

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

Rok akademicki 2027/28

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE/MODULE

Nazwa przedmiotu	Analiza obrazów wspomagana AI
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 5
Rodzaj przedmiotu	specjalnościowy: Sztuczna inteligencja w diagnostyce medycznej
Język wykładowy	polski
Koordinator	dr Andrii Pozaruk
Imię i nazwisko osoby prowadzącej / osób prowadzących	dr Andrii Pozaruk

* - 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
5	15			30					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)****WYKŁAD – EGZAMIN****LABORATORIUM - ZALICZENIE Z OCENĄ**

2. WYMAGANIA WSTĘPNE

Znajomość podstaw matematyki: w tym rachunku różniczkowego, algebry liniowej oraz statystyki, niezbędna do zrozumienia metod analizy obrazów i algorytmów sztucznej inteligencji.
Podstawowa znajomość programowania: umiejętność programowania w językach takich jak Python, w tym korzystania z bibliotek do przetwarzania danych (np. NumPy, OpenCV, scikit-learn).
Znajomość podstawowych zasad przetwarzania obrazów: rozumienie technik takich jak segmentacja, filtracja, detekcja krawędzi i inne podstawowe operacje na obrazach.
Podstawowa znajomość algorytmów sztucznej inteligencji: znajomość podstaw uczenia maszynowego, w tym regresji, klasyfikacji oraz wstępna znajomość sieci neuronowych.
Zrozumienie podstawowych pojęć z zakresu analizy danych: znajomość metod analizy danych, w tym analizy statystycznej oraz technik walidacji modeli.

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

3.1 Cele przedmiotu

C1	Rozumienie podstawowych metod analizy obrazów, w tym przetwarzania, segmentacji i ekstrakcji cech oraz ich zastosowania w różnych dziedzinach.
C2	Znajomość algorytmów sztucznej inteligencji, takich jak sieci neuronowe, klasyfikacja obrazów, detekcja obiektów i uczenie maszynowe w kontekście analizy obrazów.
C3	Umiejętność posługiwania się specjalistycznym oprogramowaniem oraz narzędziami do analizy obrazów, w tym bibliotekami Python (np. OpenCV, TensorFlow, scikit-image).
C4	Umiejętność interpretacji wyników analizy obrazów oraz ich zastosowania w medycynie, przemyśle, inżynierii oraz innych dziedzinach.
C5	Rozumienie wpływu jakości obrazu, szumów, rozdzielczości oraz warunków akwizycji na proces analizy obrazów i wyniki analizy.
C6	Znajomość metod oceny jakości obrazów oraz skuteczności algorytmów analizy obrazów wspomaganej AI, w tym technik walidacji i testowania.
C7	Umiejętność tworzenia raportów z wynikami analizy obrazów, uwzględniając wnioski, rekomendacje i aspekty etyczne związane z wykorzystaniem AI w analizie obrazów.

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 podstawy rachunku różniczkowego i całkowego, algebry, elementy statystyki matematycznej oraz matematyki stosowanej w zakresie niezbędnym do analizy, przetwarzania i modelowania obrazów cyfrowych.	K_Wo1
EK_02	Student zna i rozumie podstawowe metody analizy obrazów oraz procesy związane z ich zastosowaniem w różnych dziedzinach, w tym w medycynie, technice oraz przemyśle.	K_Wo3

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

EK_03	Student zna i rozumie algorytmy i techniki wykorzystywane w analizie obrazów wspomaganą AI, w tym metody przetwarzania sygnałów, segmentacji, klasyfikacji oraz uczenia maszynowego.	K_Wo6
EK_04	Student zna i rozumie uwarunkowania prawne, etyczne i ekonomiczne związane z analizą obrazów wspomaganą AI, w tym zagadnienia ochrony danych, prywatności i praw autorskich.	K_Wo9
EK_05	Student potrafi analizować obrazy i wyciągać z nich istotne informacje przy użyciu narzędzi i metod analizy obrazów oraz AI.	K_Uo1
EK_06	Student potrafi stosować odpowiednie algorytmy i narzędzia do przetwarzania obrazów, w tym techniki segmentacji, detekcji obiektów, klasyfikacji oraz analizy statystycznej.	K_Uo4
EK_07	Student potrafi przygotować raport dotyczący analizy obrazów, uwzględniając dobór metod, interpretację wyników oraz ocenę efektywności zastosowanych technik.	K_Uo5
EK_08	Student potrafi wykorzystywać metody analityczne i eksperymentalne do formułowania oraz rozwiązywania problemów związanych z analizą obrazów, dostrzegając aspekty systemowe, techniczne i etyczne ich zastosowania.	K_Uo9
EK_09	Student jest gotów do inicjowania działań na rzecz popularyzacji wiedzy związanej z implementacją algorytmów analizy obrazów z wykorzystaniem narzędzi sztucznej inteligencji	K_Ko4

