

Karta przedmiotu

Nazwa i kod przedmiotu	Sztuczna inteligencja w inżynierii lądowej, PG_00069220						
Kierunek studiów	Budownictwo						
Data rozpoczęcia studiów	październik 2023 r.		Rok akademicki realizacji przedmiotu		2026/2027		
Poziom kształcenia	I stopnia - inżynierskie		Grupa zajęć				
Forma studiów	stacjonarne		Sposób realizacji		na uczelni		
Rok studiów	4		Język wykładowy		polski		
Semestr studiów	7		Liczba punktów ECTS		5.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Inżynierii Lądowej i Środowiska -> Katedra Konstrukcji Inżynierskich						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Patryk Ziółkowski				
	Prowadzący zajęcia z przedmiotu						
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	15.0	30.0	0.0	0.0	0.0	45
	W tym liczba godzin zajęć na odległość: 0.0						
	Adres kursu na platformie eNauczanie: https://enauczanie.pg.edu.pl/moodle/course/view.php?id=29772						
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		10.0		70.0	125
Cel przedmiotu	Celem przedmiotu <i>Sztuczna Inteligencja w Inżynierii Lądowej</i> jest przekazanie studentom fundamentalnej wiedzy oraz praktycznych umiejętności z zakresu stosowania metod sztucznej inteligencji i uczenia maszynowego w rozwiązywaniu problemów inżynierii lądowej. Przedmiot przygotowuje studentów do samodzielnej realizacji prostych projektów AI/ML od przygotowania danych i konfiguracji środowiska programistycznego, poprzez trenowanie, walidację i ocenę modeli, aż po interpretację wyników w kontekście inżynierskim. Studenci nabywają kompetencje cenione we współczesnym budownictwie, takie jak: analiza danych inżynierskich, predykcja parametrów konstrukcji, automatyzacja diagnostyki oraz wykorzystanie narzędzi programistycznych do rozwiązywania praktycznych problemów branżowych.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		
	[K6_K04] Angażuje się w niezależne uczenie się przez całe życie i samodzielnie śledzi rozwój nauki i technologii w obszarze inżynierii lądowej.		Po zakończeniu kursu student wykazuje gotowość do samodzielnego i ciągłego pogłębiania wiedzy w obszarze sztucznej inteligencji w inżynierii lądowej, aktywnie śledzi nowe narzędzia, algorytmy i rozwiązania technologiczne oraz potrafi samodzielnie eksperymentować z nimi w celu rozwiązywania problemów inżynierskich.		[SK5] Ocena umiejętności rozwiązywania problemów występujących w praktyce		
	[K6_K03] Potrafi skutecznie, jasno i jednoznacznie przekazywać informacje, opisywać działania i komunikować ich rezultaty/wyniki inżynierom lub szerszej publiczności przy użyciu odpowiednich metod i narzędzi komunikacji.		Po zakończeniu kursu student potrafi w sposób jasny, zrozumiały i profesjonalny przedstawić wyniki zastosowania metod sztucznej inteligencji w inżynierii lądowej – zarówno w formie pisemnej (raport techniczny, dokumentacja projektu) jak i ustnej (prezentacja), wykorzystując odpowiednie narzędzia komunikacji oraz dostosowując przekaz do odbiorców będących inżynierami lub szerszą publicznością.		[SK2] Ocena postępów pracy		

Treści przedmiotu	Treści przedmiotu - wykład		
	Wykłady obejmują zagadnienia teoretyczne związane z podstawami sztucznej inteligencji i uczenia maszynowego oraz ich zastosowaniami w inżynierii lądowej, zgodnie ze strukturą modułów kursu: Wprowadzenie do AI/ML w inżynierii lądowej definicje, znaczenie AI, przykłady zastosowań: analiza obrazów z dronów, przewidywanie osiadań, systemy predykcji zużycia materiałów. Rola AI jako narzędzia inżynierskiego. Typowe zadania ML i etapy projektu AI regresja, klasyfikacja, grupowanie; etapy projektu ML: dane, przygotowanie, trenowanie, walidacja, interpretacja. Techniki uczenia maszynowego przegląd algorytmów regresja liniowa, regresja logistyczna, k-NN, drzewa decyzyjne, SVM, perceptron wielowarstwowy. Intuicja działania, przykłady zastosowań inżynierskich (np. przewidywanie wytrzymałości betonu). Środowisko i narzędzia AI Python, biblioteki ML (scikit-learn, TensorFlow, DEAP), konfiguracja środowiska, narzędzia wspierające wizualizację danych i trenowanie modeli. Przetwarzanie i analiza danych inżynierskich czyszczenie danych, identyfikacja błędów pomiarowych, analiza statystyczna, interpretacja wykresów. Znaczenie jakości danych w projektach AI. Optymalizacja konstrukcji z wykorzystaniem SI algorytmy genetyczne, optymalizacja przekroju, zbrojenia, kosztu i masy konstrukcji; potencjał algorytmów rojowych. Studia przypadków. Diagnozowanie konstrukcji z wykorzystaniem analizy obrazów (CV) sieci konwolucyjne (CNN), wykrywanie rys, korozji, degradacji materiałów. Przykłady praktyczne i ograniczenia metod. Krytyczne myślenie i rola inżyniera w projektach AI ograniczenia SI, znaczenie interpretacji inżynierskiej, rola eksperta przy decyzjach projektowych.		
	Treści przedmiotu - ćwiczenia		
	Ćwiczenia (laboratoria) obejmują praktyczną realizację zagadnień z wykładów, poprzez pracę z rzeczywistymi danymi inżynierskimi, implementację algorytmów oraz rozwijanie projektu zespołowego: Warsztat 1: Konfiguracja środowiska i podstawy programowania Instalacja i testowanie środowiska Python (Anaconda, Jupyter, Google Colab), import bibliotek (NumPy, Pandas, scikit-learn, TensorFlow), testowe uruchomienie skryptów; podstawy składni Python, struktury danych, instrukcje sterujące. Warsztat 2: Przygotowanie i eksploracja danych (EDA) Wczytywanie danych inżynierskich, czyszczenie danych (braki, outliery), interpolacja, kodowanie zmiennych, skalowanie; analiza statystyczna i wizualizacja danych (histogramy, wykresy rozproszenia, boxploty). Przygotowanie zbioru treningowego i testowego. Warsztat 3: Trenowanie modeli regresja i klasyfikacja Implementacja modeli ML (regresja liniowa, drzewa, k-NN); podział danych na trening/test; obliczanie metryk (MSE, RMSE, accuracy, confusion matrix); interpretacja wyników; dyskusja nad walidacją krzyżową i strojenie hiperparametrów. Kick-off projektu zespołowego. Warsztat 4: Prezentacje projektów i podsumowanie kursu Prezentacje zespołowe: cel projektu, dane, zastosowane metody, wyniki i interpretacja, wnioski. Dyskusja, ocena jakości rozwiązań, feedback, rekomendacje dalszego rozwoju.		
Wymagania wstępne i dodatkowe	Brak formalnych wymagań wstępnych. Zalecana jest podstawowa wiedza z matematyki, w szczególności z algebry liniowej i statystyki. Umiejętność programowania nie jest wymagana kurs obejmuje wprowadzenie do podstaw programowania w języku Python.		
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	Projekt semestralny	60.0%	40.0%
	Egzamin	60.0%	60.0%

