

KARTA PRZEDMIOTU (SYLABUS)

Opis przedmiotu

Kod przedmiotu		Nazwa przedmiotu	Prognozowanie z wykorzystaniem AI	
AIWB/O/II/NST/B2-30a			Forecasting with AI	
Język wykładowy		Polski		
Rok akademicki		2026/2027		
Kierunek		Sztuczna Inteligencja w Biznesie		
w zakresie		-		
Poziom studiów		studia drugiego stopnia		
Profil studiów		ogólnoakademicki		
Forma studiów		studia niestacjonarne		
Semestr / semestry		semestr trzeci		
Przynależność do grupy zajęć		B. Grupa zajęć kierunkowych B2. Grupa zajęć kierunkowych wybieralnych		
Status przedmiotu		Wybieralny		
Formy realizacji zajęć dydaktycznych, wymiar, punkty ECTS		Forma zajęć	Liczba godzin zajęć dydaktycznych	Liczba punktów ECTS
		Wykład	8 [h]	3 ECTS
		Ćwiczenia	[h]	
		Konwersatorium	[h]	
		Laboratorium	15 [h]	
Powiązanie przedmiotu	z profilem studiów	Związany z prowadzoną działalnością naukową w dyscyplinie informatyka techniczna i telekomunikacja		2 ECTS
	z uprawnieniami			ECTS
	z dyscypliną	Informatyka techniczna i telekomunikacja		3 ECTS
Forma nauczania		tradycyjna- zajęcia zorganizowane w Uczelni / zajęcia realizowane z wykorzystaniem metod i technik kształcenia na odległość		
Wymagania wstępne		Znajomość podstawowej obsługi komputera niezbędna dla wykonania ćwiczeń laboratoryjnych.		
Jednostka prowadząca		Katedra Biznesu i Finansów Międzynarodowych		
Koordynator		Dr inż. Jacek Wołoszyn		
Adres strony internetowej pjo		http://weif.uniwersytetradom.pl		
Adres e-mail, telefon koordynatora		Jacek.woloszyn@urad.edu.pl (48) 361-7410		

EFEKTY UCZENIA SIĘ, TREŚCI PROGRAMOWE, REALIZACJA ZAJĘĆ DYDAKTYCZNYCH, WERYFIKACJA EFEKTÓW UCZENIA SIĘ

Cel kształcenia:	Celem przedmiotu jest zapoznanie z metodami prognozowania opartymi na technikach sztucznej inteligencji oraz rozwinięcie umiejętności budowy i oceny modeli predykcyjnych wykorzystywanych do analizy danych i przewidywania przyszłych zdarzeń w różnych obszarach zastosowań.
Treści programowe:	<p>Treści zajęć są powiązane z prowadzonymi badaniami naukowymi.</p> <p>Treści wykładów:</p> <p>Wprowadzenie do problematyki prognozowania oraz roli sztucznej inteligencji w analizie danych predykcyjnych. Rodzaje danych wykorzystywanych w prognozowaniu, w szczególności szeregi czasowe. Metody przygotowania i wstępnej analizy danych do budowy modeli prognostycznych. Klasyczne metody prognozowania oraz ich ograniczenia. Zastosowanie metod uczenia maszynowego w zadaniach predykcyjnych. Modele regresyjne i ich zastosowanie w prognozowaniu. Metody oparte na sieciach neuronowych w prognozowaniu danych. Wykorzystanie modeli sekwencyjnych w analizie szeregów czasowych. Ocena jakości modeli prognostycznych oraz metody walidacji. Przegląd praktycznych zastosowań prognozowania z wykorzystaniem sztucznej inteligencji w gospodarce, finansach i przemyśle.</p> <p>Suma: 8 [h]</p> <p>Treść laboratoriów:</p> <p>Zapoznanie ze środowiskiem programistycznym wykorzystywanym do analizy danych i budowy modeli prognostycznych. Przygotowanie i eksploracyjna analiza danych wykorzystywanych w prognozowaniu. Implementacja podstawowych modeli regresyjnych do predykcji wartości zmiennych. Budowa i testowanie modeli uczenia maszynowego w zadaniach prognozowania. Analiza i modelowanie szeregów czasowych. Implementacja wybranych modeli sieci neuronowych w zadaniach prognozowania. Porównywanie skuteczności różnych metod prognozowania. Ocena jakości prognoz z wykorzystaniem wybranych miar błędów. Interpretacja wyników modeli predykcyjnych. Realizacja projektu polegającego na opracowaniu modelu prognozowania dla wybranego zbioru danych.</p> <p>Suma: 15 [h]</p>
Metody dydaktyczne (kształcenia):	<ul style="list-style-type: none"> - metody podające (wykład informacyjny), - metody programowane (z wykorzystaniem komputera), - Obserwacja
	<p>Warunkiem zaliczenia przedmiotu jest osiągnięcie wszystkich wymaganych efektów uczenia się określonych dla przedmiotu. Uzyskanie pozytywnych ocen ze wszystkich form zajęć wchodzących w skład danego przedmiotu jest równoznaczne z jego zaliczeniem i zdobyciem przez studenta liczby punktów ECTS przyporządkowanej temu przedmiotowi. Sposób obliczenia oceny końcowej z przedmiotu określony został zarządzeniem Rektora URad.</p> <p>Sposób obliczania oceny z poszczególnych form zajęć przedstawia się następująco:</p> <p>Ocena z laboratorium: test lub projekt</p> <p>Na ocenę z wykładu składa się wynik otwartego testu pisemnego.</p>

