



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Sztuczna inteligencja [N1ZiIP2>SzI]

Przedmiot

Kierunek studiów

Zarządzanie i inżynieria produkcji

Rok/Semestr

3/6

Studia w zakresie (specjalność)

–

Profil studiów

ogólnoakademicki

Poziom studiów

pierwszego stopnia

Język oferowanego przedmiotu

polski

Forma studiów

niestacjonarne

Wymagalność

obieralny

Liczba godzin

Wykład

8

Laboratorium

8

Inne

0

Ćwiczenia

0

Projekty/seminaria

0

Liczba punktów ECTS

2,00

Koordynatorzy

Wykładowcy

Wymagania wstępne

Wiedza podstawowa dotycząca matematyki i informatyki.

Cel przedmiotu

Przekazanie wiedzy związanej z podstawami metod sztucznej inteligencji w tym wiedzy dotyczącej metod uczenia maszynowego i sieci neuronowych.

Przedmiotowe efekty uczenia się

Wiedza:

Student zna pojęcia dotyczące sztucznej inteligencji i uczenia maszynowego. Student ma wiedzę dotyczącą kierunków rozwoju sztucznej inteligencji i jej praktycznych zastosowań. Student zna podstawowe algorytmy dotyczące nienadzorowanych, półnadzorowanych i nadzorowanych metod uczenia maszynowego, uczenia ze wzmacnianiem, działania i zastosowania sztucznych sieci neuronowych.

Umiejętności:

Student potrafi przetwarzać dane, zastosować gotowe narzędzia do uczenia sieci neuronowych oraz innych systemów uczących się w zastosowaniach do grupowania danych, klasyfikacji danych i regresji. Potrafi dokonać wizualizacji, analizy danych i zinterpretować uzyskane wyniki.

Kompetencje społeczne:

Student rozumie rolę informatyzacji w tym eksploracji danych i sztucznej inteligencji we współczesnej gospodarce. Potrafi w niej twórczo uczestniczyć. Student widzi potrzebę ciągłego dokształcania się co wynika z bardzo szybkiego rozwoju metod sztucznej inteligencji.

Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wykład: Zaliczenie na podstawie testu w formie pytań zamkniętych, próg zaliczenia wynosi 50% maksimum punktów.

Przyporządkowanie ocen do przedziałów procentowych wyników: <90-100> bardzo dobry; <80-90> dobry plus; <70-80> dobry; <60-70> dostateczny plus; <50-60> dostateczny; <0-50> niedostateczny.

Laboratorium: Zaliczenie na podstawie sprawozdań z zadań dotyczących analizy danych realizowanej na ćwiczeniach

Przyporządkowanie ocen do przedziałów procentowych wyników: <90-100> bardzo dobry; <80-90> dobry plus; <70-80> dobry; <60-70> dostateczny plus; <50-60> dostateczny; <0-50> niedostateczny.

Treści programowe

Podstawowe zagadnienia teoretyczne dotyczące metod sztucznej inteligencji. Rozwiązywanie praktycznych problemów modelowania, aproksymacji i predykcji z wykorzystaniem metod sztucznej inteligencji

Tematyka zajęć

Wykład.

Ogólne pojęcia dotyczące sztucznej inteligencji i uczenia maszynowego w tym uczenie nadzorowane, półnadzorowane, nienadzorowane, uczenie przez wzmacnianie. Pojęcia klasyfikacji, grupowania, estymacji, predykcji, asocjacji, transformacji danych. Przygotowanie danych do dalszego przetwarzania w tym: środkowanie, normalizacja, standaryzacja, wybielanie, transformacje i redukcje wymiarowości cech (PCA, t-SNE, analiza czynnikowa, analiza ICA, SSA), kodowanie cech kategoryalnych, dyskretyzacja, uzupełnianie brakujących danych. Ogólny algorytm budowy i testowania modelu w tym test hold-out, repeated hold-out, k - krotna walidacja, metoda leave-one-out. Regresja liniowa, nieliniowa, wieloraka i prosta. Funkcje strat, metoda najmniejszych kwadratów, funkcja Hubera i inne. Metody regularyzacji w tym regresja grzbietowa, metoda LASSO, metoda elastycznej siatki. Regresja k-NN, regresja za pomocą drzewa binarnego i lasu losowego. Budowa modelu dla wielu zmiennych zależnych. Ocena modelu regresji. Predykcja wartości i ocena błędów predykcji ex-ante i ex-post. Kompromis pomiędzy wariancją a obciążeniem modelu. Klasyfikacja - ogólne pojęcia. Klasyfikatory binarne i wieloklasowe, metody OvA i OvO, klasyfikacja jedno i wieloetykietowa, klasyfikacja wielowyjściowo- wieloklasowa. Funkcje strat w klasyfikacji. Ocena jakości klasyfikatorów binarnych i niebinarnych. Metody: regresja logistyczna, k-NN, LDA, naiwny klasyfikator Bayesa, klasyfikator SVM, nieliniowy klasyfikator SVM, klasyfikacja za pomocą drzew binarnych i niebinarnych, uczenie zespołowe, bagging, pasting, boosting, lasy losowe, metoda extra-trees. Zastosowanie i rozwój metod bazujących na sztucznych sieciach neuronowych. Budowa sztucznych sieci neuronowych. Głębokie sieci neuronowe. Trenowanie sieci. Widzenie maszynowe. Przetwarzanie języka naturalnego. Sieci GAN. Głębokie uczenie przez wzmacnianie. Regresja z wykorzystaniem sieci neuronowej. Zastosowanie sieci neuronowych do klasyfikacji. Metody grupowania danych: algorytm k- means, algorytm hierarchiczny, grupowanie rozmyte. Miary odległości między wektorami i klastrami. Miary jakości grupowania.

