

Categorical data analysis
Karta opisu przedmiotu (sylabus)

Informacje podstawowe

Kierunek studiów Informatyka i analityka danych Specjalność - Jednostka organizacyjna UEP Poziom kształcenia studia pierwszego stopnia (licencjackie) Forma studiów stacjonarne Profil kształcenia ogólnoakademicki		Cykl dydaktyczny 2025/2026 Kod przedmiotu UEPIADS.120C.12911.25 Język wykładowy Angielski Obligatoryjność Do wyboru Blok zajęciowy Blok C		
Osoba odpowiedzialna za treść sylabusa		Maciej Beręsewicz		
Okres Semestr 6		Forma zaliczenia Zaliczenie Forma prowadzenia i godziny zajęć • Uczestnictwo w wykładach: 30		Liczba punktów ECTS 3

Cele uczenia się dla przedmiotu

C1	Poznanie metod analizy danych jakościowych
C2	Poznanie modeli dla danych jakościowych
C3	Poznanie możliwości języków programowania i pakietów statystycznych w zakresie analizy danych jakościowych

Cele kształcenia UEP

Kod	Treść celu
CS1_1.1	student rozumie strukturę i elementy problemu gospodarczego

Kod	Treść celu
CS1_1.2	student właściwie wykorzystuje techniki, metody i modele analityczne
CS1_2.1	student rozumie i stosuje zasady pracy grupowej
CS1_2.2	student skutecznie komunikuje się w formie ustnej i pisemnej
CS1_3.1	student rozumie i docenia zasady zrównoważonego rozwoju i ich zastosowanie w biznesie
CS1_3.2	student stosuje etyczne standardy akademickie i biznesowe, uwzględniając aspekty środowiskowe i społeczne

Wymagania wstępne

znajomość statystyki, podstawowa znajomość pakietu statystycznego R, podstawowa znajomość ekonometrii

Efekty uczenia się dla przedmiotu

Kod	Efekty w zakresie	Kierunkowe efekty uczenia się	Metody weryfikacji
Wiedzy			
W1	Student zna słabe skale pomiarowe (nominalna, porządkowa)	K1_W01, K1_W03, K1_W06	Quiz na platformie moodle
W2	Student zna modele dla danych jakościowych i zawierających skale mieszane (np. porządkowe i ilorazowe)	K1_W01, K1_W03	Quiz na platformie moodle
W3	Student wie, jak przeprowadzić analizę danych jakościowych i zawierających skale mieszane	K1_W03, K1_W04	Quiz na platformie moodle
W4	Student wie, jak interpretować wyniki analiz danych jakościowych i ilościowych	K1_W01, K1_W03, K1_W04	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle
W5	Student zna narzędzia informatyczne umożliwiające analizę danych jakościowych	K1_W04, K1_W05	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle
W6	Student wie, jakie są główne modele uczenia maszynowego/sztucznej inteligencji do klasyfikacji danych jakościowych	K1_W03, K1_W06	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle
Umiejętności			
U1	Student wie, jak zidentyfikować słabe skale pomiarowe	K1_U01, K1_U02, K1_U03, K1_U06	Udział w dyskusji / Uczestnictwo w zajęciach
U2	Student wie, które metody analizy danych jakościowych należy zastosować w określonych przypadkach	K1_U01, K1_U02, K1_U03, K1_U05, K1_U06	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle
U3	Student zna możliwości i ograniczenia języków programowania i pakietów statystycznych na potrzeby analiz danych jakościowych	K1_U01, K1_U02, K1_U03, K1_U05, K1_U06	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle

Kod	Efekty w zakresie	Kierunkowe efekty uczenia się	Metody weryfikacji
U4	Student wie, jak wykorzystać wielkie modele językowe (np. ChatGPT, Claude) do wspomagania analiz danych jakościowych	K1_U01, K1_U04, K1_U05, K1_U06	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle
Kompetencje społecznych			
K1	Student jest gotów do pogłębiania wiedzy z zakresu analizy danych jakościowych	K1_K01, K1_K02	Udział w dyskusji / Uczestnictwo w zajęciach
K2	Student jest świadomy przydatności analizy danych jakościowych	K1_K01, K1_K02	Udział w dyskusji / Uczestnictwo w zajęciach
K3	Student jest świadomy przydatności wielkich modeli językowych do wspomagania analizy danych jakościowych	K1_K03, K1_K04, K1_K05	Udział w dyskusji / Uczestnictwo w zajęciach