Efekty uczenia się dla przedmiotu w odniesieniu do efektów kierunkowych i formy zajęć				Metody weryfikacji efektów uczenia się	
Numer efektu	Opis efektów uczenia się dla przedmiotu (PEU) Student, który zaliczył przedmiot	Kierunkowy efekt	Forma zajęć	Forma weryfikacji (zaliczeń)	Metody sprawdzania i oceny

uczenia się	(W) zna i rozumie/ (U) potrafi /(K) jest gotów do:	uczenia się (KEU)			
W1	Zna i rozumie w pogłębionym stopniu metody prognozowania oraz modele sztucznej inteligencji stosowane w analizie danych i predykcji przyszłych zdarzeń.	K_W08 K_W09 K_W10	wykład	Zaliczenie na ocenę	pisemny test otwarty
W2	Zna i rozumie w pogłębionym stopniu metody oceny jakości modeli prognostycznych oraz zasady ich stosowania w analizie danych.	K_W08 K_W09 K_W10	wykład	Zaliczenie na ocenę	pisemny test otwarty
U1	Potrafi przygotować dane oraz budować modele prognostyczne z wykorzystaniem metod uczenia maszynowego i sztucznej inteligencji.	K_U02 K_U03 K_U09	laboratorium	Zaliczenie na ocenę	pisemny test lub projekt
U2	Potrafi analizować wyniki prognozowania oraz oceniać skuteczność zastosowanych modeli predykcyjnych.	K_U02 K_U03 K_U09	laboratorium	Zaliczenie na ocenę	pisemny test lub projekt
K1	Jest gotów do samodzielnego rozwijania wiedzy w zakresie metod prognozowania z wykorzystaniem sztucznej inteligencji.	K_K01 K_K02	laboratorium	Zaliczenie na ocenę	pisemny test lub projekt
K2	Jest gotów do odpowiedzialnego wykorzystywania modeli prognostycznych w analizie danych i podejmowaniu decyzji.	K_K01 K_K02	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja

Literatura i pomoce naukowe
<p>Literatura podstawowa:</p> <ol style="list-style-type: none"> Literatura podstawowa: Rob J Hyndman, George Athanasopoulos – Forecasting: Principles and Practice, OTexts, Melbourne, 2021. Christopher M Bishop – Pattern Recognition and Machine Learning, Springer, New York, 2006. Kevin P Murphy – Machine Learning: A Probabilistic Perspective, MIT Press, Cambridge (MA), 2012. Aurélien Géron – Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, O'Reilly Media, Sebastopol, 2022. Jason Brownlee – Deep Learning for Time Series Forecasting, Machine Learning Mastery, Melbourne, 2018. Gareth James, Daniela Witten, Trevor Hastie, Robert Tibshirani – An Introduction to Statistical Learning, Springer, New York, 2021. <p>Literatura uzupełniająca:</p> <ol style="list-style-type: none"> Brockwell Peter J, Richard A Davis – Introduction to Time Series and Forecasting, Springer, New York, 2016. Ethem Alpaydin – Introduction to Machine Learning, MIT Press, Cambridge (MA), 2020. Ian Goodfellow, Yoshua Bengio, Aaron Courville – Deep Learning, MIT Press, Cambridge (MA), 2016. Wołoszyn, J. W., & Wołoszyn, M. (2025). Practical Implementation of Artificial Intelligence in Cybersecurity, One-Class SVM for Anomaly Detection in Network Traffic. Dydaktyka Informatyki , Article 20. https://doi.org/10.15584/di.2025.20.17 Wołoszyn, J. W., & Wołoszyn, M. (2025). Theoretical Considerations on Artificial Intelligence and Cybersecurity, One-Class SVM for Anomaly Detection in Network Traffic. Dydaktyka Informatyki , Article 20. https://doi.org/10.15584/di.2025.20.16 <p>Szczegółowy wykaz dodatkowych źródeł i pomocy naukowych na pierwszych zajęciach podają prowadzący.</p>

Naład pracy studenta potrzebny do osiągnięcia zakładanych efektów uczenia się – bilans punktów ECTS		
Udział w zajęciach, aktywność	Obciążenie studenta [h]	
	Praca własna studenta - zajęcia bez nauczyciela (ZBN)	Zajęcia dydaktyczne

Udział w wykładach i laboratoriach	X	23 [h]
Przygotowanie do zajęć, Przygotowanie do zaliczenia	52 [h]	X
Sumaryczne obciążenie pracą studenta	52 [h]/ 2,1 ECTS	23 [h]/ 0,9 ECTS
Punkty ECTS za przedmiot	3 ECTS	

Informacje dodatkowe, uwagi
<p>W przypadku studentów ze szczególnymi potrzebami, w tym: z niepełnosprawnością, przewlekle chorych, określone powyżej (w karcie) metody i formy weryfikacji efektów uczenia się dostosowuje się odpowiednio do indywidualnych potrzeb tych studentów.</p> <p>Szczegółowe zasady i formy wsparcia studentów ze szczególnymi potrzebami: w tym z niepełnosprawnością, przewlekle chorych podczas zajęć, zaliczeń i egzaminów określono w: Regulaminie Studiów, Zasadach Studiowania, Procedurze dotyczącej zapewnienia dostępności procesu kształcenia studentom ze szczególnymi potrzebami, w tym: z niepełnosprawnością, przewlekle chorych.</p>