



Karta przedmiotu

Nazwa i kod przedmiotu	MACHINE LEARNING, PG_00068680						
Kierunek studiów	Analityka gospodarcza						
Data rozpoczęcia studiów	październik 2025 r.		Rok akademicki realizacji przedmiotu		2026/2027		
Poziom kształcenia	II stopnia		Grupa zajęć		Grupa zajęć fakultatywnych Grupa zajęć specjalnościowych Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	niestacjonarne		Sposób realizacji		na uczelni		
Rok studiów	2		Język wykładowy		polski		
Semestr studiów	3		Liczba punktów ECTS		4.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		zaliczenie		
Jednostka prowadząca	Wydziały Politechniki Gdańskiej -> Wydział Zarządzania i Ekonomii -> Katedra Statystyki i Ekonometrii						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		dr inż. Karol Flisikowski				
	Prowadzący zajęcia z przedmiotu						
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	0.0	0.0	16.0	0.0	0.0	16
	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	16		4.0		80.0	100
Cel przedmiotu	Celem przedmiotu jest zapoznanie studentów z podstawowymi koncepcjami, metodami i algorytmami uczenia maszynowego, umożliwiającymi tworzenie modeli analizy danych, prognozowania i podejmowania decyzji w oparciu o dane. Studenci zdobędą wiedzę teoretyczną oraz praktyczne umiejętności w zakresie stosowania wybranych algorytmów nadzorowanych i nienadzorowanych, przetwarzania danych, walidacji modeli oraz oceny ich skuteczności. Kurs kładzie nacisk na zrozumienie procesu budowy modeli ML, ich interpretację i zastosowanie w rzeczywistych problemach z różnych dziedzin.						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu			Sposób weryfikacji i oceny efektu	
	[K7_U01] potrafi tworzyć innowacyjne rozwiązania złożonych i nieustrukturyzowanych procesów uwzględniając nieprzewidywalne warunki otoczenia poprzez syntezę informacji pochodzących z różnych źródeł.		Ma zaawansowaną wiedzę na temat metod analizy danych i algorytmów uczenia maszynowego, umożliwiającą identyfikację oraz modelowanie złożonych i nieustrukturyzowanych procesów. Zna współczesne narzędzia i technologie wykorzystywane do przetwarzania danych pochodzących z heterogenicznych źródeł.			[SU4] Ocena umiejętności korzystania z metod i narzędzi [SU2] Ocena umiejętności analizy informacji [SU1] Ocena realizacji zadania	
	[K7_W03] demonstruje pogłębioną wiedzę w zakresie zastosowań metod analitycznych oraz technik formułowania i rozwiązywania problemów społeczno-ekonomicznych.		Student potrafi projektować i wdrażać modele uczenia maszynowego do analizy złożonych procesów przy zmiennych warunkach otoczenia. Potrafi ocenić przydatność różnych źródeł danych i integrować je w celu uzyskania spójnych i trafnych wniosków.			[SW3] Ocena wiedzy zawartej w opracowaniu tekstowym i projektowym	

Treści przedmiotu	Wprowadzenie do uczenia maszynowego Definicja i historia uczenia maszynowego Różnica między sztuczną inteligencją, uczeniem maszynowym i głębokim Obszary zastosowań uczenia maszynowego (rozpoznawanie obrazów, analiza tekstu, prognozy itp.) Podstawowe kategorie algorytmów ML: nadzorowane, nienadzorowane, ze wzmocnieniem Podstawy matematyczne uczenia maszynowego Wprowadzenie do algebry liniowej (macierze, wektory, operacje) Statystyka: miary centralne, rozkłady prawdopodobieństwa, estymacja Pojęcia związane z optymalizacją (funkcje kosztu, gradient descent) Przygotowanie danych Podstawy przetwarzania danych: czyszczenie, uzupełnianie braków, normalizacja, standaryzacja Przekształcanie zmiennych: kodowanie zmiennych kategorycznych, inżynieria cech Podział danych: zbiór treningowy, walidacyjny, testowy Wyzwania związane z dużymi zbiorami danych (Big Data) Uczenie nadzorowane (Supervised Learning) Regresja: liniowa, wielomianowa, regresja logistyczna Klasyfikacja: Naive Bayes, k-NN, drzewa decyzyjne, SVM Modele ensemble: Random Forest, Gradient Boosting (XGBoost, LightGBM, CatBoost) Neural Networks (MLP) Optymalizacja: Cross-validation, regularizacja (L1, L2), walidacja krzyżowa Uczenie nienadzorowane (Unsupervised Learning) Klasteryzacja: K-Means, DBSCAN, aglomeracyjna klasteryzacja hierarchiczna Redukcja wymiarowości: PCA, t-SNE, LDA Analiza zależności: analiza głównych składowych, analiza czynnikowa Uczenie głębokie (Deep Learning)
-------------------	--

