



**POLITECHNIKA
BYDGOSKA**

Wydział Telekomunikacji,
Informatyki i Elektrotechniki

Karta przedmiotu
Zaawansowane metody statystycznej analizy danych

1. Informacje podstawowe

Kierunek studiów informatyka stosowana Jednostka zarządzająca kierunkiem studiów Wydział Telekomunikacji, Informatyki i Elektrotechniki Poziom studiów drugiego stopnia (mgr inż.) Profil studiów Profil ogólnoakademicki Forma studiów studia stacjonarne		Cykl kształcenia (nabór) 2025/26 Kod przedmiotu 05ISTS.DI1.3966.25 Języki wykładowe polski Obligatoryjność Obowiązkowy Blok zajęciowy Przedmioty podstawowe	
Wymagania wstępne	brak		
Przedmioty wprowadzające	brak		
Koordinator	Tomasz Marciniak		
Okres Semestr 1	Forma zaliczenia Egzamin Forma prowadzenia i godziny zajęć Wykład: 15 Ćwiczenia laboratoryjne: 30		Liczba punktów ECTS 3.0

2. Efekty uczenia się dla przedmiotu

Kod	Opis efektów uczenia się	Odniesienie do kierunkowych efektów uczenia się	Odniesienie do charakterystyk PRK
Wiedza:			
W1	Student zna zaawansowane modele statystyczne i ich zastosowania	IST_O2_K_W01	P7S_WG_inż P7S_WG
W2	Rozumie testowanie hipotez i ocenę efektywności modeli	IST_O2_K_W06, IST_O2_K_W15	P7S_WG_inż, P7S_WG, P7S_WG P7S_WG_inż
W3	Zna metody ewaluacji algorytmów optymalizacyjnych	IST_O2_K_W02, IST_O2_K_W14, IST_O2_K_W15	P7S_WG_inż, P7S_WG, P7S_WG, P7S_WG_inż, P7S_WG P7S_WG_inż
Umiejętności:			
U1	Dobiera i implementuje metody analizy do problemu badawczego	IST_O2_K_U07	P7S_UW P7S_UW_inż
U2	Porównuje modele przy użyciu testów statystycznych i metryk	IST_O2_K_U10	P7S_UW P7S_UW_inż
U3	Tworzy raporty zgodne z zasadami reprodukowalności	IST_O2_K_U02, IST_O2_K_U16	P7S_UW_inż, P7S_UW, P7S_UW P7S_UW_inż
Kompetencje społeczne:			
K1	Pracuje zespołowo w projektach analizy danych	IST_O2_K_K02, IST_O2_K_K03	P7S_KO, P7S_KO
K2	Wykazuje odpowiedzialność za jakość i wpływ analiz	IST_O2_K_K05	P7S_KR
K3	Rozumie potrzebę ustawicznego doskonalenia się w zakresie statystycznej analizy danych	IST_O2_K_K01	P7S_KK

3. Treści programowe

Lp.	Treści programowe	Formy zajęć	Efekty uczenia się dla przedmiotu
1.	Tematy wykładów: Wprowadzenie do zaawansowanej analizy danych, typy danych i pytania badawcze Regresja wieloraka i modele liniowe Modele nieliniowe i GLM Modele mieszane: dane wielopoziomowe Redukcja wymiaru: PCA, LDA, CCA Regularyzacja: Lasso, Ridge, Elastic Net Testy statystyczne: t-Studenta, ANOVA, Wilcoxon, Friedman, FDR Wnioskowanie bayesowskie i MCMC Klasteryzacja i modele mieszaninowe Analizy anomalii: metody statystyczne i ML Bootstrap, jackknife, testy permutacyjne Walidacja modeli: CV, AIC, BIC, stabilność modeli Analiza szeregów czasowych i testy Dickeya-Fullera Ewaluacja algorytmów optymalizacyjnych: hypervolume, IGD, testy statystyczne Raportowanie i reproducibility, open science	Wykład	W1, W2, W3