Zalecana lista lektur	Podstawowa lista lektur	Podstawowa lista lektur obejmuje publikacje naukowe, materiały dydaktyczne oraz dokumentację narzędzi wykorzystywanych w kursie, zgodnie z dokumentacją dydaktyczną. Kluczowe pozycje to: 1. Mohammed Rady, <i>Application of evolutionary algorithms to design economic flat slab buildings based on the intended function</i>, Scientific Reports, vol. 14, Art. 8826, 2024. 2. M.A. Nyathi, J. Bai, I.D. Wilson, <i>Deep Learning for Concrete Crack Detection and Measurement</i>, Metrology, 4(1): 6681, 2024. 3. Materiały własne opracowane przez prowadzącego: notatki, instrukcje do ćwiczeń, przykładowe zbiory danych oraz notebooki Jupyter (np. DataCleaning.ipynb). 4. Dokumentacja bibliotek: scikit-learn, TensorFlow, PyTorch (materiały dostępne online).
	Uzupełniająca lista lektur	• M. D. Wilkinson et al., <i>The FAIR Guiding Principles for scientific data management and stewardship</i>, Scientific Data, 2016. • E. E. Ambarita et al., <i>Industrial digital twins in offshore wind farms</i>, Energy Informatics, 2024. • V. Leble et al., <i>Data exchange formats</i>, HYBRID WIND Project, Work Package 1 - Deliverable D1.2, 2025. • A. Michiorri et al., <i>Topic Taxonomy and Metadata to Support Renewable Energy Digitalisation</i>, Energies, 2022. • DCMI Metadata Terms, Dublin Core Metadata Initiative, 2020. • Kursowe materiały e-learningowe: multimedia, case studies, notebooki Python, instrukcje laboratoryjne, przykłady zbiorów danych (np. DataCleaning.ipynb).
	Adresy eZasobów	

Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	1. Wyjaśnij różnicę między uczeniem nadzorowanym, nienadzorowanym i uczeniem przez wzmacnianie podaj przykłady zastosowań w inżynierii lądowej. 2. Wczytaj rzeczywisty zbiór danych dotyczący wytrzymałości betonu, oczyść dane z wartości odstających i braków, dokonaj analizy eksploracyjnej (EDA) i przedstaw wnioski. 3. Porównaj działanie regresji liniowej i drzewa decyzyjnego w przewidywaniu wytrzymałości betonu zinterpretuj wyniki (MSE, R^2). 4. Zaprojektuj prosty model klasyfikacyjny do wykrywania pęknięć betonu na zdjęciach omów, jak przygotować dane i jakie metryki oceny zastosować. 5. Zdefiniuj problem optymalizacji konstrukcji żelbetowej zaproponuj, jakie zmienne decyzyjne i ograniczenia można zastosować w algorytmie genetycznym. 6. Jakie są kluczowe etapy projektu AI/ML? Wskaż, które z nich mogą sprawiać największe trudności w zastosowaniach inżynierskich i dlaczego. 7. Opracuj krótki raport techniczny podsumowujący wyniki trenowania modelu regresji uwzględnij interpretację wyników i potencjalne zastosowania praktyczne. 8. Przeanalizuj wygenerowane wyniki detekcji uszkodzeń na zdjęciu płyty betonowej wskaż, które obszary są prawdziwymi uszkodzeniami, a które są szumem. 9. Jaką rolę pełni inżynier w procesie projektowania rozwiązań AI dlaczego nie można go całkowicie zastąpić algorytmem? 10. Przygotuj prezentację zespołową przedstawiającą projekt AI w budownictwie cel, dane, metoda, wyniki, wnioski i rekomendacje.
Zajęcia praktyczne w ramach przedmiotu	Nie dotyczy

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.