



Karta przedmiotu

Nazwa i kod przedmiotu	Business Data Analytics, PG_00053096						
Kierunek studiów	Inżynieria danych						
Data rozpoczęcia studiów	październik 2025 r.		Rok akademicki realizacji przedmiotu		2027/2028		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć		Grupa zajęć fakultatywnych Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	3		Język wykładowy		angielski		
Semestr studiów	5		Liczba punktów ECTS		4.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Zarządzania i Ekonomii -> Katedra Informatyki w Zarządzaniu						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr Nina Rizun				
	Prowadzący zajęcia z przedmiotu		dr Nina Rizun mgr Jaromir Durkiewicz				
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	15.0	0.0	30.0	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		50.0	100
Cel przedmiotu	Celem przedmiotu jest zapoznanie studentów z podstawowymi algorytmami eksploracji danych w kontekście odkrywania wiedzy z nieustrukturyzowanych danych organizacji gospodarczych						

Efekty uczenia się przedmiotu	Efekt kierunkowy	Efekt z przedmiotu	Sposób weryfikacji i oceny efektu
	[K6_K03] wykazuje się zdolnością do krytycznego i analitycznego myślenia oraz integruje wiedzę z wielu dyscyplin w celu podejmowania efektywnych decyzji	Student wykazuje się zdolnością do krytycznej interpretacji wyników analiz danych, integruje wiedzę z zakresu analityki danych, ekonomii oraz zarządzania i wykorzystuje ją do formułowania wniosków oraz wspierania procesu podejmowania decyzji biznesowych.	[SK2] Ocena postępów pracy [SK4] Ocena umiejętności komunikacji, w tym poprawności językowej [SK3] Ocena umiejętności organizacji pracy
	[K6_W03] identyfikuje wiarygodne źródła informacji istotne dla analizowanych zagadnień	Student identyfikuje, pozyskuje oraz krytycznie ocenia dane pochodzące z różnych źródeł (np. bazy danych, raporty biznesowe, otwarte zbiory danych), a następnie wykorzystuje je do analizy i interpretacji problemów biznesowych z zastosowaniem podstawowych narzędzi analityki danych.	[SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym [SW2] Ocena wiedzy zawartej w prezentacji
	[K6_U06] zdobywa nową wiedzę, planując własny rozwój sprzyjający osiąganiu wyznaczonych celów	Student samodzielnie poszerza wiedzę i kompetencje w zakresie analityki danych, wyszukując specjalistyczne materiały, dokumentację narzędzi analitycznych oraz przykłady zastosowań biznesowych, a następnie wykorzystuje je do planowania własnego rozwoju w obszarze analizy danych i podejmowania decyzji opartych na danych.	[SU2] Ocena umiejętności analizy informacji [SU1] Ocena realizacji zadania [SU3] Ocena umiejętności wykorzystania wiedzy uzyskanej w ramach przedmiotu [SU4] Ocena umiejętności korzystania z metod i narzędzi [SU5] Ocena umiejętności zaprezentowania wyników realizacji zadania
Treści przedmiotu	Treści przedmiotu - wykład 1. Czym jest Business Data Analytics? CRISP-DM. Przygotowanie danych. Metody eksploracji danych 2. Czym jest Text Analytics (BTA)? Text Analytics & NLP. Zadania Text Analytics. Miary oceny wyszukiwania. Wyszukiwanie w oparciu o słowa kluczowe. Wyszukiwanie w oparciu o reprezentację wektorową. Techniki wstępnego przetwarzania dokumentów tekstowych. Prawo Zipfa 3. Korpus. Własności reprezentacji wektorowej. Wyznaczanie macierzy częstości (Obliczanie wag). Reprezentacja binarna. Odwrotna częstość słowa (inverse-document frequency, IDF). Schemat wagowy TFIDF. Wektorowa reprezentacja dokumentu. Pomiar odległości/podobieństwa. Metody obliczania odległości. Metody obliczania podobieństwa. Analiza skupień grupowanie. Metody hierarchiczne aglomeracyjne. Przykład Metody hierarchicznej. Metody k-optymalizacyjne. 4. Podobieństwo Kosinusowe. Odległość Euklidesowa vs. Podobieństwo Kosinusowe. Macierz sąsiedztwa i wizualizacja. Podobieństwa za pomocą grafów. Macierz sąsiedztwa. Stopień wężła grafu. Struktura społeczności sieci. 5. Skalowanie wielowymiarowe (MDS): Motywacja. Cele. Formalny model. Stress (Goodness-of-fit). Analiza ukrytych grup semantycznych (LSA): Motywacja. Model wektorowy: Ograniczenia. Rozkład według wartości osobliwych (Singular Value Decomposition). LSA zmniejszenie wymiaru. Podobieństwo dokumentów. Podobieństwo wyrazów. Automatyczne modelowanie tematyki danych tekstowych. Latent Dirichlet Allocation (LDA). 6. Wprowadzenie do Sentiment Analysis 7. Structural Topic Modeling. 8. SNA - wprowadzenie. Historia teorii analizy sieci społecznej. Teoria małego świata. Eksperyment Milgrama. Relacje jako sieć. Graf skierowany. Graf nieskierowany. Atrybuty krawędzi. Gęstość grafu. Osiągalność i odległość. Miary centralności Treści przedmiotu - laboratoria • Podstawowa analiza tekstu w R • Transformacja TF-IDF • Analiza skupień (cluster analysis) w R • Podobieństwo cosinusowe (cosine similarity) • Grafy sieciowe w R • Modelowanie tematów (Topic Modeling) • Wielowymiarowe skalowanie (Multidimensional Scaling, MDS) oraz analiza semantyczna LSA (Latent Semantic Analysis) • Analiza opinii i analiza sentymentu (Opinion Mining and Sentiment Analysis) • Strukturalne modelowanie tematów (Structural Topic Modeling) • Analiza sieci społecznych (Social Network Analysis) • Podstawowe miary sieci (Basic Network Measures)		
Wymagania wstępne i dodatkowe			

