

SYLABUS

DOTYCZY CYKLU KSZTAŁCENIA 2023 -2027

Rok akademicki 2025/2026

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>rozpoznawanie obrazów</i>
Kod przedmiotu*	
Nazwa jednostki prowadzącej kierunek	<i>Instytut Informatyki, Kolegium Nauk Przyrodniczych</i>
Nazwa jednostki realizującej przedmiot	<i>Instytut Informatyki, Kolegium Nauk Przyrodniczych</i>
Kierunek studiów	<i>informatyka</i>
Poziom studiów	<i>I-stopnia</i>
Profil	<i>ogólnoakademicki</i>
Forma studiów	<i>stacjonarne</i>
Rok i semestr/y studiów	<i>III rok, 6 semestr</i>
Rodzaj przedmiotu	<i>przedmiot specjalnościowy</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>

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)

zaliczenie z oceną

2. WYMAGANIA WSTĘPNE

Znajomość podstaw algebry i analizy matematycznej. Znajomość podstawowych algorytmów i struktur danych. Podstawowa umiejętność programowania w środowisku *Python*.

3. CELE, EFEKTY UCZENIA SIĘ, TREŚCI PROGRAMOWE I STOSOWANE METODY DYDAKTYCZNE**3.1 Cele przedmiotu**

C1	Poznanie wybranych metod rozpoznawania obrazów.
C1	Zapoznanie studentów z tematyką widzenia komputerowego i powiązań z pokrewnymi zagadnieniami (uczenie maszynowe, sztuczna inteligencja). Zapoznanie z typowymi problemami i wyzwaniami stawianymi przed systemami rozpoznawania obrazów.
C3	Poznanie środowiska <i>NumPy</i> i wybranej biblioteki do konwolucyjnych sieci neuronowych, nabycie umiejętności stosowania ich 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_01	Student zna wybrane metody rozpoznawania obrazu, ich podstawy matematyczne oraz klasy problemów, do których metody te są wykorzystywane.	K_Wo8
EK_02	Student zna sposoby implementacji metod przetwarzania obrazów, jest świadomy ich wymagań obliczeniowych i złożoności, potrafi wskazać architektury sprzętowe i techniki programowania wykorzystywane przy ich implementacji.	K_W10
EK_03	Student potrafi stosować metody rozpoznawania obrazów z wybranej biblioteki programistycznej i interpretować rezultaty.	K_U03
EK_04	Student potrafi parametryzować algorytmy rozpoznawania obrazów w zależności od rozwiązywanego problemu. Potrafi porównać uzyskane wyniki z wynikami dostępnymi w literaturze.	K_U01

3.3 Treści programowe**A. Problematyka wykładu**

1. Podstawowe zagadnienia widzenia komputerowego. Sposoby akwizycji i reprezentacji obrazów kolorowych i RGB-D. Podstawowe operacje bezkontekstowe na obrazach. Konwolucje. Filtrowanie. Gradient i detekcja krawędzi.
2. Rozpoznawanie obrazów. Prosty przykład z klasyfikatorem liniowym. Proces uczenia klasyfikatora obrazów. Podział danych. Funkcja kosztu, miary jakości.
3. Klasyfikacja liniowa, klasyfikator SVM. <i>Stochastic gradient descent</i> . Wielowarstwowy perceptron (MLP) i algorytm wstecznej propagacji. Przykładowe deskryptory cech obrazu.
4. Konwolucyjne sieci neuronowe. Uczenie głębokie. Warstwy konwolucyjne i <i>pooling</i> .
5. Uczenie sieci konwolucyjnej. Przetwarzanie wstępne i augmentacja danych. Funkcje aktywacji, inicjalizacja, hiperparametry. <i>Batch normalization, fine tuning, transfer learning</i> .
6. Klasyfikacja obrazów. Współczesne architektury sieci głębokich do rozpoznawania obrazów. Detekcja obiektów na obrazie. Segmentacja obrazów. Generowanie obrazów.
7. Autoenkodery. Sieci rekurencyjne. <i>Attention and Transformers</i> .
8. Rozpoznawanie wideo.

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

B. Problematyka laboratoriów

1. Biblioteka <i>OpenCV</i> i <i>NumPy</i> . Podstawowe operacje na obrazach. <i>Jupyter Notebook</i> jako środowisko do prezentacji wyników. (2 godziny)
2. Filtracja obrazu. Wykrywanie krawędzi. (2 godziny)
3. Klasyfikator liniowy od podstaw. Proces uczenia klasyfikatora liniowego (4 godziny).
4. Deskryptory cech. Klasyfikacja w oparciu o deskryptory cech. (2 godziny)
5. SVM, deskryptory cech i biblioteka <i>scikit-learn</i> . (2 godziny)
6. Sieci neuronowe: biblioteki programistyczne, proces uczenia prostej sieci MLP do rozpoznawania obrazów (zbiór CIFAR-10). (2 godziny)
7. Konwolucyjne sieci neuronowe: biblioteki programistyczne, proces uczenia prostej sieci do rozpoznawania obrazów (zbiór CIFAR-10). (2 godziny)
8. Przetwarzanie wstępne i augmentacja danych. (2 godziny)
9. <i>Batch normalization, fine tuning, transfer learning</i> . (2 godziny)
10. Rozpoznawanie obrazów dla urządzeń mobilnych i wbudowanych. (2 godziny)
11. Mini-projekt programistyczny. (8 godzin)

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	Ocena mini-projektu programistycznego, rozwiązania zadań, aktywność w trakcie zajęć	Laboratorium
EK_04	Ocena mini-projektu programistycznego, rozwiązania zadań, aktywność w trakcie zajęć	Laboratorium

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie wykładu – test – efekty EK_01, EK_02 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). Zaliczenie laboratorium – efekty EK_03, EK_04 średnia ważona: rozwiązanie zadań (60%), mini-projekt programistyczny (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:

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).

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

Ocena mini-projektu jest ustalana biorąc pod uwagę uzyskany zakres funkcjonalny, zgodność z ustaloną specyfikacją oraz jakość przygotowanej implementacji i prezentacji wyników.

Aktywność w trakcie zajęć laboratoryjnych może być podstawą do podwyższenia lub obniżenia oceny o pół stopnia.

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. (dostępna w internecie)
2. Goodfellow I., Bengio Y., Courville A.: *Deep learning*, MIT Press, 2017.
3. Klette R.: *Concise Computer Vision: An Introduction into Theory and Algorithms. Undergraduate Topics in Computer Science*, Springer-Verlag London, 2014.

Literatura uzupełniająca:

1. McKinney W.: *Python w analizie danych: przetwarzanie danych za pomocą pakietów Pandas i NumPy oraz środowiska IPython*, Helion, 2018.
2. Foster D.: *Deep learning i modelowanie generatywne: jak nauczyć komputer malowania, pisania, komponowania i grania*, Helion, 2021.