

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, Wydział Medyczny
Kierunek studiów	Systemy diagnostyczne w medycynie
Poziom studiów	studia pierwszego 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
Koordynator	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

LABORATORIA - 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.

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 matematyczne wykorzystywane w analizie obrazów: operacje na macierzach i tensorach obrazu, optymalizację modeli oraz analizę rozkładów, estymację parametrów, w kontekście przetwarzania i modelowania danych obrazowych.	K_Wo1
EK_02	Student zna i rozumie klasyczne metody przetwarzania obrazów cyfrowych, w tym filtrację (filtry dolno- i górnoprzepustowe), poprawę jakości obrazu (redukcja szumów, wyostrażanie), operacje morfologiczne (erozja, dylatacja, otwarcie, zamknięcie), transformacje geometryczne oraz techniki analizy histogramów i detekcji krawędzi.	K_Wo3
EK_03	Student zna i rozumie podstawy uczenia maszynowego w analizie obrazów, w tym metody ekstrakcji cech oraz klasyczne algorytmy, a także ich zastosowanie w zadaniach klasyfikacji i redukcji wymiarowości danych obrazowych.	K_Wo6
EK_04	Student zna i rozumie metody głębokiego uczenia stosowane w analizie obrazów, w szczególności architekturę i działanie sieci konwolucyjnych, mechanizmy uczenia modeli, a także koncepcję transfer learning.	K_Wo9
EK_05	Student zna i rozumie algorytmy klasyfikacji, detekcji i segmentacji obrazów, w tym nowoczesne rozwiązania oparte na	K_Uo1

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

	AI (np. CNN, U-Net, SegNet), oraz ich zastosowanie w praktyce, zwłaszcza w diagnostyce medycznej i systemach przemysłowych.	
EK_o6	Student potrafi przetwarzać obrazy cyfrowe z wykorzystaniem narzędzi programistycznych (Python) i bibliotek (OpenCV, scikit-image, PIL), realizując operacje takie jak filtracja, transformacje geometryczne, normalizacja oraz poprawa jakości obrazów.	K_Uo4
EK_o7	Student potrafi projektować i implementować modele analizy obrazów z wykorzystaniem bibliotek AI (TensorFlow, PyTorch), w tym przygotowywać dane (tworzenie zbiorów danych, augmentacja, podział na zbiory treningowe i testowe), trenować modele klasyfikacyjne i segmentacyjne.	K_Uo5
EK_o8	Student potrafi analizować i interpretować wyniki działania algorytmów analizy obrazów, oceniać jakość modeli z wykorzystaniem odpowiednich metryk (np. accuracy, precision), identyfikować źródła błędów oraz optymalizować działanie modeli.	K_Uo9
EK_o9	Student rozumie uwarunkowania prawne, etyczne i społeczne związane z analizą obrazów wspomaganą AI, w szczególności w kontekście danych medycznych (ochrona danych osobowych, prywatność).	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.

Laboratoria: 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.

Laboratoria: 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 niezdarny.

- 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:

1. ESPOSITO, DINO; ESPOSITO, FRANCESCO. WPROWADZENIE DO UCZENIA MASZYNOWEGO WEDŁUG ESPOSITO. RED. . WARSZAWA: PROMISE, 2020, 449 S. ISBN 978-83-7541-423-3
2. COMPUTER VISION: ALGORITHMS AND APPLICATIONS" SPRINGER, 2022 (2ND EDITION)
3. DEEP LEARNING FOR COMPUTER VISION WITH PYTHON PYIMAGESEARCH, 2018
4. TOMASZ TRZCIŃSKI, ŁUKASZ BROCKI „DEEP LEARNING. PRAKTYCZNE WPROWADZENIE W JĘZYKU PYTHON I KERAS" HELION, 2021

- | |
|---|
| <ol style="list-style-type: none">5. DEEP LEARNING IN MEDICAL IMAGE ANALYSIS EDITED BY YUDONG ZHANG, JUAN MANUEL GORRIZ AND ZHENGCHAO DONG PRINTED EDITION OF THE SPECIAL ISSUE PUBLISHED IN JOURNAL OF IMAGING 20216. DEEP LEARNING WITH PYTHON THIRD EDITION |
|---|

Literatura uzupełniająca:

- | |
|---|
| <ol style="list-style-type: none">1. A. KRIZHEVSKY, I. SUTSKEVER, G. HINTON „IMAGENET CLASSIFICATION WITH DEEPCONVOLUTIONAL NEURAL NETWORKS” (ARTYKUŁ, 2012)2. Deep Learning Applications in Medical Image Segmentation: Overview, Approaches, and Challenges Editor(s): Sajid Yousuf Bhat, Aasia Rehman, Muhammad Abulaish 2025 |
|---|

Akceptacja Kierownika Jednostki lub osoby upoważnionej