3.3 Treści programowe

A. Problematyka wykładu

Treści merytoryczne
1. Definicja analizy obrazów. Zakres i obszary zastosowań. Rola AI w analizie obrazów.
2. Klasyczne metody vs. AI w analizie obrazów: Tradycyjne metody przetwarzania obrazów; Zalety i ograniczenia metod klasycznych; Przewagi AI w analizie obrazów.
3. Podstawowe techniki przetwarzania obrazów: Przekształcenia geometryczne; Korekcja jasności i kontrastu; Konwersja kolorów
4. Filtracja i poprawa jakości obrazu: Filtry dolnoprzepustowe i górnoprzepustowe; Redukcja szumów; Wyodrębnianie obrazów.
5. Operacje morfologiczne (Erozja i dylatacja, Otwarcie i zamknięcie, Analiza kształtów).
6. Uczenie maszynowe w analizie obrazów: Wstęp do uczenia maszynowego; Algorytmy klasyczne (SVM, PCA); Tworzenie zbiorów danych do analizy obrazów.
7. Klasyfikacja obrazów: Metody klasyfikacji obrazów; Najczęściej stosowane modele; Przykłady zastosowań
8. Wykrywanie obiektów: Różnice między klasyfikacją a detekcją; Algorytmy detekcji (YOLO, SSD, Faster R-CNN); Przykłady użycia.
9. Segmentacja obrazów. Zastosowania w medycynie i autonomicznych systemach.
10. Głębokie sieci neuronowe w analizie obrazów: Zasada działania głębokich sieci; Zastosowanie w analizie obrazów; Wady i ograniczenia.
11. Sieci konwolucyjne (CNN): Architektura CNN; Warstwy konwolucyjne, pooling i w pełni połączone; Przykłady popularnych modeli (VGG, ResNet)

12. Transfer learning: Idea transferu wiedzy między modelami; Wykorzystanie gotowych modeli (ImageNet); Fine-tuning w praktyce.
13. Generative Adversarial Networks (GAN): Zasada działania GAN; Przykłady generowanych obrazów; Zastosowania (deepfake, stylizacja)
14. Praktyczne zastosowania AI w analizie obrazów: Medycyna (diagnostyka obrazowa, analiza CT, PET i MRI); Przemysł (automatyczna kontrola jakości, inspekcja).

B. Problematyka laboratoriów

Treści merytoryczne
1. Omówienie celów i zakresu ćwiczeń. Przegląd technik analizy obrazów.
2. Podstawy pracy z narzędziami do analizy obrazów: Instalacja i konfiguracja środowiska; Wprowadzenie do bibliotek (OpenCV, scikit-image, PIL)
3. Wprowadzenie do TensorFlow/PyTorch (Podstawowe operacje na tensorach, Struktura modeli głębokiego uczenia, Implementacja prostych sieci neuronowych).
4. Przetwarzanie i poprawa jakości obrazów: Filtracja obrazu; Transformacje obrazu; Normalizacja i standaryzacja obrazów.
5. Filtracja i transformacje obrazu. Wykorzystanie filtrów konwolucyjnych. Transformacje geometryczne a także redukcja szumów.
6. Histogramy i wykrywanie krawędzi. Równanie histogramów, algorytmy wykrywania krawędzi. Przykłady zastosowań w analizie obrazów.
7. Implementacja klasyfikacji obrazów z użyciem AI. Przygotowanie zbioru danych do klasyfikacji. Trening i testowanie modeli klasyfikacyjnych za pomocą różnych architektur modeli (MLP, CNN)
8. Wykorzystanie gotowych modeli (Implementacja transfer learningu). Praca z pretrenowanymi modelami (ResNet, VGG i EfficientNet).
9. Segmentacja obrazów z użyciem AI. Wprowadzenie do segmentacji obrazów. (Klasyczne metody segmentacji (Thresholding, Watershed, Segmentacja, U-Net, Mask R-CNN).
10. Projekt końcowy – analiza obrazów w praktyce. Zastosowanie AI do analizy obrazów w wybranym obszarze. Implementacja wybranego modelu. Ocena skuteczności modelu i interpretacja wyników

3.4 Metody dydaktyczne

Wykład: Wykład z prezentacją multimedialną, przekazywanie zaawansowanej wiedzy naukowej z zakresu analizy obrazów cyfrowych oraz zastosowań sztucznej inteligencji w przetwarzaniu i analizie obrazów.