	<i>Wprowadzenie do sieci neuronowych</i>
	<i>Budowa i działanie perceptronów</i>
	<i>Sieci konwolucyjne (CNN) do analizy obrazów</i>
	<i>Sieci rekurencyjne (RNN) i LSTM w analizie sekwencyjnej</i>
	<i>Transfer learning i fine-tuning</i>
	<i>Wprowadzenie do bibliotek: TensorFlow, Keras, PyTorch</i>
	<i>Optymalizacja modeli i hyperparameter tuning</i>
	<i>Wybór najlepszych hiperparametrów modelu (Grid Search, Random Search, Bayesian Optimization)</i>
	<i>Regularizacja i techniki redukcji nadmiernego dopasowania (dropout, early stopping)</i>
	<i>Cross-validation i walidacja krzyżowa</i>
	<i>Analiza błędów i ocena wyników (RMSE, MAE, AUC-ROC, F1-score)</i>
	<i>Zastosowania uczenia maszynowego w praktyce</i>
	<i>Rozpoznawanie obrazów: klasyfikacja obrazów z wykorzystaniem CNN</i>
	<i>Przetwarzanie języka naturalnego (NLP): analiza tekstów, modele word embeddings (Word2Vec, GloVe)</i>
	<i>Rekomendacje: algorytmy filtracji oparte na treści i współpracy (Collaborative Filtering)</i>
	<i>Predykacja: prognozowanie szeregów czasowych i analiza trendów</i>
	<i>Anomalie i detekcja oszustw: identyfikacja nieprawidłowości w danych</i>
	<i>Etyka i odpowiedzialność w uczeniu maszynowym</i>
	<i>Problemy związane z uprzedzeniami w danych (bias)</i>
	<i>Etyczne wykorzystanie algorytmów w różnych branżach</i>
	<i>Transparentność i interpretowalność modeli ML</i>
	<i>Odpowiedzialność za decyzje oparte na algorytmach (np. w medycynie, finansach, wymiarze sprawiedliwości)</i>
	<i>Warsztaty praktyczne i projekty</i>
	<i>Implementacja wybranych algorytmów ML w Pythonie (scikit-learn, pandas, numpy, matplotlib)</i>
	<i>Analiza rzeczywistych przypadków (case studies)</i>

	<i>Praca z danymi z różnych źródeł (np. dane zebrane z mediów społecznościowych, dane finansowe, obrazy)</i> <i>Mini-projekt: wdrożenie i prezentacja wyników na podstawie własnego zbioru danych</i>		
Wymagania wstępne i dodatkowe	Statystyka opisowa, statystyka matematyczna, podstawy programowania w R/Pythonie.		
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej
	Sprawozdania	50.0%	40.0%
	Projekt końcowy	50.0%	50.0%
	Wejściówki	50.0%	10.0%
Zalecana lista lektur	Podstawowa lista lektur	1. Rogalski, M. (2019). Uczenie maszynowe z Pythonem. Helion. 2. Raschka, S., & Mirjalili, V. (2020). Python. Machine Learning i Deep Learning. Biblioteki scikit-learn i TensorFlow 2. Wydanie III. Helion. 3. Siemieniuk, S. (2018). Python w uczeniu maszynowym. Praktyczne podejście. Wydawnictwo Helion.	
	Uzupełniająca lista lektur	1. Chollet, F. (2025). Deep learning with Python (3rd ed.). Manning Publications. 2. Chen, S., Zhang, H., & Li, J. (2024). Deep learning and machine learning Python data structures and mathematics fundamentals: From theory to practice. Springer.	
	Adresy eZasobów	Podstawowe https://github.com/ageron/handson-ml3 - Seria notebooków Jupyter, które wprowadzą Cię w podstawy uczenia maszynowego i głębokiego w Pythonie z wykorzystaniem Scikit-Learn, Keras i TensorFlow 2. Uzupełniające Adresy na platformie eNauczanie:	

Zagadnienia:

Podstawy uczenia maszynowego:

Klasyfikacja vs. regresja: czym się różnią i kiedy je stosować?

Przypadki użycia różnych algorytmów klasyfikacji (np. drzewa decyzyjne, SVM, KNN).

Podstawowe techniki optymalizacji w uczeniu maszynowym (np. gradient descent).

Przygotowanie danych:

Przeszukiwanie i oczyszczanie danych (missing values, outliers).

Normalizacja, standaryzacja i inżynieria cech.

Metody selekcji cech (feature selection) i redukcji wymiarów (PCA, LDA).

Uczenie głębokie:

Podstawy neuronów i sieci neuronowych.

Architektury sieci neuronowych: CNN, RNN, GANs.

Overfitting i regularizacja w głębokim uczeniu (dropout, L2 regularization).

Modelowanie i ocena:

Cross-validation i techniki walidacji.

Matryce pomyłek, Precision, Recall, F1-score.

Strojenie hiperparametrów i wybór najlepszego modelu.

Pytania:

Jakie są różnice między klasycznymi algorytmami uczenia maszynowego, a metodami głębokiego uczenia?

Jakie techniki można zastosować w celu zapobiegania overfittingowi w modelach głębokiego uczenia?

W jaki sposób można ocenić skuteczność modelu klasyfikacyjnego w kontekście nierównych klas?

Co to jest gradient descent i jak wpływa na proces uczenia modeli?

Realizowane zadania:

Zadanie 1:

Wykorzystanie Scikit-learn do klasyfikacji danych z wykorzystaniem algorytmu KNN. Porównanie wyników z innymi

	algorytmami, np. SVM, drzewa decyzyjne. Zadanie 2: Zastosowanie algorytmu PCA do redukcji wymiarów w zbiorze danych (np. Iris dataset) i ocena efektywności tej metody na wynikach klasyfikacji. Zadanie 3: Budowa modelu sieci neuronowej przy użyciu Keras/TensorFlow do klasyfikacji obrazów (np. dataset CIFAR-10). Porównanie wyników z klasycznymi algorytmami ML. Zadanie 4: Przeprowadzenie analizy i oczyszczania danych (missing values, outliers) w zbiorze danych o klientach banku. Następnie budowa modelu predykcji bankructwa klienta. Zadanie 5: Zastosowanie metody regularizacji (L2, Dropout) w modelu głębokiego uczenia do rozwiązania problemu klasyfikacji obrazów. Ocena skuteczności w zapobieganiu overfittingowi.
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.