

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

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>uczenie maszynowe</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 II, semestr 4</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
4	30			30					5

1.2. Sposób realizacji zajęć

zajęcia w formie tradycyjnej

1.3 Forma zaliczenia przedmiotu (z toku)

wykład – egzamin, laboratoria – zaliczenie z oceną

2. WYMAGANIA WSTĘPNE

Analiza matematyczna, algebra liniowa, rachunek prawdopodobieństwa i statystyka, podstawy sztucznej inteligencji.

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

3.1 Cele przedmiotu

C1	Poznanie podstawowych paradygmatów uczenia maszynowego (nienadzorowane, nadzorowane, ze wzmocnieniem, częściowo nadzorowane, samo-nadzorowane) oraz zrozumienie ich założeń, ograniczeń i klas problemów, do których się je stosuje.
C2	Nabywanie umiejętności implementacji i/lub wykorzystania oraz eksperymentalnej analizy klasycznych algorytmów uczenia maszynowego w środowisku Python, obejmującej dobór cech i hiperparametrów, walidację oraz ocenę jakości modeli.
C3	Zapoznanie z podstawami i współczesnymi podejściami uczenia głębokiego oraz opanowanie ich praktycznego użycia w PyTorch, w tym z zastosowaniem elementów interpretowalności modeli.

3.2 Efekty uczenia się dla przedmiotu

EK (efekt uczenia się)	Treść efektu uczenia się zdefiniowanego dla przedmiotu	Odniesienie do efektów kierunkowych
EK_01	Student zna i rozumie podstawowe oraz wybrane zaawansowane metody uczenia maszynowego i uczenia głębokiego, w tym uczenie nadzorowane i nienadzorowane wraz z ich założeniami, ograniczeniami i typowymi zastosowaniami w analizie danych.	K_Wo5, K_Wo6
EK_02	Student potrafi analizować i przetwarzać dane z wykorzystaniem metod uczenia maszynowego w dedykowanych narzędziach programistycznych (NumPy, scikit-learn, PyTorch), przygotować dane do uczenia oraz przeprowadzić eksperymenty obliczeniowe.	K_Uo4
EK_03	Student potrafi dobrać metodę uczenia do postawionego problemu, dobrać cechy i hiperparametry, przeprowadzić walidację i analizę błędów oraz ocenić jakość modelu z użyciem właściwych metryk, a następnie zinterpretować wyniki.	K_Uo5

3.3 Treści programowe

A. Problematyka wykładu

Uczenie nienadzorowane: PCA, estymacja gęstości.
Uczenie nadzorowane: regresja liniowa.
Uczenie nadzorowane: klasyfikator SVM, regresja logistyczna, metody kernelowe.
<i>Boosting i baging</i> , lasy drzew losowych, XGBoost.
Wprowadzenie do sieci neuronowych.
Trenowanie: optymalizacja, regularyzacja, uczenie transferowe.
Sieci konwolucyjne.
Uczenie adwersarialne (modele GAN).
Sieci rekurencyjne: RNN i LSTM.
Atencja i transformery.
Uczenie ze wzmocnieniem.
Uczenie samonadzorowane, częściowo nadzorowane, <i>weakly-supervised</i> .
Wyjaśnialność/interpretowalność modeli głębokich.
Modele grafowe.

B. Problematyka laboratoriów

Uczenie nienadzorowane – implementacja metod i eksperymenty na danych w Numpy.
Regresja liniowa – implementacja metod i eksperymenty na danych w Numpy.
Klasyfikator liniowy, metody kernelowe – implementacja i eksperymenty na danych w Numpy.
Biblioteka scikit-learn: boosting, baging, lasy drzew losowych. Klasyfikator XGBoost.
Wprowadzenie do sieci neuronowych – implementacja sieci fully-connected w Numpy.
Sieci neuronowe – implementacja metod w Numpy (kontynuacja).
Wprowadzenie do biblioteki Pytorch – implementacja sieci i eksperymenty.
Sieci konwolucyjne – implementacja sieci i eksperymenty.
Modele GAN – implementacja i eksperymenty.
Sieci rekurencyjne: RNN i LSTM – implementacja prostych mechanizmów sieci rekurencyjnych w Numpy. Eksperymenty z sieciami rekurencyjnymi w PyTorch.
Atencja i transformery.
Uczenie ze wzmocnieniem.
Uczenie samonadzorowane, częściowo nadzorowane, <i>weakly-supervised</i> .
Wyjaśnialność/interpretowalność modeli głębokich.
Modele grafowe.

3.4 Metody dydaktyczne

Wykład: wykład z prezentacją multimedialną.

Laboratorium: implementacja i testowanie technik uczenia maszynowego.

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	wykład
EK_02	Kolokwium, rozwiązanie zadań	laboratorium
EK_03	Kolokwium, rozwiązanie zadań	laboratorium

4.2 Warunki zaliczenia przedmiotu (kryteria oceniania)

Zaliczenie wykładu – efekt EK_01

Egzamin pisemny: składa się z pytań związanych z pojęciami związanymi z treściami prezentowanymi na wykładach i zawartymi we wskazanej przez prowadzącego literaturze przedmiotu. Ocena z egzaminu ustalana jest wg skali procentowej.

Zaliczenie laboratorium – efekty EK_03, EK_04

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

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. 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	60
Inne z udziałem nauczyciela akademickiego (udział w konsultacjach, egzaminie)	2
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	88
SUMA GODZIN	150
SUMARYCZNA LICZBA PUNKTÓW ECTS	5

* 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. Tabor J., Śmieja M., Struski Ł., Spurek P., Wołczyk M.: *Głębokie uczenie. Wprowadzenie*, Helion, 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.
4. Hastie T., Tibshirani R., Friedman J.: *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd edition, Springer, 2009

Literatura uzupełniająca:

1. James G., Witten D., Hastie T., Tibshirani R., Taylor J.: *An Introduction to Statistical Learning: with Applications in Python*, 1st edition, Springer, 2023.