Laboratorium: Praktyczne wykonywanie zadań z zakresu analizy obrazów, planowanie eksperymentów z wykorzystaniem narzędzi AI, formułowanie problemów badawczych, praca z danymi obrazowymi, opracowywanie wyników oraz prezentacja uzyskanych rezultatów w formie raportów i wizualizacji.

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, sprawozdanie, obserwacja w trakcie zajęć	W., LAB.
EK_02	Egzamin pisemny, sprawozdanie, kolokwium	W., LAB.
EK_03	Egzamin pisemny, sprawozdanie, kolokwium	W.
EK_04	Obserwacja w trakcie zajęć	W.
EK_05	sprawozdanie, kolokwium	LAB.
EK_06	sprawozdanie, kolokwium	LAB.
EK_07	sprawozdanie, kolokwium	LAB.
EK_08	sprawozdanie, kolokwium	LAB.
EK_09	obserwacja w trakcie zajęć	W., LAB.

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Wykład: Zaliczenie egzaminu pisemnego.

Laboratorium: Praca na ćwiczeniach obejmuje regularną obecność na zajęciach oraz aktywność w zadaniach indywidualnych lub grupowych związanych z analizą obrazów za pomocą AI. Studenci mogą być zobowiązani do wykonania projektu praktycznego, np. implementacji algorytmu analizy obrazów (rozpoznawanie obiektów, klasyfikacja, segmentacja) przy użyciu narzędzi jak TensorFlow, PyTorch czy OpenCV.

W ramach zadań studenci wykonują zadania związane z praktycznym zastosowaniem AI w analizie obrazów, m.in. implementację algorytmów, optymalizację modeli i analizę wyników. Na koniec kursu mogą zaprezentować aplikację AI rozwiązującą konkretne problemy, np. identyfikację obiektów w obrazach medycznych czy rozpoznawanie twarzy.

Egzamin końcowy składa się z pytań teoretycznych dotyczących analizy obrazów w oparciu o AI oraz części praktycznej, obejmującej implementację prostych algorytmów.

Ocena wiedzy:

- 5.0 – wykazuje znajomość treści kształcenia na poziomie 93%-100%
- 4.5 – wykazuje znajomość treści kształcenia na poziomie 85%-92%
- 4.0 – wykazuje znajomość treści kształcenia na poziomie 77%-84%
- 3.5 – wykazuje znajomość treści kształcenia na poziomie 69%-76%
- 3.0 – wykazuje znajomość treści kształcenia na poziomie 60%-68%
- 2.0 – wykazuje znajomość treści kształcenia poniżej 60%

Ocena umiejętności:

- 3,0 – Opanowanie treści programowych na poziomie podstawowym. Odpowiedzi chaotyczne, konieczność stosowania pytań naprowadzających. Czynności laboratoryjne wykonywane przy pomocy nauczyciela.
- 3,5 – Opanowanie treści programowych na poziomie podstawowym. Odpowiedzi uporządkowane, ale wymagają pomocy nauczyciela. Czynności laboratoryjne wykonywane z pomocą nauczyciela, ale w sposób nieco niezdarly.
- 4,0 – Opanowanie treści programowych na poziomie podstawowym. Odpowiedzi dobrze

uporządkowane i samodzielne. Rozwiązywanie problemów w typowych sytuacjach. Czynności laboratoryjne wykonywane samodzielnie, dość sprawnie, z niewielkimi błędami.

- 4,5 – Wiedza wykracza poza poziom podstawowy, wzbogacona o dodatkowe źródła piśmiennictwa. Rozwiązywanie problemów w nowych i złożonych sytuacjach. Czynności laboratoryjne wykonywane samodzielnie, sprawnie i poprawnie.
- 5,0 – Wiedza wykracza poza poziom podstawowy, oparta na samodzielnie zdobytych naukowych źródłach informacji. Czynności laboratoryjne wykonywane samodzielnie, sprawnie, dokładnie i bezbłędnie.

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.)	50
SUMA GODZIN	100
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	nd
zasady i formy odbywania praktyk	nd

7. LITERATURA

Literatura podstawowa:
Literatura uzupełniająca:

Akceptacja Kierownika Jednostki lub osoby upoważnionej