



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Sztuczne sieci neuronowe [S1DSwB1>SSN]

Przedmiot

Kierunek studiów

Data Science w biznesie

Rok/Semestr

3/5

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 posiadać podstawową wiedzę z zakresu programowania w języku Python, w tym programowania obiektowego. Wymagana jest znajomość podstaw uczenia maszynowego, a także umiejętność analizy i przetwarzania danych. Niezbędne są również kompetencje matematyczne, obejmujące analizę oraz matematykę dyskretną, które są kluczowe dla zrozumienia działania sztucznych sieci neuronowych.

Cel przedmiotu

Celem przedmiotu jest zapoznanie studentów z podstawami sztucznych sieci neuronowych, ich architekturą oraz metodami uczenia. Studenci nauczą się implementować i trenować modele neuronowe przy użyciu języka Python oraz dedykowanych bibliotek. Przedmiot kładzie nacisk na praktyczne zastosowania sieci neuronowych w analizie danych

Przedmiotowe efekty uczenia się

Wiedza:

1. Charakteryzuje podstawowe architektury sztucznych sieci neuronowych, w tym perceptron, MLP, CNN i RNN [DSB1_W01].
2. Opisuje matematyczne podstawy sieci neuronowych, w tym funkcje aktywacji, algorytmy uczenia oraz metody optymalizacji [DSB1_W02].
3. Wyjaśnia proces regularizacji i przygotowania danych wejściowych do modeli sieci neuronowych [DSB1_W03].
4. Charakteryzuje zastosowania sieci neuronowych w analizie obrazów, dźwięku i przetwarzaniu języka naturalnego [DSB1_W05].

Umiejętności:

1. Dobiera odpowiednie metody optymalizacji i regularizacji w procesie trenowania sieci neuronowych [DSB1_U02].
2. Projektuje i implementuje modele sieci neuronowych w Pythonie, uwzględniając ich zastosowanie do różnych problemów analizy danych [DSB1_U03].
3. Tworzy proces analizy danych dla uczenia modeli, przygotowując odpowiednie struktury wejściowe oraz stosując transfer learning i fine-tuning modeli [DSB1_U08].
4. Wykorzystuje narzędzia uczenia maszynowego i deep learningu, implementując sieci neuronowe w praktycznych zadaniach biznesowych i analitycznych [DSB1_U09].

Kompetencje społeczne:

1. Krytycznie analizuje własną wiedzę i umiejętności w zakresie sieci neuronowych, dążąc do ich rozwoju i aktualizacji w kontekście nowych technologii [DSB1_K01].
2. Podejmuje inicjatywy w zakresie wdrażania i testowania modeli deep learningowych w aplikacjach biznesowych i badawczych [DSB1_K04].

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

Przedmiot obejmuje wprowadzenie do sztucznych sieci neuronowych, ich matematycznych podstaw oraz algorytmów uczenia. Studenci poznają perceptron, wielowarstwowe sieci neuronowe (MLP) oraz zaawansowane architektury, takie jak konwolucyjne (CNN) i rekurencyjne sieci neuronowe (RNN), w tym modele LSTM i GRU. Kurs obejmuje techniki optymalizacji, regularizacji oraz przetwarzania danych wejściowych. Omówione zostaną również zastosowania sieci neuronowych w analizie obrazów, dźwięku oraz przetwarzaniu języka naturalnego (NLP). Studenci zapoznają się z transfer learning, uczeniem nienadzorowanym oraz interpretowalnością modeli.

Tematyka zajęć

Wprowadzenie do sztucznych sieci neuronowych
Matematyczne podstawy sieci neuronowych
Perceptron i jego ograniczenia
Wielowarstwowe sieci neuronowe (MLP)
Algorytmy optymalizacyjne w uczeniu sieci
Regularizacja w sieciach neuronowych
Przygotowanie i przetwarzanie danych wejściowych
Implementacja podstawowej sieci neuronowej w Pythonie

Konwolucyjne sieci neuronowe (CNN)
 Rekurencyjne sieci neuronowe (RNN)
 Długoterminowa pamięć (LSTM) i sieci GRU
 Zastosowanie sieci neuronowych w analizie obrazów i dźwięku
 Transfer learning i fine-tuning modeli
 Uczenie nienadzorowane w sieciach neuronowych
 Sieci neuronowe do przetwarzania języka naturalnego (NLP)
 Wydajność i skalowalność sieci neuronowych
 Modele atencyjne i deep reinforcement learning
 Interpretowalność i wyjaśnialność sieci neuronowych
 Wyzwania związane z sieciami neuronowymi

Metody dydaktyczne

Wykład - prezentacja multimedialna oraz pisanie kodu bezpośrednio w wybranym IDE programistycznym lub środowisku do analizy danych
 Laboratoria - ćwiczenia w wybranym IDE programistycznym lub środowisku do analizy danych (np. Pycharm lub Google Colaboratory)

Literatura

Podstawowa:

Krzywicki, T. (2022). Sztuczne sieci neuronowe i uczenie głębokie: systemy uczące się. Wydawnictwo Uniwersytetu Warmińsko-Mazurskiego
 Rashka, S., Mirjalili, V. (2021). Python. Machine learning i deep learning. Biblioteki scikit-learn i TensorFlow 2

Uzupełniająca:

Kirk, M., (2018). Python w uczeniu maszynowym. Podejście sterowane testami, APN Promise
 Kosiński, R.A. (2017), Sztuczne sieci neuronowe, Wydawnictwo Naukowe PWN
 Zocca, V., Spacagna, G., Slater, D., Roelants, P. (2018). Deep Learning. Uczenie głębokie z językiem Python. Sztuczna inteligencja i sieci neuronowe, Helion

Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	125	5,00
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	60	2,50
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwίων/egzaminu, wykonanie projektu)	65	2,50