Sposoby i kryteria oceniania osiąganych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	Projekt	60.0%	40.0%
	Ćwiczenia na zajęciach	60.0%	20.0%
	Kolokwium końcowe	60.0%	40.0%
Zalecana lista lektur	Podstawowa lista lektur	1. Provost, Foster, Fawcett, Tom. Data Science for Business: What you need to know about data mining and data-analytic thinking. " O'Reilly Media, Inc.", 2019 2. Sharda, R., Delen, D., & Turban, E. Business intelligence: a managerial perspective on analytics. Pearson. 2018 3. Siegel, E. Predictive analytics: The power to predict who will click, buy, lie, or die. John Wiley & Sons, 2016. 338 pp. 4. James, G., Witten, D., Hastie, T., Tibshirani, R. An introduction to statistical learning with applications in R. Springer, 2018.	
	Uzupełniająca lista lektur	1. Han, J., Kamber, M., Pei, J. Data mining concepts and techniques. Morgan Kaufmann, 2021. 2. Hastie, T., Tibshirani, R., Friedman, J. The Elements of Statistical Learning, 2nd edition. Springer, 2022. 3. James, G. et al. An introduction to statistical learning. Springer, 2013. 426 pp. 4. Murphy, K. Machine Learning: A Probabilistic Perspective. MIT Press, 2019	
	Adresy eZasobów		
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Wybierz główne właściwości odległości euklidesowej Wybierz odpowiednią wartość miary podobieństwa cosinusa między dokumentem 1 a dokumentem 2 Algorytm K-średnich pozwala ... Jaka jest różnica między odległością euklidesową a miarą podobieństwa cosinusów? Osoba o wysokiej centralności wektora własnego to ... Proszę obliczyć IDF dla warunków z następującego Korpusu Zbuduj wykres prawa Zipfa dla następującego Corpusu Podaj ogólną charakterystykę aktorów następującej sieci społecznościowej		
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy		

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.