

KARTA PRZEDMIOTU (SYLABUS)

Opis przedmiotu

Kod przedmiotu		Nazwa przedmiotu	Uczenie maszynowe	
AIwB/O/I/ST/B1-25			Machine Learning	
Język wykładowy		Polski		
Rok akademicki		2026/2027		
Kierunek		Sztuczna Inteligencja w Biznesie		
w zakresie		-		
Poziom studiów		studia pierwszego stopnia		
Profil studiów		ogólnoakademicki		
Forma studiów		studia stacjonarne		
Semestr / semestry		semestr trzeci		
Przynależność do grupy zajęć		B. Grupa zajęć kierunkowych B1. Grupa zajęć kierunkowych obowiązkowych		
Status przedmiotu		Obowiązkowy		
Formy realizacji zajęć dydaktycznych, wymiar, punkty ECTS		Forma zajęć	Liczba godzin zajęć dydaktycznych	Liczba punktów ECTS
		Wykład	15[h]	3,5 ECTS
		Ćwiczenia	[h]	
		Laboratorium	30 [h]	
Powiązanie przedmiotu	z profilem studiów	Związany z prowadzoną działalnością naukową w dyscyplinie informatyka techniczna i telekomunikacja		3,5ECTS
	z uprawnieniami			ECTS
	z dyscypliną	Informatyka techniczna i telekomunikacja		3,5 ECTS
Forma nauczania		Tradycyjna - zajęcia zorganizowane w Uczelni /		
Wymagania wstępne		Wymagana znajomość z przedmiotu analiza matematyka, bardzo dobra znajomość podstawy programowania.		
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:	<p>Celem przedmiotu jest zapoznanie studentów z podstawowymi pojęciami, technikami i algorytmami uczenia maszynowego oraz ich praktycznym zastosowaniem w kontekście analizy danych i rozwiązywania problemów biznesowych. Zajęcia łączą teorię z praktyką – od fundamentów matematycznych po implementację modeli ML w rzeczywistych przypadkach użycia.</p>
Treści programowe:	<p>Treści zajęć są powiązane z prowadzonymi badaniami naukowymi.</p> <p>Treści wykładów:</p> <ul style="list-style-type: none"> • rodzaje uczenia maszynowego (nadzorowane, nienadzorowane, wzmacniane), • podstawowe algorytmy (regresja liniowa i logistyczna, drzewa decyzyjne, SVM, kNN, klasteryzacja, PCA), • metryki oceny modeli, walidacja krzyżowa, nadmierne dopasowanie, • wprowadzenie do bibliotek Python (scikit-learn, pandas, matplotlib), • wykorzystanie modeli ML w analizie klientów, prognozowaniu sprzedaży, wykrywaniu anomalii, segmentacji rynku i automatyzacji procesów decyzyjnych. <p>Suma: 15 [h]</p> <p>Treść laboratoriów:</p> <p>Wprowadzenie do uczenia maszynowego</p> <ul style="list-style-type: none"> • Omówienie rodzajów uczenia maszynowego: nadzorowanego, nienadzorowanego i wzmacnianego. • Praktyczne przykłady zastosowania każdego z nich. <p>Podstawowe algorytmy uczenia maszynowego</p> <ul style="list-style-type: none"> • Implementacja regresji liniowej i logistycznej. • Tworzenie i ocena modeli drzewa decyzyjnego, SVM i kNN. • Klasteryzacja metodą K-Means i analiza PCA. <p>Ocena i optymalizacja modeli</p> <ul style="list-style-type: none"> • Metryki oceny modeli: dokładność, precyzja, recall, F1-score, RMSE, R^2. • Walidacja krzyżowa – implementacja i interpretacja wyników. • Nadmierne dopasowanie – metody redukcji (pruning, regularyzacja, dropout). <p>Praca z bibliotekami Python</p> <ul style="list-style-type: none"> • Wprowadzenie do Scikit-learn: budowa i trenowanie modeli. • Analiza danych z Pandas – operacje na zbiorach danych. • Wizualizacja wyników za pomocą Matplotlib i Seaborn. <p>Zastosowanie modeli ML w analizie biznesowej</p> <ul style="list-style-type: none"> • Prognozowanie sprzedaży na podstawie danych historycznych. • Wykrywanie anomalii w transakcjach finansowych. • Segmentacja klientów metodami klasteryzacji. • Automatyzacja procesów decyzyjnych na podstawie predykcji ML. <p>Suma: 30 [h]</p>
Metody dydaktyczne (kształcenia):	<ul style="list-style-type: none"> - metody podające (wykład informacyjny), - metody programowane (z wykorzystaniem komputera), - Obserwacja <p>Zajęcia prowadzone w programie Python</p>

	<p>Warunkiem zaliczenia przedmiotu jest osiągnięcie wszystkich wymaganych efektów uczenia się określonych dla danego 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 określa regulamin studiów.</p> <p>Sposób obliczania oceny z poszczególnych form zajęć przedstawia się następująco:</p> <p>Ocenę z laboratorium to ocena testu.</p> <p>Na ocenę z wykładu składa się wynik otwartego testu pisemnego. Zdobyte w poszczególnych formach zajęć punkty przeliczane zostają na ocenę wg skali:</p> <p>Ocena 2 poniżej 51%</p> <p>Ocena 3 od 51%</p> <p>Ocena 3,5 od 61%</p> <p>Ocena 4 od 71%</p> <p>Ocena 4,5 od 81%</p> <p>Ocena 5 od 91%</p>
--	--

