



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wprowadzenie do uczenia maszynowego [S1DSwB1>WdUM]

Przedmiot

Kierunek studiów

Data Science w biznesie

Rok/Semestr

1/2

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

30

Laboratorium

0

Inne

0

Ćwiczenia

30

Projekty/seminaria

0

Liczba punktów ECTS

5,00

Koordynatorzy

dr Grzegorz Nowak

grzegorz.nowak@put.poznan.pl

dr inż. Marcin Nowak

marcin.nowak@put.poznan.pl

Wykładowcy

Wymagania wstępne

Studenci powinni znać podstawy Python (struktury danych, pętle, funkcje, podstawowe biblioteki) oraz analizy matematycznej (algebra liniowa, rachunek macierzowy oraz rachunek różniczkowy)

Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z kluczowymi koncepcjami, metodami i narzędziami uczenia maszynowego. Studenci poznają zarówno teoretyczne podstawy algorytmów, jak i ich matematyczne aspekty, w tym modele regresyjne, klasyfikacyjne i klasteryzacyjne. Omówione zostaną metody walidacji modeli, redukcji wymiarowości oraz techniki poprawy jakości predykcji, takie jak regularizacja i tuning hiperparametrów.

Przedmiotowe efekty uczenia się

Wiedza:

1. Wyjaśnia podstawowe koncepcje i matematyczne podstawy uczenia maszynowego, w tym regresję,

klasyfikację i grupowanie danych [DSB1_W01].

2. Charakteryzuje proces tworzenia modeli ML, od przetwarzania danych i inżynierii cech po walidację, tuning hiperparametrów i interpretację wyników [DSB1_W03].

3. Opisuje kluczowe metody uczenia maszynowego, takie jak regresja liniowa i logistyczna, drzewa decyzyjne, SVM, metody zespołowe oraz algorytmy klasteryzacji [DSB1_W02].

Umiejętności:

1. Stosuje metody regresji (liniowa, logistyczna, Ridge, Lasso) do analizy danych i predykcji wyników [DSB1_U02].

2. Projektuje i przeprowadza eksperymenty z użyciem algorytmów klasyfikacyjnych i grupujących, takich jak drzewa decyzyjne, k-NN, SVM oraz DBSCAN [DSB1_U03].

3. Wykorzystuje metody redukcji wymiarowości, takie jak PCA, oraz inżynierię cech do poprawy

4. Analizuje działanie modeli ML pod kątem błędów, overfittingu i interpretowalności [DSB1_U07].

5. Tworzy pełny pipeline analityczny od przetwarzania danych po ewaluację modeli ML [DSB1_U08].

6. Wykorzystuje narzędzia ML, takie jak scikit-learn, TensorFlow lub PyTorch, do implementacji modeli uczenia maszynowego [DSB1_U09].

7. Argumentuje wybór metod analizy danych oraz ocenia skuteczność modeli na podstawie wskaźników jakości [DSB1_U11].

8. Rozwija swoje kompetencje w zakresie uczenia maszynowego, śledząc najnowsze osiągnięcia naukowe i praktyczne [DSB1_U15].

9. Dobiera odpowiednie źródła wiedzy i narzędzia do projektowania i implementacji modeli uczenia maszynowego [DSB1_U01].

Kompetencje społeczne:

1. Ocenia wpływ metod ML na procesy decyzyjne w biznesie i analizie danych, uwzględniając etykę i potencjalne zagrożenia [DSB1_K05].

2. Współpracuje w zespołach interdyscyplinarnych nad projektami związanymi z wdrażaniem i optymalizacją modeli ML [DSB1_K02].

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykład: Dwa kolokwia, za które studenci otrzymują oceny formułujące w postaci punktów - po 50 punktów za każde kolokwium. Ocena końcowa stanowi sumę punktów z dwóch ocen formułujących. Pierwsze kolokwium odbywa się w połowie kursu, a drugie na jego zakończenie. Próg zaliczeniowy to 50 punktów łącznie z obu kolokwiów.

Laboratoria: Dwa kolokwia, za które studenci otrzymują oceny formułujące w postaci punktów - po 50 punktów za każde kolokwium. Ocena końcowa stanowi sumę punktów z dwóch ocen formułujących. Pierwsze kolokwium odbywa się w połowie kursu, a drugie na jego zakończenie. Próg zaliczeniowy to 50 punktów łącznie z obu kolokwiów.

Treści programowe

Kurs obejmuje podstawowe koncepcje, metody i narzędzia uczenia maszynowego, kładąc nacisk na ich matematyczne podstawy. Studenci poznają historię ML, kluczowe pojęcia oraz pełny proces tworzenia modeli - od przetwarzania danych po walidację i interpretację wyników. Omówione zostaną metody regresyjne (liniowa, logistyczna, Ridge, Lasso), algorytmy klasyfikacyjne (drzewa decyzyjne, k-NN, SVM, modele zespołowe) oraz techniki grupowania (k-means, DBSCAN, klasteryzacja hierarchiczna). Studenci nauczą się również redukcji wymiarowości (PCA), inżynierii cech, tuningowania modeli oraz zasad interpretowalności i etyki w ML. Kurs obejmuje przegląd kluczowych narzędzi i frameworków stosowanych w uczeniu maszynowym

Tematyka zajęć

Historia i koncepcje uczenia maszynowego

Matematyczne podstawy uczenia maszynowego

Pipeline uczenia maszynowego i problem overfittingu

Regresja liniowa - model matematyczny i optymalizacja

Regresja logistyczna - teoria i matematyka

Regularizacja w regresji - Lasso i Ridge

Drzewa decyzyjne - matematyka podziału danych
 k-NN i metody oparte na podobieństwie
 Maszyny wektorów nośnych (SVM) - teoria i matematyczne podstawy
 Metody ensemble learning (bagging i boosting)
 Metody grupowania - matematyka algorytmów klasteryzacji
 Hierarchiczne metody klasteryzacji
 Klasteryzacja Density-Based (DBSCAN)
 Redukcja wymiarowości i analiza głównych składowych (PCA)
 Dobór cech i inżynieria cech
 Metody walidacji modeli i tuning hiperparametrów
 Interpretowalność modeli i etyka w ML
 Przegląd narzędzi i frameworków ML

Metody dydaktyczne

Wykłady: wykład problemowy, prezentacja case studies
 Laboratoria: zadania problemowe, studium przypadku, praca w grupach

Literatura

Podstawowa:

Geron, A. (2023). *Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow*, Helion
 Gallatin, K. (2024). *Uczenie maszynowe w Pythonie. Receptury. Od przygotowania danych do deep learningu*, Helion

Uzupełniająca:

Hurbans, R. (2020) *Algorytmy sztucznej inteligencji. Ilustrowany przewodnik*, Helion
 Raschka, S., Mirjalili, V. (2019). *Python. Uczenie maszynowe. Wydanie II*, Helion
 Nowak, M., & Pawłowska-Nowak, M. (2024). Dynamic Pricing Method in the E-Commerce Industry Using Machine Learning. *Applied Sciences* (2076-3417), 14(24).
 Nowak, M. (2024). Prediction of voluntary employee turnover using machine learning. *Scientific Papers of Silesian University of Technology. Organization & Management/Zeszyty Naukowe Politechniki Śląskiej. Seria Organizacji i Zarządzanie*, (201).

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	62	2,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	63	2,50