



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Przetwarzanie danych i uczenie maszynowe [S2Teleinf2>PDiUM]

Przedmiot

Kierunek studiów
Teleinformatyka

Rok/Semestr
1/1

Studia w zakresie (specjalność)
–

Profil studiów
ogólnoakademicki

Poziom studiów
drugiego stopnia

Język oferowanego przedmiotu
polski

Forma studiów
stacjonarne

Wymagalność
obligatoryjny

Liczba godzin

Wykład
14

Laboratorium
24

Inne
14

Ćwiczenia
0

Projekty/seminaria
0

Liczba punktów ECTS

3,00

Koordynatorzy

dr inż. Sławomir Maćkowiak
slawomir.mackowiak@put.poznan.pl

Wykładowcy

mgr inż. Mateusz Lorkiewicz
mateusz.lorkiewicz@put.poznan.pl
dr inż. Sławomir Maćkowiak
slawomir.mackowiak@put.poznan.pl

Wymagania wstępne

Podstawowa wiedza matematyczna: Studenci powinni mieć solidną podstawową wiedzę z zakresu matematyki, w tym algebra liniowa, rachunek różniczkowy i całkowy oraz statystyka. Uczenie maszynowe często opiera się na matematycznych podstawach, takich jak równania różniczkowe, wzory statystyczne i algebra macierzowa. Programowanie: Znajomość podstaw programowania jest kluczowa, zwłaszcza w językach takich jak Python lub R, które są powszechnie stosowane w uczeniu maszynowym. Studenci powinni umieć pisać i rozumieć kod, tworzyć funkcje i analizować dane przy użyciu narzędzi programistycznych. Statystyka i analiza danych: Rozumienie podstawowych pojęć statystycznych oraz umiejętność analizy danych są niezbędne do pracy w uczeniu maszynowym. Studenci powinni być w stanie przeprowadzać eksplorację danych, oceniać rozkłady prawdopodobieństwa i testować hipotezy. Podstawowa wiedza z algorytmów: Zrozumienie podstawowych koncepcji dotyczących algorytmów jest ważne, ponieważ wiele algorytmów uczenia maszynowego opiera się na algorytmach optymalizacji, algorytmach grafowych i innych strukturach algorytmicznych.

Cel przedmiotu

Przedmiot to zaawansowany program studiów skoncentrowany na teorii, algorytmach i praktycznych zastosowaniach uczenia maszynowego. Studenci tego przedmiotu zdobywają dogłębną wiedzę na temat technik analizy danych i uczenia maszynowego, w tym uczenia nadzorowanego i nienadzorowanego, głębokiego uczenia oraz sztucznej inteligencji. Cechą charakterystyczną tego przedmiotu jest praktyczne podejście, które obejmuje projektowanie modeli, eksperymentowanie z danymi oraz rozwiązywanie rzeczywistych problemów z użyciem różnorodnych narzędzi i frameworków. Kurs ten przygotowuje studentów do pracy w dziedzinach, takich jak analiza danych, rozpoznawanie wzorców oraz rozwijanie zaawansowanych aplikacji opartych na uczeniu maszynowym

Przedmiotowe efekty uczenia się

Wiedza:

Zrozumienie teorii i algorytmów uczenia maszynowego: Studenci zdobędą dogłębną wiedzę na temat różnych rodzajów algorytmów uczenia maszynowego, zarówno nadzorowanych, jak i nienadzorowanych, oraz będą w stanie wybrać odpowiednią metodę do rozwiązywania różnych rodzajów problemów. K2_W06, K2_W11

Znajomość zaawansowanych koncepcji w głębokim uczeniu: Studenci będą zaznajomieni z głębokimi sieciami neuronowymi, architekturami sieci i technikami sztucznej inteligencji, co pozwoli im na zaawansowane projektowanie modeli i rozwiązywanie skomplikowanych problemów. K2_W06, K2_W07, K2_W11

Świadomość etycznych aspektów uczenia maszynowego: Studenci nabędą wiedzę na temat etycznych i społecznych implikacji związanych z uczeniem maszynowym, w tym biasu, dyskryminacji i ochrony prywatności danych.

Umiejętności:

Praktyczne doświadczenie w implementacji modeli uczenia maszynowego: Studenci będą w stanie implementować modele uczenia maszynowego za pomocą narzędzi i frameworków, takich jak TensorFlow lub PyTorch, oraz dostosowywać je do konkretnych zastosowań.