Efekty uczenia się dla przedmiotu w odniesieniu do efektów kierunkowych i formy zajęć				Metody weryfikacji efektów uczenia się	
Numer efektu uczenia się	Opis efektów uczenia się dla przedmiotu (PEU) Student, który zaliczył przedmiot (W) zna i rozumie/ (U) potrafi /(K) jest gotów do:	Kierunkowy efekt uczenia się (KEU)	Forma zajęć	Forma weryfikacji (zaliczeń)	Metody sprawdzania i oceny
W1	rozumie podstawowe pojęcia i metody uczenia maszynowego,	K_W03 K_W07	wykład	Zaliczenie na ocenę	pisemny test otwarty
U1	potrafi przygotować dane do analizy (czyszczenie, normalizacja, selekcja cech)	K_U03 K_U04	laboratorium	Zaliczenie na ocenę	pisemny test otwarty
U2	umie dobrać i zaimplementować odpowiedni algorytm ML do konkretnego problemu,	K_U03 K_U04	laboratorium	Zaliczenie na ocenę	pisemny test otwarty
U3	potrafi interpretować wyniki modelu i ocenić jego jakość,	K_U03 K_U04	laboratorium	Zaliczenie na ocenę	pisemny test otwarty
K1	zna przykłady praktycznego zastosowania ML w różnych obszarach biznesowych	K_K03 K_K04 K_U05	Wykład/ laboratorium	Zaliczenie na ocenę	Obserwacja, aktywność na zajęciach obserwacja

Literatura i pomoce naukowe
<p>Literatura podstawowa:</p> <ol style="list-style-type: none"> 1. Kapela, M. (2024). <i>Wykorzystanie sztucznej inteligencji w łańcuchach dostaw. Przypadek polskich przedsiębiorstw przemysłowych</i>. CeDeWu. Księgarnia internetowa Profinfo.pl 2. Davenport, T. H., & Mittal, N. (2023). <i>Sztuczna inteligencja w biznesie. Jak zdobyć rynkową przewagę dzięki AI</i>. MT Biznes. ksiazki.wp.pl 3. Gałek, D. (2023). <i>AI w Biznesie: Praktyczny Przewodnik Stosowania Sztucznej Inteligencji w Różnych Branżach</i>. Pearnet. 4. Ćwiertniak, R. (2024). <i>Sztuczna inteligencja w organizacji. Innowacje biznesowe w praktyce</i>. Onepress. Księgarnia internetowa Profinfo.pl 5. Kelleher, J. D., & Tierney, B. (2018). <i>Data Science</i>. MIT Press. <p>Literatura uzupełniająca:</p> <ol style="list-style-type: none"> 6. Shmueli, G., Bruce, P. C., & Deokar, K. R. (2023). <i>Machine Learning for Business Analytics: Concepts, Techniques, and Applications with Analytic Solver Data Mining</i> (4th ed.). Wiley.Amazon

7. Hull, J. C. (2019). *Machine Learning in Business: An Introduction to the World of Data Science*. Independently published. Amazon
 8. Hudgeon, D., & Nichol, R. (2019). *Machine Learning for Business: Using Amazon SageMaker and Jupyter*. Manning Publications
 9. Wołoszyn, J. W., Wołoszyn, M., & Molga, A. M. (2025). Metody numeryczne : implementacje. W Monografie - Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego (No. 350; s. 155). Uniwersytet Radomski im. Kazimierza Pułaskiego.
<https://katalog.uniwersytetradom.pl/1783601779191/woloszyn-jacek/metody-numeryczne?bibFilter=178>
 10. Wołoszyn, J. W., & Molga, A. M. (2025). Artificial intelligence in science and technology : from biomedical image analysis to engineering and digital security. W Monografie - Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego (No. 346; s. 113). Uniwersytet Radomski im. Kazimierza Pułaskiego. <https://katalog.uniwersytetradom.pl/1783601774065/woloszyn-jacek/artificial-intelligence-in-science-and-technology?bibFilter=178>
 11. Wołoszyn, J. W. (2025). Sztuczna inteligencja : implementacja i analiza modeli YOLO : koduj przyszłość. W Monografie - Uniwersytet Technologiczno-Humanistyczny im. Kazimierza Pułaskiego (No. 335; s. 203). Uniwersytet Radomski im. Kazimierza Pułaskiego.
<https://katalog.uniwersytetradom.pl/1783601722898/woloszyn-jacek/sztuczna-inteligencja?bibFilter=178>
- Szczegółowy wykaz dodatkowych źródeł i pomocy naukowych na pierwszych zajęciach podaje prowadzący.

Nakład 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	45 [h]
Przygotowanie do zajęć, Przygotowanie do zaliczenia	43 [h]	X
Sumaryczne obciążenie pracą studenta	43 [h]/ 1,7 ECTS	45 [h]/ 1,8 ECTS
Punkty ECTS za przedmiot	3,5 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>