Treści programowe

Lp.	Treści programowe	Cele kształcenia dla przedmiotu	Efekty uczenia się dla przedmiotu
1.	Wprowadzenie do analizy danych jakościowych: słabe skale pomiarowe, zmienne jakościowe, tablice kontyngencji	C1	W1, U1, K1, K2
2.	Rozkłady zmiennych losowych dyskretnych: Bernoullego, Poissona, wielomianowe i inne	C1, C2	W1, W2, U1, U2, U3, U4, K1, K2, K3
3.	Zmienne jakościowe w modelach regresji liniowej	C1, C2, C3	W1, W2, W3, W4, W5, U1, U2, U3, U4, K3
4.	Modele regresji logistycznej (dwumianowe, wielomianowe)	C1, C2, C3	W1, W2, W3, W4, W5, W6, U1, U2, U3, U4, K1, K2, K3
5.	Modele dla zmiennych wyliczeniowych (np. Poissona)	C1, C2, C3	W1, W2, W3, W4, W5, U1, U2, U3, U4, K1, K2, K3
6.	Podstawowe modele uczenia maszynowego: drzewa klasyfikacyjne i regresyjne, lasy losowe	C1, C2, C3	W1, W2, W3, W4, W5, W6, U1, U2, U3, U4, K1, K2, K3

Literatura

Obowiązkowa

1. Agresti, A. (2013). Categorical data analysis, 3rd Edition, Wiley.
2. Bilder, C. R., & Loughin, T. M. (2014). Analysis of categorical data with R. CRC Press.
3. Brzezińska Justyna, 2015, Analiza logarytmiczno-liniowa. Teoria i zastosowania z wykorzystaniem programu R
4. Gatnar Eugeniusz, Walesiak Marek, 2011, Analiza danych jakościowych i symbolicznych z wykorzystaniem programu R
5. Friendly, M., & Meyer, D. (2015). Discrete Data Analysis with R: Visualization and Modeling Techniques for Categorical and Count Data (Vol. 120). CRC Press
6. James, G., Witten, D., Hastie, T. & Tibshirani, R (2023). An Introduction to Statistical Learning with applications in R. Springer.

Zalecana

1. Faraway, J. J. (2016). Extending the linear model with R: generalized linear, mixed effects and nonparametric regression models (Vol. 124). CRC press
2. Kateri, M. (2014). Contingency Table Analysis. Springer New York
3. Gagolewski, M., Deep R Programming, Melbourne, v1.0.0 edition, 2023, 456 pp., [DOI:10.5281/zenodo.7490464](https://doi.org/10.5281/zenodo.7490464), URL:<https://deepr.gagolewski.com/>
4. Gagolewski, M., Minimalist Data Wrangling with Python, Melbourne, v1.0.3 edition, 2023, 442 pp., [DOI:10.5281/zenodo.6451068](https://doi.org/10.5281/zenodo.6451068), URL:<https://datawranglingpy.gagolewski.com/>
5. Biecek, P., & Burzykowski, T. (2021). Explanatory model analysis: explore, explain, and examine predictive models. Chapman and Hall/CRC.

Informacje rozszerzone

Metody nauczania:

Burza mózgow, Wykład konwersatoryjny, Wykład z prezentacją multimedialną, Analiza przypadków, Rozwiązywanie zadań, Ćwiczenia laboratoryjne, Metody e-learningowe, praca z komputerem

Metody nauczania	Sposób zaliczenia	Warunki zaliczenia przedmiotu
Wykład	Udział w dyskusji / Uczestnictwo w zajęciach, Quiz na platformie moodle	Warunki zaliczenia przedmiotu są podawane do wiadomości studentów przez prowadzącego na pierwszych zajęciach.

