



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Uczenie maszynowe dla Internetu Przedmiotów

### Przedmiot

Kierunek studiów

Informatyka

Studia w zakresie (specjalność)

Aplikacje mobilne i wbudowane dla internetu przedmiotów

Poziom studiów

drugiego stopnia

Forma studiów

niestacjonarne

Rok/semestr

2/3

Profil studiów

ogólnoakademicki

Język oferowanego przedmiotu

polski

Wymagalność

obieralny

### Liczba godzin

Wykład

16

Ćwiczenia

0

Laboratoria

16

Projekty/seminaria

0

Inne (np. online)

0

### Liczba punktów ECTS

3

### Wykładowcy

Odpowiedzialny za przedmiot/wykładowca:

dr inż. Jędrzej Potoniec

Odpowiedzialny za przedmiot/wykładowca:

dr inż. Tomasz Łukaszewski

### Wymagania wstępne

Student rozpoczynający ten przedmiot powinien posiadać podstawową wiedzę w zakresie rachunku prawdopodobieństwa i statystyki, algebry liniowej, analizy matematycznej oraz sztucznej inteligencji. Powinien również posiadać umiejętność pozyskiwania informacji ze wskazanych źródeł oraz mieć gotowość do podjęcia współpracy w ramach zespołu.

### Cel przedmiotu

Wprowadzenie do analizy danych i uczenia maszynowego z uwzględnieniem dużych wolumenów danych. Poznanie wybranych problemów analizy danych i metod ich rozwiązywania:



1. Przekazanie studentom podstawowej wiedzy o analizie danych, w szczególności dotyczącej nadzorowanego uczenia.
2. Rozwijanie u studentów umiejętności doboru odpowiednich metod rozwiązania problemów analizy danych.
3. Zapoznanie studentów z metodologią praktycznego rozwiązywania problemów analizy danych oraz etapami projektu analizy danych.

### **Przedmiotowe efekty uczenia się**

#### Wiedza

1. Ma wiedzę na temat wstępnej analizy i przetwarzania danych na potrzeby eksperymentów uczenia maszynowego.
2. Ma wiedzę na temat algorytmów nadzorowanego uczenia maszynowego.
3. Ma wiedzę na temat współczesnych sieci neuronowych.

#### Umiejętności

1. Potrafi dokonać wstępnej analizy danych i ich przetwarzania pod kątem przygotowania eksperymentu uczenia maszynowego w jednym z powszechnie wykorzystywanych narzędzi.
2. Potrafi wykorzystać biblioteki implementujące algorytmy uczenia maszynowego do przeprowadzanie eksperymentu.
3. Potrafi wykorzystać biblioteki implementujące komponenty sieci neuronowych do skonstruowania sieci neuronowej i przeprowadzenia eksperymentu.

#### Kompetencje społeczne

1. Rozumie, że wiedza związana z analizą danych i uczeniem maszynowym bardzo szybko stają się przestarzałe.
2. Rozumie znaczenie wykorzystywania najnowszej wiedzy z zakresu informatyki w rozwiązywaniu problemów badawczych i praktycznych

### **Metody weryfikacji efektów uczenia się i kryteria oceny**

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

Wiedza nabyta w ramach wykładu jest weryfikowana na podstawie odpowiedzi na pytania dotyczące materiału omówionego na wykładu (np. sprawdziany wejściowe, quizy online).

Umiejętności nabyte w ramach laboratorium są weryfikowane przez ocenę wykonania przez studenta przydzielonych zadań o charakterze praktycznym.

### **Treści programowe**

Wykład: wstępna analiza i przetwarzanie danych, uczenie nadzorowane (wybrane algorytmy regresji i klasyfikacji), ewaluacja modeli, regularyzacja. Wybrane zagadnienia optymalizacji gradientowej, w pełni połączone, splotowe i rekurencyjne sieci neuronowe.



W ramach laboratorium studenci poznają zagadnienia przedstawione na wykładzie od strony praktycznej przez realizację zadań programistycznych polegających na samodzielnej implementacji w języku Python wskazanych algorytmów bądź wykorzystanie gotowych bibliotek (numpy, scikit-learn, matplotlib, PyTorch) do skonstruowania eksperymentów uczenia maszynowego.

### Metody dydaktyczne

Wykład: prezentacja multimedialna, ilustrowana przykładami podawanymi na tablicy; dyskusja.

Laboratorium: metoda problemowa, dyskusja, wykonywanie zadań podanych przez prowadzącego - ćwiczenia praktyczne.

### Literatura

Podstawowa

Aurélien Géron, Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow, Helion, 2018

Uzupełniająca

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

Dostępne on-line: <https://www.deeplearningbook.org/>

### Bilans nakładu pracy przeciętnego studenta

	Godzin	ECTS
Łączny nakład pracy	75	3
Zajęcia wymagające bezpośredniego kontaktu z nauczycielem	32	1,25
Praca własna studenta (studia literaturowe, samodzielne dokończenie zadań laboratoryjnych, przygotowanie do zajęć laboratoryjnych, przygotowanie do testu) <sup>1</sup>	43	1,75

<sup>1</sup> niepotrzebne skreślić lub dopisać inne czynności