Umiejętność analizy danych i oceny modeli: Studenci nauczą się analizować dane, oceniać wydajność modeli i dostosowywać parametry, aby uzyskać najlepsze wyniki. K2_U06, K2_U07, K2_U10, K2_U16

Rozwiązywanie problemów z użyciem uczenia maszynowego: Studenci nabędą umiejętność identyfikacji problemów, które można rozwiązać za pomocą uczenia maszynowego, oraz projektowania i wdrażania rozwiązań w praktyce. K2_U01, K2_U14

Kompetencje społeczne:

Praca zespołowa w projektach uczenia maszynowego: Studenci będą pracować w zespołach nad projektami uczenia maszynowego, co pozwoli im rozwijać umiejętności komunikacyjne, zdolność do współpracy i efektywną pracę w grupie. K2_K03

Komunikacja naukowa i biznesowa: Studenci nauczą się jasnego i efektywnego przekazywania wyników swoich projektów zarówno w środowisku akademickim, jak i biznesowym, co ułatwi współpracę z różnymi interesariuszami. K2_K06

Świadomość etyczna i społeczna odpowiedzialność: Studenci będą rozwijali świadomość etyczną i społeczną, co pozwoli im podejmować odpowiedzialne decyzje w zakresie wykorzystania uczenia maszynowego i zarządzania danymi. K2_K04

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

1. Wykład

Zadanie z rozwiązywania problemów: studium przypadków, które wymagają współpracy w zespołach w celu analizy i rozwiązania problemów. Ocena umiejętności współpracy, ustalania priorytetów i proponowania skutecznych rozwiązań. Ocena krytycznego myślenia, umiejętności rozwiązywania problemów i dynamiki pracy zespołowej.

Próg zaliczeniowy wynosi 50% punktów.

W przypadku zaliczenia pisemnego i ustnego punkty są sumowane.

Skala ocen: <50% - 2,0 (ndst); 50% do 59% - 3,0 (dst); 60% do 69% - 3,5 (dst+); 70% do 79% - 4,0 (db); 80% do 89% - 4,5 (db+); 90% do 100% - 5,0 (bdb).

2. Laboratorium

Umiejętności osiągnięte w laboratorium określa się na podstawie raportów (sprawozdań) z

przeprowadzonych ćwiczeń laboratoryjnych (OL) oraz zaliczenia końcowego (ZK) w formie samodzielnie realizowanego ćwiczenia lub projektu.

Kompetencje społeczne (KS) ocenia się na podstawie oceny umiejętności aktywnego słuchania, umiejętności współpracy i efektywnego udziału w dyskusjach zespołowych oraz poziomu zaangażowania w procesy rozwiązywania problemów .

Wyznacza się średnią ważoną: $OK = 0,5 \times OL + 0,3 \times ZK + 0,2 \times KS$ i wystawia oceny:

5,0 dla $OK > 4,75$;

4,5 dla $4,75 > OK > 4,25$;

4,0 dla $4,25 > OK > 3,75$;

3,5 dla $3,75 > OK > 3,25$;

3,0 dla $3,25 > OK > 2,75$;

2,0 dla $OK < 2,75$.

Treści programowe

Podstawy uczenia maszynowego (Historia i rozwój uczenia maszynowego. Koncepcja zbiorów treningowych, walidacyjnych i testowych. Klasyfikacja problemów uczenia maszynowego: nadzorowane, nienadzorowane i ze wzmacnieniem.)

Metody uczenia maszynowego (Algorytmy uczenia nadzorowanego: regresja liniowa, drzewa decyzyjne, algorytmy ensemble (np. Random Forest, Gradient Boosting). Algorytmy uczenia nienadzorowanego: klasteryzacja, analiza składowych głównych (PCA), redukcja wymiarowości. Algorytmy uczenia ze wzmacnieniem: Q-learning, strategie eksploracyjne.)

Głębokie uczenie maszynowe (Sieci neuronowe: architektury, warstwy, funkcje aktywacji. Uczenie głębokie: spłotowe sieci neuronowe (CNN), rekurencyjne sieci neuronowe (RNN). Przetwarzanie obrazów i przetwarzanie języka naturalnego za pomocą głębokich sieci.)

Eksploracja danych i przygotowanie danych (Czyszczenie danych: usuwanie brakujących danych, obsługa wartości odstających. Ekstrakcja cech: wybór odpowiednich cech do modelowania. Inżynieria cech: tworzenie nowych cech na podstawie istniejących danych.)

Walidacja i optymalizacja modeli (Walidacja krzyżowa: ocena wydajności modelu. Hiperparametryzacja: dostrojenie parametrów modelu. Ocena wydajności modeli w kontekście overfittingu i underfittingu.)

Etyka i Odpowiedzialność w Uczeniu Maszynowym (Etyczne kwestie w uczeniu maszynowym: bias, dyskryminacja, prywatność danych. Odpowiedzialność społeczna i etyczna podczas projektowania i wdrażania modeli uczenia maszynowego. Praktyczne wytyczne dotyczące etyki w uczeniu maszynowym i regulacje prawne.)

Tematyka zajęć

Podstawy uczenia maszynowego (Historia i rozwój uczenia maszynowego. Koncepcja zbiorów treningowych, walidacyjnych i testowych. Klasyfikacja problemów uczenia maszynowego: nadzorowane, nienadzorowane i ze wzmacnieniem.)

