

SYLABUS
DOTYCZY CYKLU KSZTAŁCENIA 2025/26-2028/29
ROK AKADEMICKI 2026/27

1. PODSTAWOWE INFORMACJE O PRZEDMIOCIE

Nazwa przedmiotu	<i>Eksploracja danych</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>Informatyka i ekonometria</i>
Poziom studiów	<i>studia pierwszego stopnia</i>
Profil	<i>praktyczny</i>
Forma studiów	<i>studia stacjonarne</i>
Rok i semestr/y studiów	<i>rok II, sem. IV</i>
Rodzaj przedmiotu	<i>przedmiot kierunkowy</i>
Język wykładowy	<i>polski</i>
Koordynator	<i>dr Wojciech Rzęsa</i>
Imię i nazwisko osoby prowadzącej / osób prowadzących	<i>dr Wojciech Rzęsa</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
4	12			30					3

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)

zaliczenie z oceną

2. WYMAGANIA WSTĘPNE

Znajomość następujących zagadnień:

- z teoretycznych podstaw informatyki: entropia informacyjna;
- z rachunku prawdopodobieństwa i statystyki: klasyczna definicja prawdopodobieństwa, prawdopodobieństwo warunkowe, niezależność zdarzeń, twierdzenie Bayesa, podstawowe parametry statystyczne jednej zmiennej i korelacja cech.

Umiejętności:

- programowanie w języku Python;
- sprawna obsługa arkusza kalkulacyjnego.

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

3.1 Cele przedmiotu

C1	Zapoznanie studentów z modelami odkrywania wiedzy z danych, technikami wstępnego przetwarzania danych, wybranymi zadaniami eksploracji danych, w tym z algorytmami uczenia maszynowego
C2	Wypracowanie przez studentów umiejętności eksplorowania danych z użyciem następujących narzędzi: Python, Excel oraz Power BI (w tym Power Query)

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 rozróżnia pojęcia: dane, informacja, wiedza. Zna 3 modele procesu odkrywania wiedzy z danych, w tym CRISP-DM, rozumie znaczenie poszczególnych etapów w uzyskaniu wartościowych informacji wyjściowych, w szczególności etapu eksploracji danych. Student zna przykładowe techniki i algorytmy preprocessingu, predykcji, analizy skupień, analizy koszykowej.	K_W02
EK_02	Student zna kilka narzędzi informatycznych wspierających eksplorację danych – potrafi wskazać ich mocne i słabe strony.	K_W03
EK_03	Student swobodnie korzysta w aplikacji biurowych Excel i Power BI w wybranych zadaniach odkrywania wiedzy z danych, w tym danych z obszaru ekonomii oraz w zadaniach komputerowego wspomagania decyzji. Student interpretuje odkryte informacje przekuwając je na wiedzę.	K_U02, K_U03, K_U04, K_U05
EK_04	Student świadomie stosuje funkcje biblioteczne języka Python implementujące wybrane algorytmy uczenia maszynowego lub eksploracji danych w rozwiązywaniu różnych zadań z zakresu eksploracji danych, w tym: danych z obszaru ekonomii oraz w zadaniach komputerowego wspomagania decyzji.	K_U02, K_U03, K_U04, K_U05
EK_05	W trakcie rozwiązywania złożonych problemów Student korzysta z wiedzy eksperckiej, a wiedzę zaczerpniętą z Internetu poddaje krytycznej analizie.	K_K02

3.3. Treści programowe

A. Problematyka wykładu

Znaczenie pojęć: dane, informacja, wiedza. Modele odkrywania wiedzy z danych (KDD). Eksploracja danych jako etap procesu KDD.
Akwizycja danych, opowiadanie danych (ang. data story telling) z wizualizacją danych; preprocessing danych.
Wybrane algorytmy predykcyjnej eksploracji danych – klasyfikacja, regresja.
Szacowanie jakości odkrytej wiedzy.
Wybrane algorytmy analizy koszykowej – zbiory częste, asocjacje, sekwencje, rekomendacje.

