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), -zaliczenia sprawdzianu wiedzy z materiału wykładowego (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

** 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: 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