Metody uczenia maszynowego (Algorytmy uczenia nadzorowanego: regresja liniowa, drzewa decyzyjne, algorytmy ensemble (np. Random Forest, Gradient Boosting). Algorytmy uczenia nienadzorowanego: klasteryzacja, analiza składowych głównych (PCA), redukcja wymiarowości. Algorytmy uczenia ze wzmacnieniem: Q-learning, strategie eksploracyjne.)

Głębokie uczenie maszynowe (Sieci neuronowe: architektury, warstwy, funkcje aktywacji. Uczenie głębokie: spłotowe sieci neuronowe (CNN), rekurencyjne sieci neuronowe (RNN). Przetwarzanie obrazów i przetwarzanie języka naturalnego za pomocą głębokich sieci.)

Eksploracja danych i przygotowanie danych (Czyszczenie danych: usuwanie brakujących danych, obsługa wartości odstających. Ekstrakcja cech: wybór odpowiednich cech do modelowania. Inżynieria cech: tworzenie nowych cech na podstawie istniejących danych.)

Walidacja i optymalizacja modeli (Walidacja krzyżowa: ocena wydajności modelu. Hiperparametryzacja: dostrojenie parametrów modelu. Ocena wydajności modeli w kontekście overfittingu i underfittingu.)

Etyka i Odpowiedzialność w Uczeniu Maszynowym (Etyczne kwestie w uczeniu maszynowym: bias, dyskryminacja, prywatność danych. Odpowiedzialność społeczna i etyczna podczas projektowania i wdrażania modeli uczenia maszynowego. Praktyczne wytyczne dotyczące etyki w uczeniu maszynowym i regulacje prawne.)

Metody dydaktyczne

1. Techniki aktywnego uczenia się: Strategie aktywnego uczenia się, takie jak dyskusje w grupach, rozwiązywanie problemów i studia przypadków, aby aktywnie zaangażować studentów w proces uczenia

się. Zachęcanie do wspólnego uczenia się i interakcji, aby wspierać krytyczne myślenie i stosowanie wiedzy.

2. Integracja technologii: Wykorzystanie narzędzi i platformy technologicznej, aby poprawić jakość nauki. Korzystanie z narzędzi do współpracy online podczas sesji burzy mózgów, wirtualnych symulacji do rozwiązywania problemów oraz prezentacji multimedialnych, aby dostarczać wciągające treści. Ponadto wykorzystanie internetowych forów dyskusyjnych lub systemów zarządzania nauczaniem do asynchronicznego uczenia się i udostępniania zasobów.

3. Uczenie się oparte na przypadkach: Włączenie rzeczywistych studiów przypadków do wykładów i laboratoriów, aby zademonstrować praktyczne zastosowanie kreatywnego myślenia w rozwiązywaniu problemów technicznych. Zachęci to do analizowania i omawiania przypadków, identyfikowania kreatywnych rozwiązań i refleksji nad procesem podejmowania decyzji.

4. Informacja zwrotna i nauczanie od studentów: Wprowadzenie mechanizmów informacji zwrotnej od studentów, w ramach których uczniowie przekazują konstruktywne informacje zwrotne na temat podejść do rozwiązywania problemów lub rozwiązań projektowych swoich rówieśników. Zachęcanie do sesji nauczania studenckiego, podczas których studenci mogą dzielić się swoją wiedzą i kreatywnymi technikami z kolegami.

5. Nauka oparta na projektach: Włączenie nauki opartej na projektach do programu nauczania, w której studenci pracują nad rzeczywistymi problemami lub projektują wyzwania wymagające kreatywnego myślenia. Takie podejście pozwala zastosować swoje umiejętności, przeprowadzić dogłębne badania i opracować innowacyjne rozwiązania poprzez praktyczne, empiryczne uczenie się.

Literatura

Podstawowa:

Christopher M. Bishop, "Pattern Recognition and Machine Learning", Springer, 2006

Trevor Hastie, Robert Tibshirani, Jerome Friedman, "The Elements of Statistical Learning: Data Mining, Inference, and Prediction", Springer, 2009

Ian Goodfellow, Yoshua Bengio, Aaron Courville, "Deep Learning", MIT Press, 2016

Richard S. Sutton, Andrew G. Barto, "Reinforcement Learning: An Introduction", The MIT Press, 2018

Peter Flach, "Machine Learning: The Art and Science of Algorithms that Make Sense of Data", Cambridge University Press, 2012

Uzupełniająca:

J. Redmon and A. Farhadi, "YOLOv4: Optimal Speed and Accuracy of Object Detection," Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020.

A. Rosebrock, "Deep Learning for Computer Vision with Python," 2nd ed., PyImageSearch, 2020.

R. Girshick, "Fast R-CNN," Proceedings of the IEEE International Conference on Computer Vision, 2015.

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	78	3,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	38	1,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	40	1,50