

SYLABUS
DOTYCZY CYKLU KSZTAŁCENIA 2026/2027 - 2029/2030
Rok akademicki 2028/2029

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>rozpoznawanie obrazów</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>sztuczna inteligencja</i>
Poziom studiów	<i>studia I stopnia</i>
Profil	<i>ogólnoakademicki</i>
Forma studiów	<i>stacjonarne</i>
Rok i semestr/y studiów	<i>rok III, semestr 6</i>
Rodzaj przedmiotu	<i>przedmiot kierunkowy</i>
Język wykładowy	<i>polski</i>
Koordinator	<i>dr inż. Michał Kępski</i>
Imię i nazwisko osoby prowadzącej / osób prowadzących	<i>dr inż. Michał Kępski</i>

* - *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
6	15			30					4

1.2. Sposób realizacji zajęć

zajęcia w formie tradycyjnej

1.3 Forma zaliczenia przedmiotu (z toku)

wykład – zaliczenie bez oceny, laboratoria – zaliczenie z oceną

2. WYMAGANIA WSTĘPNE

Znajomość podstaw algebry, analizy matematycznej, uczenia maszynowego, algorytmów i struktur danych. Podstawowa umiejętność programowania w środowisku Python (Numpy).

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

3.1 Cele przedmiotu

C ₁	Poznanie wybranych architektur głębokich sieci neuronowych stosowanych w zagadnieniu rozpoznawania obrazów.
C ₂	Zapoznanie studentów z tematyką widzenia komputerowego i współczesnych badań w tej dziedzinie. Zapoznanie z typowymi problemami i wyzwaniem stawianymi przed systemami rozpoznawania obrazów.
C ₃	Implementacja wybranych architektur i metod uczenia w środowisku PyTorch oraz nabycie umiejętności stosowania sieci neuronowych do rozpoznawania obrazów we własnych projektach informatycznych.

3.2 Efekty uczenia się dla przedmiotu

EK (efekt uczenia się)	Treść efektu uczenia się zdefiniowanego dla przedmiotu	Odniesienie do efektów kierunkowych ¹
EK_o1	Student zna i rozumie zasady działania oraz ograniczenia kluczowych metod widzenia komputerowego opartych o głębokie sieci CNN i ViT w zadaniach klasyfikacji, detekcji i segmentacji.	K_Wo5, K_Wo6
EK_o2	Student zna i rozumie wybrane zaawansowane zagadnienia zastosowań AI w rozpoznawaniu obrazów, w tym: modele wizualno-językowe, rozpoznawanie wideo, metody rozpoznawania danych 3D oraz generowania obrazów – wraz z typowymi wyzwaniami i ograniczeniami.	K_W10
EK_o3	Student potrafi przeanalizować dane obrazowe oraz zbudować potok przetwarzania w Pythonie: przygotowanie danych, uczenie/uczenie transferowe, uruchomienie i modyfikacja modeli w PyTorch, oraz wykorzystanie narzędzi do wstępnego przetwarzania.	K_Uo4, K_Uo7
EK_o4	Student potrafi dobrać metodę/architekturę do problemu, przeprowadzić walidację i ocenę jakości (metryki odpowiednie do zadania), wykonać analizę błędów oraz zaprezentować wnioski, uwzględniając niepewność/odporność opracowanego rozwiązania. Dodatkowo potrafi wesprzeć wybory angielskojęzyczną literaturą przedmiotu i krytycznie ją ocenić.	K_Uo5

3.3 Treści programowe

A. Problematyka wykładu

Podstawowe zagadnienia widzenia komputerowego. Filtracja, gradient, krawędzie. Detekcja punktów charakterystycznych metodami klasycznymi: detektor Harris'a i SIFT.
Konwolucyjne sieci neuronowe. Klasyczne architektury głębokie w computer vision: AlexNet, ResNet. Współczesne architektury głębokich sieci konwolucyjnych do rozpoznawania obrazów.

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

Detekcja obiektów na obrazie. Segmentacja obrazów. Sieci w pełni konwolucyjne (U-Net).
<i>Vision transformer.</i>
Modele <i>vision-language</i> .
Rozpoznawanie wideo. Rozpoznawanie 3D (chmury punktów, voxele).
Generowanie obrazów. <i>Diffusion models. Neural Radiance Fields.</i>

B. Problematyka laboratoriów

Biblioteka OpenCV i NumPy. Podstawowe operacje na obrazach. Filtracja obrazów.
Detektor Harrisa i SIFT.
Sieci konwolucyjne cz. 1 – implementacja w PyTorch i eksperymenty.
Sieci konwolucyjne cz. 2 – transfer learning.
Detekcja obiektów.
Segmentacja obrazów.
Wyjaśnialność i wizualizacja.
Ataki adversarialne.
Vision transformer cz 1.
Vision transformer cz 2.
Rozpoznawanie wideo.
Metody rozpoznawania danych 3D.
Modele generatywne cz 1.
Modele generatywne cz 2.

3.4 Metody dydaktyczne

Wykład: wykład z prezentacją multimedialną.

Laboratorium: implementacja i testowanie skryptów wykorzystujących techniki rozpoznawania obrazu.

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	test zaliczeniowy	wykład
EK_02	test zaliczeniowy	wykład
EK_03	rozwiązanie zadań, kolokwium	laboratorium
EK_04	rozwiązanie zadań, kolokwium	laboratorium

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie wykładu – efekty EK_ 01, EK_ 02
--

Zaliczenie: student potrafi poprawnie odpowiedzieć na co najmniej 50% pytań związanych pojęciami związanymi z treściami prezentowanymi na wykładach i zawartymi we wskazanej przez prowadzącego literaturze przedmiotu.

Zaliczenie laboratorium – efekty EK_03, EK_04

średnia ważona: rozwiązanie zadań (60%), kolokwium (40%)

Ocena zadań jest średnią uzyskaną z wskazanych zadań do samodzielnego wykonania zawartych w instrukcjach do laboratorium. Zadaniom przypisano wagę punktową, a ocena zadań z danego laboratorium dokonywana jest wg. skali procentowej.

Oddanie zadań po wyznaczonym terminie skutkuje obniżeniem punktacji o 10 punktów proc.

Kolokwium jest przeprowadzane przy komputerze i ma formę praktyczną. Obejmuje samodzielne wykonanie zadań związanych z tematyką ćwiczeń laboratoryjnych (m.in. przygotowanie danych, użycie lub modyfikacja modelu w środowisku PyTorch, dobór metryk oraz analiza wyników). W trakcie kolokwium student korzysta z przygotowanego środowiska programistycznego oraz udostępnionych danych wejściowych zgodnie z zasadami podanymi przez prowadzącego. Kolokwium oceniane jest wg. skali procentowej.

Skala procentowa:

91 – 100% bardzo dobry (5.0); 81 – 90% plus dobry (4.5); 71 – 80% dobry (4.0); 61 – 70% plus dostateczny (3.5); 50 – 60% dostateczny (3.0); poniżej 50% niedostateczny (2.0).

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)	2
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	58
SUMA GODZIN	105
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. Szeliski R.: *Computer vision: Algorithms and applications*, 2nd edition, Springer, 2022.
2. Goodfellow I., Bengio Y., Courville A.: *Deep learning*, MIT Press, 2017.
3. Bishop C. M., Bishop H.: *Deep Learning: Foundations and Concepts*, Springer, 2024.
(w/w pozycie dostępne są w internecie)

Literatura uzupełniająca:

1. Tabor J., Śmieja M., Struski Ł., Spurek P., Wołczyk M.: *Głębokie uczenie. Wprowadzenie*, Helion, 2022.