B. Problematyka laboratoriów

Przypomnienie i rozszerzenie umiejętności wykorzystania programu MS Excel: wykresy, filtry, działanie na tabelach w tym tabelach przestawnych.
Przypomnienie i rozszerzenie umiejętności programowania w języku Python.
Nauka korzystania z programu Power BI.
Implementowanie w programach Excel, Power BI, Python technik i algorytmów z wykładów; dyskusja wyników działania tych algorytmów na różnych zbiorach danych.
Realizacja projektu zespołowego z zakresu KDD.

3.4 Metody dydaktyczne

Wykład: wykład problemowy, wykład z prezentacją multimedialną

Laboratorium: ćwiczenia indywidualne i grupowe z zakresu analizy danych rzeczywistych połączone z dyskusją i interpretacją wyników, metoda projektów

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_o1	test wiedzy	wykład
EK_o2	test wiedzy	wykład
EK_o3	kolokwium	laboratoria
EK_o4	kolokwium	laboratoria
EK_o5	projekt	laboratoria

4.2. Warunki zaliczenia przedmiotu (kryteria oceniania)

Aby zaliczyć przedmiot należy zaliczyć wykład oraz laboratoria, aby zweryfikować osiągnięte efekty uczenia zastosowane zostaną następujące formy:

Zaliczenie wykładu odbywa się na podstawie testu wiedzy z zakresu: modeli KDD, technik i algorytmów: wstępnego przetwarzania danych oraz eksploracji danych. Zaliczenie testu jest binarne.

[0%; 50%)	niezaliczony
[50%; 100%]	zaliczony

Zaliczenie laboratoriów odbywa się na podstawie (1) dwóch kolokwiów sprawdzających praktyczne umiejętności korzystania z Excela i Power BI (kolokwium 1) oraz Pythona (kolokwium 2) w realizacji wybranych zadań eksploracji danych oraz (2) zespołowego projektu analizy danych realizowanego w małym zespole.

- Kolokwia sprawdzają umiejętność implementacji technik i algorytmów analizy danych w narzędziach Excel, Power BI, Python. Za każde kolokwium można uzyskać maksymalnie 30% łącznej liczby punktów z laboratoriów.

- Projekt sprawdza umiejętność rozwiązywania w zespole realistycznych problemów z zakresu eksploracji danych, interpretacji wyników i formułowania wniosków. Za projekt („obroniony”) można uzyskać maksymalnie 40% łącznej liczby punktów z laboratoriów.

Zakres zdobytych punktów	Ocena z laboratoriów
poniżej 50% punktów możliwych do zdobycia z dowolnego z trzech komponentów oceny	niedostateczny
w przypadku zaliczenia każdego z trzech komponentów oceny na co najmniej 50%:	
[50%; 60%)	dostateczny
[60%; 70%)	dostateczny plus
[70%; 80%)	dobry
[80%; 90%)	dobry plus
[90%; 100%]	bardzo dobry

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	42
Inne z udziałem nauczyciela akademickiego (udział w konsultacjach, „obrona” projektu)	5
Godziny niekontaktowe – praca własna studenta (przygotowanie do zajęć, egzaminu, napisanie referatu itp.)	35
SUMA GODZIN	82
SUMARYCZNA LICZBA PUNKTÓW ECTS	3

6. PRAKTYKI ZAWODOWE W RAMACH PRZEDMIOTU

wymiar godzinowy	nie dotyczy
zasady i formy odbywania praktyk	nie dotyczy

7. LITERATURA

Literatura podstawowa:

1. Kirill Eremenko: Kluczowe kompetencje specjalisty danych, PWN 2021
2. Tadeusz Morzy: Eksploracja danych : metody i algorytmy, PWN 2013

Literatura uzupełniająca:

1. Luca Zavarella: Dodaj mocy Power BI! : jak za pomocą kodu w Pythonie i R pobierać, przekształcać i wizualizować dane, Helion 2023
2. Daniil Maslyuk, Gil Raviv: Power Query w Excelu i Power BI : zbieranie i przekształcanie danych, Helion 2025.

Akceptacja Kierownika Jednostki lub osoby upoważnionej