

Karta przedmiotu

Nazwa i kod przedmiotu	Matematyczne podstawy inżynierii danych, PG_00062725						
Kierunek studiów	Technologie Przemysłu 5.0						
Data rozpoczęcia studiów	październik 2025 r.		Rok akademicki realizacji przedmiotu		2026/2027		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć		Grupa zajęć obowiązkowych z zakresu kierunku studiów		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	2		Język wykładowy		polski		
Semestr studiów	3		Liczba punktów ECTS		5.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		egzamin		
Jednostka prowadząca							
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot						
	Prowadzący zajęcia z przedmiotu						
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	15.0	0.0	0.0	0.0	45
	W tym liczba godzin zajęć na odległość: 0.0						
Aktywność studenta i liczba godzin pracy	Aktywność studenta	Udział w zajęciach dydaktycznych, objętych planem studiów		Udział w konsultacjach		Praca własna studenta	RAZEM
	Liczba godzin pracy studenta	45		5.0		75.0	125
Cel przedmiotu	Celem przedmiotu jest zapoznanie studentów z matematycznymi podstawami i metodami stosowanymi w inżynierii danych.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu			Sposób weryfikacji i oceny efektu	
	[K6_U01] stosuje wiedzę z matematyki, fizyki, chemii, narzędzi informatycznych i innych dyscyplin inżynierskich do rozwiązywania problemów teoretycznych, inżynierskich oraz technologicznych		Student potrafi wykorzystać narzędzia informatyczne i programistyczne do implementacji algorytmów takich jak algorytm najbliższych sąsiadów, drzewa decyzyjne, sieci neuronowe, algorytm k-średnich i algorytm a priori.			[SU1] Ocena realizacji zadania	
	[K6_W01] wykazuje się znajomością i zrozumieniem matematyki, fizyki, chemii oraz narzędzi informatycznych na poziomie niezbędnym do formułowania i rozwiązywania typowych problemów inżynierskich oraz technologicznych		Student wykazuje się znajomością podstawowych metod matematycznych używanych w analizie i eksploracji danych, takich jak regresja wielokrotna, analiza korelacji, czy metody normalizacji i standaryzacji.			[SW1] Ocena wiedzy faktograficznej	
	[K6_K01] jest świadoma potrzeby stałego aktualizowania i wzbogacania posiadanej wiedzy i umiejętności praktycznych, podnoszenia kompetencji zawodowych, osobistych i społecznych		Student jest świadomy potrzeby stałego aktualizowania wiedzy w szybko rozwijającej się dziedzinie inżynierii danych. Student angażuje się w samodzielne poszukiwanie nowych informacji, uczestnictwo w kursach i szkoleniach oraz śledzenie najnowszych trendów i osiągnięć w dziedzinie analizy danych i uczenia maszynowego.			[SK2] Ocena postępów pracy	

Treści przedmiotu	1. Podstawowe zadania używane w eksploracji danych: identyfikacja i definiowanie problemu; przygotowanie danych: zbieranie, czyszczenie, obróbka; analiza wstępna danych. 2. Obróbka danych: normalizacja; standaryzacja; dyskretyzacja zmiennych ciągłych 3. Zmienne jakościowe i numeryczne: rodzaje zmiennych; przekształcanie zmiennych jakościowych na numeryczne. 4. Relacje wielowymiarowe: analiza współzmienności; wykorzystanie macierzy korelacji. 5. Wnioskowanie statystyczne: hipotezy statystyczne; testy statystyczne; przedziały ufności. 6. Regresja wielokrotna: modele liniowe; szacowanie parametrów; ocena i interpretacja modelu 7. Algorytm najbliższych sąsiadów: metody klasyfikacji, wybór liczby sąsiadów. 8. Funkcje decyzyjne i drzewa klasyfikacyjne: budowa drzew decyzyjnych; pruning i walidacja 9. Porównanie różnych algorytmów: metryki oceny algorytmów; cross-validation. 10. Wykorzystanie sieci neuronowych: podstawy sieci neuronowych; sigmoidalna funkcja aktywacji; reguły propagacji wstecznej. 11. Metody grupowania hierarchicznego: algorytmy aglomeracyjne i dzielące; miary odległości. 12. Algorytm k-średnich: klasteryzacja danych; wybór liczby klastrów. 13. Algorytm a priori i reguły asocjacyjne: wykrywanie wzorców w danych, generowanie reguł asocjacyjnych.											
Wymagania wstępne i dodatkowe	Znajomość podstaw matematyki (algebra liniowa, rachunek różniczkowy) Znajomość podstaw matematyki (algebra liniowa, rachunek różniczkowy).											
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table><tr><th>Sposób oceniania (składowe)</th><th>Próg zaliczeniowy</th><th>Składowa oceny końcowej</th></tr><tr><td>ćwiczenia</td><td>50.0%</td><td>50.0%</td></tr><tr><td>wykład</td><td>50.0%</td><td>50.0%</td></tr></table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	ćwiczenia	50.0%	50.0%	wykład	50.0%	50.0%		
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej										
ćwiczenia	50.0%	50.0%										
wykład	50.0%	50.0%										
Zalecana lista lektur	<table><tr><td>Podstawowa lista lektur</td><td> [1] Daniel T. Larose, Okrywanie wiedzy z danych, PWN 2006 [2] Daniel T. Larose, Metody i modele eksploracji danych, PWN 2016 </td></tr><tr><td>Uzupełniająca lista lektur</td><td>[3] Tadeusz Morzy, Eksploracja danych. Metody i algorytmy, PWN 2013</td></tr><tr><td>Adresy eZasobów</td><td>Adresy na platformie eNauczanie:</td></tr></table>	Podstawowa lista lektur	[1] Daniel T. Larose, Okrywanie wiedzy z danych, PWN 2006 [2] Daniel T. Larose, Metody i modele eksploracji danych, PWN 2016	Uzupełniająca lista lektur	[3] Tadeusz Morzy, Eksploracja danych. Metody i algorytmy, PWN 2013	Adresy eZasobów	Adresy na platformie eNauczanie:					
Podstawowa lista lektur	[1] Daniel T. Larose, Okrywanie wiedzy z danych, PWN 2006 [2] Daniel T. Larose, Metody i modele eksploracji danych, PWN 2016											
Uzupełniająca lista lektur	[3] Tadeusz Morzy, Eksploracja danych. Metody i algorytmy, PWN 2013											
Adresy eZasobów	Adresy na platformie eNauczanie:											

Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	1. Przykładowe zagadnienia: Jakie są różnice między normalizacją a standaryzacją danych? Jakie są zalety i wady algorytmu k-średnich? 2. Przykładowe pytania: Wyjaśnij, jak działa algorytm najbliższych sąsiadów. Opisz proces budowy drzewa decyzyjnego. 3. Realizowane zadania: Implementacja i analiza regresji wielokrotnej na rzeczywistym zbiorze danych. Przeprowadzenie analizy klastryzacji za pomocą algorytmu k-średnich. Projektowanie i trenowanie prostych sieci neuronowych do klasyfikacji.
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.