



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Uczenie maszynowe w biznesie [S1DSwB1>UMwB]

Przedmiot

Kierunek studiów

Data Science w biznesie

Rok/Semestr

2/3

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

stacjonarne

Wymagalność

obligatoryjny

Liczba godzin

Wykład

0

Laboratorium

0

Inne

0

Ćwiczenia

30

Projekty/seminaria

0

Liczba punktów ECTS

3,00

Koordynatorzy

dr Grzegorz Nowak

grzegorz.nowak@put.poznan.pl

dr inż. Marcin Nowak

marcin.nowak@put.poznan.pl

Wykładowcy

Wymagania wstępne

Studenci powinni znać język Python (w tym programowanie obiektowe) oraz podstawowe biblioteki uczenia maszynowego (scikit-learn, Pandas, NumPy, Matplotlib). Wymagana jest znajomość algebry liniowej, rachunku różniczkowego oraz podstaw matematyki dyskretnej. Studenci powinni również wykazywać się podstawową znajomością algorytmów uczenia maszynowego

Cel przedmiotu

Celem przedmiotu jest rozwinięcie praktycznych umiejętności stosowania metod uczenia maszynowego w analizie biznesowej. Studenci nauczą się przygotowywać dane, dobierać i optymalizować modele predykcyjne oraz interpretować ich wyniki w kontekście rzeczywistych problemów biznesowych. Kurs obejmuje regresję i klasyfikację w analizie ryzyka i segmentacji klientów, metody klasteryzacji, wykrywanie anomalii oraz wyjaśnialność modeli ML. Studenci poznają również zaawansowane techniki tuningowania hiperparametrów oraz zastosowania modeli w takich obszarach jak predykcja wartości klienta, detekcja oszustw i systemy rekomendacyjne. Zajęcia przygotowują ich do efektywnego wykorzystania ML w strategiach biznesowych.

Przedmiotowe efekty uczenia się

Wiedza:

1. Charakteryzuje metody uczenia maszynowego stosowane w analizie biznesowej, w tym regresję, klasyfikację i klasteryzację [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. Dobiera odpowiednie źródła danych oraz narzędzia do modelowania problemów biznesowych za pomocą ML [DSB1_U01].
2. Stosuje regresję liniową i logistyczną do analizy cen, prognozowania wartości klienta (LTV) oraz klasyfikacji klientów [DSB1_U02].
3. Projektuje i implementuje modele klasyfikacyjne i regresyjne w kontekście analizy ryzyka, przewidywania churnu i scoringu kredytowego [DSB1_U07].
4. Tworzy i waliduje modele ML, stosując metody tuningowania hiperparametrów i oceny jakości predykcji [DSB1_U08].
5. Wykorzystuje techniki klasteryzacji (k-means, DBSCAN, hierarchiczne grupowanie) do segmentacji klientów i wykrywania anomalii [DSB1_U09].
6. Argumentuje wybór metod analitycznych oraz interpretuje wyniki modeli ML w kontekście decyzji biznesowych [DSB1_U11].

Kompetencje społeczne:

1. Korzysta z aktualnego dorobku naukowego i praktycznego w zakresie uczenia maszynowego, uwzględniając jego zastosowanie w biznesie [DSB1_K02].
2. Przestrzega zasad jakości kodu i testowania, uwzględniając czytelność, reużywalność i zgodność z zasadami OOP [DSB1_K05].

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Laboratoria: Przeprowadzone zostanie kolokwium, za które studenci otrzymują oceny formułujące w postaci maksymalnie 50 punktów. Pozostałe 50 punktów studenci uzyskują za przygotowanie opracowania dotyczącego analizy rzeczywistego problemu biznesowego z wykorzystaniem uczenia maszynowego. Ocena końcowa stanowi sumę punktów z dwóch ocen formułujących. Próg zaliczeniowy to 50 punktów

Treści programowe

Kurs koncentruje się na praktycznym wykorzystaniu metod uczenia maszynowego w analizie biznesowej. Studenci nauczą się przetwarzać i przygotowywać dane do modeli ML, stosować techniki regresyjne do prognozowania cen i wartości klienta, a także wykorzystywać algorytmy klasyfikacyjne do analizy ryzyka i segmentacji klientów. Omówione zostaną modele drzewa decyzyjnego, lasów losowych, XGBoost i SVM w kontekście przewidywania churnu i wykrywania oszustw. Zajęcia obejmą również metody klasteryzacji (k-means, DBSCAN, hierarchiczne grupowanie) oraz redukcję wymiarowości (PCA). Studenci poznają metody oceny i interpretacji modeli, a także zastosują zdobytą wiedzę w case study opartym na rzeczywistych danych biznesowych

Tematyka zajęć

Wprowadzenie do narzędzi i workflow analizy danych
Przygotowanie danych do modeli ML
Regresja liniowa w analizie cen i prognozowaniu
Regresja wielomianowa i regresja Ridge/Lasso w prognozach biznesowych
Modelowanie wartości klienta (LTV) z regresją logistyczną
Wykorzystanie regresji logistycznej w klasyfikacji klientów i churnu
Modele klasyfikacyjne w analizie ryzyka i segmentacji klientów
Drzewa decyzyjne - teoria i implementacja na danych biznesowych
Las losowy (Random Forest) - poprawa dokładności modeli

XGBoost - tuning hiperparametrów dla predykcji churnu
SVM w wykrywaniu oszustw finansowych i scoringu kredytowym
Klasteryzacja k-means - segmentacja klientów i rekomendacje
Hierarchiczna klasteryzacja - analiza zachowań klientów
DBSCAN i jego zastosowanie w wykrywaniu anomalii
Redukcja wymiarowości i analiza głównych składowych (PCA)
Optymalizacja modeli i interpretacja wyników
Interpretacja modeli i wyjaśnialność ML w biznesie
Praktyczne case study - analiza rzeczywistych danych biznesowych

Metody dydaktyczne

Laboratoria - ćwiczenia w wybranym IDE programistycznym lub środowisku do analizy danych (np. Pycharm lub Google Colaboratory)

Literatura

Podstawowa:

Szpringer, W. (2024). Sztuczna inteligencja w zarządzaniu, MT Biznes

VandePlas, J. (2023). Python Data Science. Niezbędne narzędzia do pracy z danymi, Helion

Uzupełniająca:

Raschka, S., Mirjalili, V. (2021). Python. Machine learning i deep learning. Biblioteki scikit-learn i TensorFlow 2, Helion

Nowak, M. (2024). Prediction of voluntary employee turnover using machine learning. Scientific Papers of Silesian University of Technology. Organization & Management/Zeszyty Naukowe Politechniki Slaskiej. Seria Organizacji i Zarzadzanie, (201).

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	75	3,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	30	1,00
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	45	2,00