Rozliczenie punktów ECTS

Forma aktywności studenta	Średnia liczba godzin* przeznaczonych na zrealizowane aktywności	
Uczestnictwo w wykładach	30	
Konsultacje z prowadzącym/i zajęcia	10	
Przygotowanie do sprawdzianu/ kolokwium	40	
Łączny nakład pracy studenta	Liczba godzin 80	ECTS 3.0
Zajęcia z bezpośrednim udziałem nauczyciela	Liczba godzin 40	ECTS 1.5

* godzina (lekcyjna) oznacza 45 minut

Kierunkowe efekty uczenia się

Kod	Treść
K1_K01	absolwent jest gotów do obiektywnej, krytycznej oceny swojej wiedzy i umiejętności
K1_K02	absolwent jest gotów do myślenia i działania w sposób przedsiębiorczy
K1_K03	absolwent jest gotów do uczestnictwa w rozwiązywaniu współczesnych problemów z zakresu zrównoważonego rozwoju wynikających z masowego zastosowania nowych technologii, w szczególności do dbania o środowisko naturalne i etykę biznesową
K1_K04	absolwent rozumie społeczne, prawne i etyczne aspekty pracy z danymi, w tym związane z ochroną prywatności i bezpieczeństwem informacji
K1_K05	absolwent jest gotów do kierowania się uczciwością intelektualną w działaniach własnych i wymagania jej od innych osób, jest wyczulony na kwestie plagiatu, auto-plagiatu i wykorzystania sztucznej inteligencji z poszanowaniem zasad etyki
K1_U01	absolwent potrafi poprawnie dobrać i efektywnie wykorzystywać metody i narzędzia ilościowe i informatyczne do opisu i analizy zjawisk społeczno-gospodarczych
K1_U02	absolwent potrafi właściwie dobierać źródła informacji, dokonywać ich oceny oraz przeprowadzać krytyczną analizę i syntezę danych z różnych źródeł, w celu wyciągania trafnych wniosków i podejmowania optymalnych decyzji w warunkach nie w pełni przewidywalnych
K1_U03	absolwent potrafi w sposób precyzyjny i spójny wyrażać myśli i poglądy, zaprezentować wyniki swojej pracy oraz brać udział w debacie z poszanowaniem opinii i stanowisk innych osób
K1_U04	absolwent potrafi posługiwać się językiem obcym w zakresie nauk społeczno-gospodarczych zgodnie z wymogami określonymi dla poziomu B2 Europejskiego Systemu Opisu Kształcenia Językowego
K1_U05	absolwent potrafi planować i organizować pracę indywidualną oraz zespołową zorientowaną na rozwiązywanie specjalistycznych problemów
K1_U06	absolwent jest gotów do systematycznego podnoszenia swoich kompetencji poprzez ciągłe samokształcenie w oparciu o zaawansowaną literaturę specjalistyczną
K1_W01	absolwent zna w zaawansowanym stopniu szeroki wachlarz metod ilościowych oraz narzędzi informatycznych stosowanych w analizach zjawisk społeczno-gospodarczych
K1_W03	absolwent zna i rozumie najnowsze trendy rozwojowe i osiągnięcia z zakresu informatyki i analizy danych
K1_W04	absolwent zna i rozumie podstawy prawa, ochrony własności i prawa autorskiego, a także prawa i etyki w zakresie stosowania nowoczesnych technologii informacyjnych z uwzględnieniem wykorzystania sztucznej inteligencji
K1_W05	absolwent zna i rozumie zasady tworzenia i rozwoju różnych form przedsiębiorczości, w szczególności opartych na wykorzystaniu nowoczesnych technologii informacyjno-komunikacyjnych
K1_W06	absolwent zna i rozumie dylematy związane z transformacją cyfrową oraz potrzebą uwzględnienia zasad zrównoważonego rozwoju w działalności gospodarczej

Ten utwór jest dostępny na licencji Creative Commons Uznanie autorstwa 4.0 Międzynarodowa (CC BY 4.0). Autor: Maciej Beręsewicz