Lp.	Treści programowe	Formy zajęć	Efekty uczenia się dla przedmiotu
2.	Tematy ćwiczeń laboratoryjnych: Praca w Pythonie: pandas, statsmodels, scikit-learn Implementacja regresji wielorakiej i diagnostyka Regresja logistyczna: ocena i walidacja Modele mieszane na danych powtarzanych PCA i wizualizacja danych Regularyzacja: analiza parametrów i interpretacja Testy statystyczne: t, ANOVA, Wilcoxon, Friedman Wnioskowanie bayesowskie: symulacje MCMC Klasteryzacja: miary jakości klastrów Wykrywanie anomalii i testy odległości Bootstrap i jackknife: niepewność estymatorów Cross-validation, tuning modeli, AIC/BIC ARIMA, testy stacjonarności Porównywanie algorytmów optymalizacyjnych: benchmarki, hypervolume, IGD	Ćwiczenia laboratoryjne	W1, W2, W3, U1, U2, U3, K1, K2, K3

4. Metody prowadzenia zajęć, weryfikacji efektów uczenia się i warunki zaliczenia

Forma zajęć		
Wykład	Metody prowadzenia zajęć:	
	Wykład	
	Metody (sposoby) weryfikacji:	Udział:
	Egzamin pisemny	100%
	Warunki zaliczenia przedmiotu:	
	Egzamin pisemny - ocena dostateczna od 51% punktów	
Ćwiczenia laboratoryjne	Metody prowadzenia zajęć:	
	Ćwiczenia laboratoryjne	
	Metody (sposoby) weryfikacji:	Udział:
	Sprawozdanie	100%
	Warunki zaliczenia przedmiotu:	
	Odaanie wszystkich sprawozdań i uzyskanie ocen min. dostatecznych z każdego, ocena końcowa to średnia arytmetyczna ocen z poszczególnych sprawozdań	

Efekt uczenia się dla przedmiotu	Metody (sposoby) weryfikacji	
	Egzamin pisemny	Sprawozdanie
W1	x	x
W2	x	x
W3	x	x
U1		x
U2		x

U3		x
K1		x
K2		x
K3		x

5. Literatura

Literatura podstawowa

1. James, G., Witten, D., Hastie, T., Tibshirani, R. (2023). Wprowadzenie do uczenia maszynowego z wykorzystaniem R (tłum.). Warszawa: Wydawnictwo Naukowe PWN
2. Hyndman, R. J., Athanasopoulos, G. (2022). Prognozowanie i analiza szeregów czasowych z wykorzystaniem R(tłum.). Warszawa: Wydawnictwo Naukowe PWN
3. Zieliński, R. (2021). Statystyka dla data scientistów z wykorzystaniem Pythona i R. Warszawa: PWN

Literatura uzupełniająca

1. Stanisław, A. (2021). Przystępny kurs statystyki z zastosowaniem STATISTICA i R. Tom 2: Modele liniowe i nieliniowe. Kraków: Wydawnictwo StatSoft Polska
2. Kelleher, J. D. (2021). Data Science: A Concise Introduction. MIT Press
3. McElreath, R. (2020). Statistical Rethinking: A Bayesian Course with Examples in R and Stan (2nd ed.). CRC Press

6. Nakład pracy studenta - bilans godzin i punktów ECTS

Aktywność studenta		Obciążenie studenta Liczba godzin
Zajęcia prowadzone z bezpośrednim udziałem nauczyciela akademickiego lub innych osób prowadzących zajęcia	Wykład	15
	Ćwiczenia laboratoryjne	30
Praca własna studenta	Konsultacje	2
	Przygotowanie do zajęć	20
	Przygotowanie do egzaminu	10
	Przygotowanie sprawozdania	13
Łączny nakład pracy studenta		90
Liczba punktów ECTS		3

* Godzina (dydaktyczna) oznacza 45 minut