

Karta przedmiotu

Nazwa i kod przedmiotu	Przetwarzanie danych i uczenie maszynowe, PG_00060677						
Kierunek studiów	Transport i logistyka						
Data rozpoczęcia studiów	październik 2023 r.		Rok akademicki realizacji przedmiotu		2025/2026		
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		polski		
Semestr studiów	6		Liczba punktów ECTS		3.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydział Politechniki Gdańskiej -> Wydział Inżynierii Mechanicznej i Okrętownictwa -> Instytut Budowy Okrętów -> Zakład Informatyki Technicznej						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Tacjana Niksa-Rynkiewicz				
	Prowadzący zajęcia z przedmiotu						
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	15.0	0.0	0.0	30.0	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		3.0		27.0	75
Cel przedmiotu	Celem przedmiotu jest zapoznanie studentów z podstawowymi metodami przetwarzania danych oraz wybranymi algorytmami uczenia maszynowego, które znajdują zastosowanie w analizie danych transportowych i logistycznych. Studenci nabędą umiejętność projektowania prostych modeli analitycznych, ich trenowania i interpretacji wyników.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K6_U06] potrafi, zgodnie ze sformułowaną specyfikacją, używając właściwych metod i narzędzi, wykonać proste zadanie inżynierskie z zakresu projektowania, wytwarzania i eksploatacji środków i systemów transportowych		Student potrafi zaprogramować i wdrożyć prosty model sztucznej inteligencji (np. klasyfikator) z wykorzystaniem języka Python i bibliotek takich jak scikit-learn, NumPy i pandas, w celu rozwiązania zadania analizy danych w kontekście transportu i logistyki.		[SU1] Assessment of task fulfilment [SU2] Assessment of ability to analyse information		
	[K6_W04] posiada uporządkowaną wiedzę w zakresie informatyki, elektroniki, automatyki i sterowania, technologii informatycznych, grafiki komputerowej, przydatną do zrozumienia możliwości ich zastosowania w transporcie		Student posiada uporządkowaną wiedzę na temat podstawowych metod przetwarzania danych i algorytmów uczenia maszynowego, w tym regresji, klasyfikacji i grupowania, oraz zna ich praktyczne zastosowania w analizie danych transportowych i logistycznych.		[SW3] Assessment of knowledge contained in written work and projects		
	[K6_U01] potrafi pozyskiwać informacje z literatury, baz danych oraz innych źródeł; weryfikować i systematyzować uzyskane informacje, dokonywać ich interpretacji oraz wyciągać wnioski, formułować i uzasadniać opinie		Student potrafi wyszukiwać i analizować dane z różnych źródeł (literatura, bazy danych), stosować metody eksploracji danych i przygotowania danych wejściowych do modeli AI, a także interpretować uzyskane wyniki i formułować wnioski.		[SU5] Assessment of ability to present the results of task		

Treści przedmiotu (Wykład 15h):

1.
Wprowadzenie do przetwarzania danych i uczenia maszynowego
 - Rola danych w systemach transportowych i logistycznych
 - Czym jest uczenie maszynowe i sztuczna inteligencja
2.
Reprezentacja i przygotowanie danych
 - Typy danych (ciągłe, kategoriyczne)
 - Braki danych, wartości odstające, standaryzacja i normalizacja
3.
Eksploracyjna analiza danych
 - Wykresy, korelacje, statystyki opisowe
 - Identyfikacja zależności i wzorców
4.
Uczenie nadzorowane
 - Regresja liniowa i logistyczna
 - Drzewa decyzyjne, kNN, SVM
 - Wprowadzenie do sieci neuronowych
5.
Uczenie nienadzorowane
 - Grupowanie (k-means)
 - Redukcja wymiarowości (PCA)
6.
Ewaluacja modeli
 - Podział danych: zbiór uczący/testowy/validacyjny
 - Miary jakości: accuracy, precision, recall, F1, confusion matrix
 - Krzywa ROC
7.
Zastosowania AI w transporcie i logistyce
 - Przykłady rzeczywistych projektów
 - Wyzwania i ograniczenia

Treści przedmiotu (Projekt 30h):

	1. Formowanie zespołów i wybór tematyki projektu - Przykładowe tematy: klasyfikacja opóźnień, analiza tras, przewidywanie popytu 2. Pozyskiwanie i przygotowanie danych - Wczytywanie danych w Pythonie (pandas, NumPy) - Wstępne przetwarzanie i czyszczenie danych 3. Eksploracja i wizualizacja danych - Tworzenie wykresów (matplotlib, seaborn) - Opis danych i wyciąganie wniosków 4. Budowa modelu ML - Wybór odpowiedniego algorytmu - Uczenie i testowanie modelu (scikit-learn) 5. Ewaluacja i optymalizacja - Walidacja krzyżowa - Dobór hiperparametrów 6. Prezentacja i dokumentacja - Raport końcowy z kodem, wynikami i wnioskami - Prezentacja zespołowa przed grupą									
Wymagania wstępne i dodatkowe										
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table><tr><th>Sposób oceniania (składowe)</th><th>Próg zaliczeniowy</th><th>Składowa oceny końcowej</th></tr><tr><td>projekt</td><td>60.0%</td><td>90.0%</td></tr><tr><td>aktywność</td><td>80.0%</td><td>10.0%</td></tr></table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	projekt	60.0%	90.0%	aktywność	80.0%	10.0%
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej								
projekt	60.0%	90.0%								
aktywność	80.0%	10.0%								
Zalecana lista lektur	<table><tr><td>Podstawowa lista lektur</td><td> - Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III, Aurélien Géron - Python Machine Learning. Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow - Second Edition Sebastian Raschka, Vahid Mirjalili - Python Data Science Handbook. Essential Tools for Working with Data Jake VanderPlas </td></tr></table>	Podstawowa lista lektur	- Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III, Aurélien Géron - Python Machine Learning. Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow - Second Edition Sebastian Raschka, Vahid Mirjalili - Python Data Science Handbook. Essential Tools for Working with Data Jake VanderPlas							
Podstawowa lista lektur	- Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow. Wydanie III, Aurélien Géron - Python Machine Learning. Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow - Second Edition Sebastian Raschka, Vahid Mirjalili - Python Data Science Handbook. Essential Tools for Working with Data Jake VanderPlas									

	Uzupełniająca lista lektur	Daniel T. Larose, Chantal D. Larose, <i>Data Mining and Predictive Analytics</i>, Wiley, 2nd ed., 2015. Przystępne wprowadzenie do eksploracji danych z naciskiem na metody predykcyjne, zawiera wiele przykładów z praktyki. Tom M. Mitchell, <i>Machine Learning</i>, McGraw-Hill, 1997. Klasyczna, teoretyczna pozycja wprowadzająca w podstawowe algorytmy ML i ich matematyczne podstawy. Trevor Hastie, Robert Tibshirani, Jerome Friedman, <i>The Elements of Statistical Learning</i>, Springer, 2009 (dostępna bezpłatnie online). Zaawansowane i matematycznie ugruntowane podejście do uczenia maszynowego. David Barber, <i>Bayesian Reasoning and Machine Learning</i>, Cambridge University Press, 2012 (dostępna online). Dla zainteresowanych probabilistycznym podejściem do ML. François Chollet, <i>Deep Learning with Python</i>, Manning, 2nd ed., 2021. Praktyczne wprowadzenie do głębokiego uczenia z użyciem Keras i TensorFlow, z przykładami w Pythonie.
	Adresy eZasobów	
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Porównanie działania dwóch wybranych klasyfikatorów na rzeczywistym zbiorze danych	
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy	

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.