

SYLABUS**DOTYCZY CYKLU KSZTAŁCENIA 2025/26 – 2028/29***(skrajne daty)*

Rok akademicki 2027/28

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE/MODULE

Nazwa przedmiotu	Sztuczna inteligencja w spektroskopii biomedycznej
Kod przedmiotu*	
nazwa jednostki prowadzącej kierunek	Wydział Nauk Ścisłych i Technicznych
Nazwa jednostki realizującej przedmiot	Wydział Nauk Ścisłych i Technicznych
Kierunek studiów	Systemy diagnostyczne w medycynie
Poziom studiów	studia I stopnia
Profil	ogólnoakademicki
Forma studiów	stacjonarne
Rok i semestr/y studiów	rok III, semestr 6
Rodzaj przedmiotu	specjalnościowy: Sztuczna inteligencja w diagnostyce medycznej
Język wykładowy	polski
Koordinator	dr Bohdan Mahlovanyi
Imię i nazwisko osoby prowadzącej / osób prowadzących	dr Bohdan Mahlovanyi

* - zgodnie z ustaleniami na Wydziale

1.1. Formy zajęć dydaktycznych, wymiar godzin i punktów ECTS

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

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)****WYKŁAD – EGZAMIN****LABORATORIA – ZALICZENIE Z OCENĄ****ĆWICZENIA – ZALICZENIE Z OCENĄ**

2. WYMAGANIA WSTĘPNE

Student powinien wykazać się wiedzą z zakresu analizy matematycznej, analizy danych, programowania i spektroskopii.

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

3.1 Cele przedmiotu

C1	Zapoznanie studentów z podstawowymi koncepcjami sztucznej inteligencji (SI) i uczenia maszynowego.
C2	Nauka zastosowania metod SI do analizy danych spektroskopowych w biomedycynie.
C3	Rozwijanie umiejętności korzystania z narzędzi programistycznych do analizy danych biomedycznych.

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	Student zna i rozumie w zaawansowanym stopniu pojęcia sztucznej inteligencji oraz metody uczenia maszynowego wykorzystywane w analizie danych spektroskopowych w biomedycynie.	K_Wo2
EK_02	Student zna i rozumie w zaawansowanym stopniu zjawiska, procesy i prawa niezbędne do opanowania zasad działania wybranego sprzętu diagnostycznego wykorzystywanego w spektroskopii biomedycznej.	K_Wo4
EK_03	Student zna i rozumie zaawansowane metody przetwarzania danych spektroskopowych, w tym redukcję wymiarowości, filtrację szumów oraz analizę statystyczną.	K_Wo5
EK_04	Student zna i rozumie w zaawansowanym stopniu modele uczenia maszynowego, w tym klasyfikację i regresję i wie jak zastosować je do analizy danych spektroskopowych i diagnostyki biomedycznej.	K_Wo6
EK_05	Student potrafi korzystać z technologii informatycznych oraz metod uczenia maszynowego w celu optymalizacji i automatyzacji analizy spektroskopowej.	K_Uo3
EK_06	Student potrafi wykorzystywać narzędzia programistyczne (np. Python, TensorFlow, Scikit-learn) do analizy danych biomedycznych i spektroskopowych.	K_Uo4
EK_07	Student potrafi przygotować opracowanie naukowe dotyczące zastosowania SI w spektroskopii biomedycznej oraz zaprezentować uzyskane wyniki.	K_Uo5
EK_08	Student potrafi w sposób profesjonalny i krytyczny przedstawić zastosowanie metod SI w analizie spektroskopowej w medycynie i technice.	K_U10
EK_09	Student jest gotów do inicjowania działań na rzecz	K_Ko4

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

	popularyzacji wiedzy związanej z zastosowaniem fizyki w informatyce	
EK_10	Student jest gotów do przestrzegania zasad etyki zawodowej	K_Ko5

3.3 Treści programowe

A. Problematyka wykładu

Treści merytoryczne
Wprowadzenie do sztucznej inteligencji i uczenia maszynowego w kontekście analiz biomedycznych.
Przegląd technik spektroskopowych w biomedycynie (Raman, FTIR, ATR, FEWS) – charakterystyka i zastosowania.
Metody wstępnego przetwarzania danych spektroskopowych: normalizacja, filtracja szumów, korekcja tła.
Redukcja wymiarowości i metody analizy statystycznej (PCA, analiza skupień, metody walidacji).
Modele uczenia maszynowego w analizie spektroskopowej: klasyfikacja, regresja, grupowanie.
Dobór metod ML/AI do określonych typów danych i problemów diagnostycznych.
Wizualizacja i interpretacja wyników analiz – od statystyki do modeli predykcyjnych.
Krytyczna ocena ograniczeń i możliwości zastosowania AI w spektroskopii biomedycznej.

B. Problematyka ćwiczeń

Treści merytoryczne
Dyskusja nad typowymi problemami w analizie danych spektroskopowych – przykłady z praktyki biomedycznej.
Rozwiązywanie zadań dotyczących doboru odpowiednich metod statystycznych i uczenia maszynowego do różnych typów widm (Raman, FTIR, ATR, FEWS).
Analiza przypadków – interpretacja wyników PCA, LDA, PLS-DA, SVM i innych metod w kontekście diagnostyki biomedycznej.
Porównanie skuteczności różnych podejść analitycznych – zalety i ograniczenia.
Krytyczna interpretacja publikacji naukowych opisujących wykorzystanie AI i ML w spektroskopii.
Dyskusja nad etycznymi i praktycznymi aspektami zastosowania sztucznej inteligencji w diagnostyce medycznej.

