



## 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

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 kolokwium/egzaminu, wykonanie projektu)	65	2,50