Laboratorium.

1. Wykorzystanie języka Python i modułów Pandas, Numpy, Matplotlib do wczytywania i wstępnego przetwarzania, oczyszczania, dyskretyzacji i wizualizacji danych. Poszukiwanie korelacji. Ilustracja działania skalowania, podstawowych transformacji danych.

2. Zastosowanie modułu Scikit-Learn. Redukcja wymiarowości przestrzeni cech. Wydzielenie zbioru testowego.

3. Uczenie modelu regresji liniowej wielorakiej metodą najmniejszych kwadratów oraz z wykorzystaniem metod regularyzacji. Dobór zmiennych niezależnych do budowy modelu za pomocą zbioru walidacyjnego i sprawdzianu krzyżowego. Ustalanie hiperparametrów modelu za pomocą sprawdzianu krzyżowego. Ocena dopasowania modelu. Ocena modelu za pomocą zbioru testowego - ocena jakości predykcji ex-post.

4. Wykorzystanie sztucznej sieci neuronowej do problemu aproksymacji i predykcji szeregu czasowego. Wykorzystanie biblioteki TensorFlow
5. Budowa klasyfikatorów na przykładzie klasyfikatora k-NN, SVM. Ustalanie hiperparametrów za pomocą sprawdzianu krzyżowego. Dobór sposobu skalowania i transformacji danych na podstawie testów. Klasyfikacja i wizualizacja wyników. Porównanie klasyfikatorów.
6. Zastosowanie drzewa CART oraz lasu losowego do klasyfikacji. Ustalanie hiperparametrów za pomocą sprawdzianu krzyżowego. Klasyfikacja i wizualizacja wyników. Ocena przydatności poszczególnych cech.
7. Klasyfikacja z wykorzystaniem sztucznej sieci neuronowej i modułu Keras. Dobór struktury sieci metodą przeszukiwania siatki. Wykorzystane biblioteki TensorFlow do budowy sieci konwolucyjnej w celu klasyfikacji danych.
8. Grupowanie danych z wykorzystaniem biblioteki Scikit-Learn

Metody dydaktyczne

Wykład: Zajęcia prowadzone w formie prezentacji multimedialnej ilustrowany przykładami w języku Python związanymi z przetwarzaniem i analizą danych z wykorzystaniem metod sztucznej inteligencji w tym wykorzystaniem uczenia maszynowego.

Laboratorium: Zajęcia przy komputerach dotyczące zastosowania sieci neuronowych i innych metod uczenia maszynowego do wybranych zagadnień w oparciu o biblioteki języka Python

Literatura

Podstawowa:

Leszek Rutkowski, Metody i techniki sztucznej inteligencji, PWN, Warszawa, 2012
 Jon Krohn i inni., Uczenie głębokie i sztuczna inteligencja, Helion, Gliwice 2022
 Aurelien Geron, Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow, Helion, Gliwice 2018
 Stanisław Orłowski, Metody i narzędzia eksploracji danych, BTC, Legionowo 2013
 Daniel T. Larose, Odkrywanie wiedzy z danych, PWN, Warszawa 2006
 Wes McKinney, Python w analizie danych, Wydanie II, Helion, Gliwice 2018

Uzupełniająca:

Mark Lutz, Python, wprowadzenie, Helion, Gliwice 2013
 Michael Dawson, Python dla każdego, podstawy programowania, Wydanie III, Helion, Gliwice 2014
 Claus O. Wilke, Podstawy wizualizacji danych, Helion, Gliwice 2020
 Douwe Osinga, Deep Learning, Receptury, Helion, Gliwice 2019
 David Foster, Deep learning i modelowanie generatywne, Helion, Gliwice, 2021
 Michał Białko, Sztuczna inteligencja i elementy hybrydowych systemów ekspertowych, WUPK, Koszalin 2005
 Marcin Szeliga, Data Science i uczenie maszynowe, PWN, Warszawa 2017
 Jacek Kornacki, Jan Ćwik, Statystyczne systemy uczące się, WNT, Warszawa 2005
 Daniel T. Larose, Metody i modele eksploracji danych, PWN, Warszawa 2008
 Mirosław Krzyśko i inni, Systemy uczące się, WNT, Warszawa 2008
 Giuseppe Bonaccorso, Algorytmy uczenia maszynowego, Helion, Gliwice 2019

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	50	2,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	16	0,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwium/egzaminu, wykonanie projektu)	34	1,50