C. Problematyka laboratorium

Treści merytoryczne
Przygotowanie danych spektroskopowych (Raman, FTIR, ATR, FEWS) do analizy: normalizacja, korekcja tła, usuwanie szumów.
Zastosowanie metod statystycznych do wstępnej analizy danych: PCA, analiza skupień, redukcja wymiarowości.
Dobór odpowiednich modeli uczenia maszynowego (klasyfikacja, regresja, metody

nadzorowane i nienadzorowane) do konkretnych przypadków danych biomedycznych.
Interpretacja wyników modeli: wskaźniki jakości klasyfikacji, ocena błędu, walidacja krzyżowa.
Porównanie skuteczności różnych metod (np. PCA+LDA, PLS-DA, SVM, Random Forest) w analizie przypadków diagnostycznych.
Wizualizacja i krytyczna interpretacja wyników analiz spektroskopowych w kontekście zastosowań biomedycznych.
Opracowanie raportu z analizy wybranego przypadku diagnostycznego — nacisk na metodologię wyboru i uzasadnienie użytych technik.

3.4 Metody dydaktyczne

1. Wykład z prezentacją multimedialną.
2. Ćwiczenia: analiza studiów przypadków, rozwiązywanie zadań problemowych, dyskusja nad doбором odpowiednich metod statystycznych i uczenia maszynowego do danych spektroskopowych.
3. Laboratoria: praktyczna analiza zbiorów danych spektroskopowych (Raman, FTIR, ATR, FEWS), zastosowanie metod statystycznych i modeli ML/AI do klasyfikacji i interpretacji wyników, przygotowanie raportów z analiz.

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 PISEMNY, KOŁOKWIUM, SPRAWOZDANIE	W, ĆW, LAB
EK_02	EGZAMIN PISEMNY, KOŁOKWIUM, SPRAWOZDANIE	W, ĆW, LAB
EK_03	EGZAMIN PISEMNY, KOŁOKWIUM, SPRAWOZDANIE	W, ĆW, LAB
EK_04	EGZAMIN PISEMNY, KOŁOKWIUM, SPRAWOZDANIE	W, ĆW, LAB
EK_05	SPRAWOZDANIE, OBSERWACJA W TRAKCIE ZAJĘĆ	LAB
EK_06	EGZAMIN PISEMNY, KOŁOKWIUM, SPRAWOZDANIE	LAB
EK_07	SPRAWOZDANIE, KOŁOKWIUM, OBSERWACJA W TRAKCIE ZAJĘĆ	ĆW, LAB
EK_08	SPRAWOZDANIE, KOŁOKWIUM, OBSERWACJA W TRAKCIE ZAJĘĆ	ĆW, LAB
EK_09	OBSERWACJA W TRAKCIE ZAJĘĆ	W, ĆW
EK_10	OBSERWACJA W TRAKCIE ZAJĘĆ	W, ĆW

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie przedmiotu odbywa się poprzez weryfikację zdobytej wiedzy i umiejętności poprzez egzamin, kolokwium, sprawozdania, aktywność na zajęciach i udział w dyskusji. Taka weryfikacja potwierdzi stopień osiągnięcia przez studenta zakładanych efektów uczenia się. Weryfikacja osiąganych efektów kształcenia kontrolowana jest na bieżąco w trakcie realizacji zajęć. Ocena uzyskana z zaliczenia przedmiotu pozwoli ocenić stopień osiągniętych efektów.

Wykład – egzamin pisemny zawierający także zagadnienie otwarte.

Egzamin jest zaliczony po zdobyciu przez studenta minimum 50% punktów.

Ćwiczenia – ocena końcowa jest oceną uzyskaną na kolokwium pisemnym. Brana jest także pod uwagę aktywność studenta na zajęciach, która może podnieść ocenę o pół stopnia.

Laboratorium – ocena końcowa jest średnią arytmetyczną ocen z poszczególnych ćwiczeń. Ocena z każdego ćwiczenia stanowi średnią z ustnego kolokwium wstępnego, sprawozdania z ćwiczenia oraz oceny pracy studenta na zajęciach laboratoryjnych.

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	45
Inne z udziałem nauczyciela akademickiego (udział w konsultacjach, egzaminie)	5
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	25
SUMA GODZIN	75
SUMARYCZNA LICZBA PUNKTÓW ECTS	3

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

6. PRAKTYKI ZAWODOWE W RAMACH PRZEDMIOTU

wymiar godzinowy	nd
zasady i formy odbywania praktyk	nd

7. LITERATURA

Literatura podstawowa:

RUSSELL, S., & NORVIG, P. (2009). Artificial Intelligence: A Modern Approach. Prentice Hall.
GOODFELLOW, I., BENGIO, Y., & COURVILLE, A. (2016). Deep Learning. MIT Press.
BISHOP, C. M. (2006). Pattern Recognition and Machine Learning. Springer.

MARIUSZ FLASIŃSKI: Wstęp do sztucznej inteligencji. PWN, 2011.

Literatura uzupełniająca:

WEBB, A. (2002). Statistical Pattern Recognition. Wiley.

TARCA, A. L., CAREY, V. J., CHEN, X. W., ROMERO, R., & DRĂGHICI, S. (2007). Machine Learning and its Applications to Biology. PLOS Computational Biology, 3(6), e116.

M.K. Goshisht, Machine Learning and Deep Learning in Synthetic Biology: Key Architectures, Applications, and Challenges, ACS Omega, 9, 9921-9945, 2024.

GEORGE LUGER: AI: Structures and Strategies for Complex Problem Solving.

Akceptacja Kierownika Jednostki lub osoby upoważnionej