



## KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wprowadzenie do sieci neuronowych i uczenia maszynowego [S1Inf1>SNUM]

### Przedmiot

Kierunek studiów  
Informatyka

Rok/Semestr  
4/7

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  
30

Inne  
0

Ćwiczenia  
0

Projekty/seminaria  
0

### Liczba punktów ECTS

4,00

### Koordynatorzy

prof. dr hab. inż. Krzysztof Krawiec  
krzysztof.krawiec@put.poznan.pl

prof. dr hab. inż. Jerzy Stefanowski  
jerzy.stefanowski@put.poznan.pl

### Wykładowcy

### Wymagania wstępne

Student(ka) rozpoczynający ten przedmiot powinien posiadać wiedzę z zakresu sztucznej inteligencji, rachunku prawdopodobieństwa, algebry liniowej, statystyki matematycznej. Powinien także posiadać podstawowe umiejętności programistyczne (wykorzystanie języka Python i wybranych bibliotek), umiejętność pozyskiwania informacji ze źródeł literaturowych, a także potrafić współpracować w grupie podczas realizacji zadań.

### Cel przedmiotu

Wykład ma za zadanie przedstawić studentom teoretyczne aspekty wybranych algorytmów uczenia maszynowego, w tym sieci neuronowych (dokładny opis poruszanych zagadnień można znaleźć w sekcji "Treści programowe"). Laboratoria poświęcone są praktycznemu wykorzystaniu metod przedstawionych na wykładzie. Studenci wykorzystują gotowe narzędzia (WEKA, sklearn), a także w przypadku niektórych algorytmów uczenia implementują je od podstaw.

### Przedmiotowe efekty uczenia się

#### Wiedza:

1. Ma uporządkowaną, podbudowaną teoretycznie wiedzę w zakresie systemów uczenia maszynowego, potrafi analizować i opisywać ich funkcjonowanie oraz rozumie zakres ich zastosowań - [K1st\_W4]
2. Ma wiedzę o istotnych kierunkach rozwoju i najważniejszych osiągnięciach systemów maszynowego uczenia się i sztucznych sieci neuronowych - [K1st\_W5]
3. Zna podstawowe techniki, metody oraz narzędzia wykorzystywane w procesie rozwiązywania zadań informatycznych korzystające z metod uczenia maszynowego - [K1st\_W7]

#### Umiejętności:

1. Potrafi zidentyfikować specjalistyczną wiedzę przedmiotową niezbędną do realizacji zadania i uzasadnić jej użycie - [K1st\_U1]
2. Potrafi opracować i zaimplementować rozwiązanie problemu klasyfikacji lub grupowania przy użyciu metod uczenia maszynowego, oraz dokonać ewaluacji istotności uzyskanych wyników - [K1st\_U3]
3. Potrafi wykorzystać odpowiednie dla specyfiki problemu metody uczenia maszynowego do rozwiązywania zadań informatycznych - [K1st\_U4]
4. Potrafi wykorzystać wiedzę z zakresu systemów uczenia maszynowego by zaprojektować złożoną aplikację wykorzystującą uczenie maszynowe jako podsystem - [K1st\_U10]
6. Posiada umiejętność praktycznego stosowania algorytmów uczenia maszynowego rozwiązywaniu zadań programistycznych - [K1st\_U11]
7. Potrafi uzupełniać i pogłębiać we własnym zakresie swoją wiedzę z zakresu uczenia maszynowego - [K1st\_U19]

#### Kompetencje społeczne:

1. Rozumie potrzebę stałego wzbogacania swojej wiedzy oraz rozwijania swoich umiejętności w zakresie narzędzi i metod uczenia maszynowego - [K1st\_K1]
2. Jest świadom potencjalnej roli jaką mogą odegrać systemy uczenia maszynowego w przemianach o charakterze społecznym i gospodarczym - [K1st\_K2]
3. Potrafi zidentyfikować możliwości wykorzystania poznanych metod uczenia maszynowego w obszarach zastosowań informatyki związanych z konstruowaniem użytecznego oprogramowania - [K1st\_K3]

### Metody weryfikacji efektów uczenia się i kryteria oceny

Efekty uczenia się przedstawione wyżej weryfikowane są w następujący sposób:

#### Ocena formująca:

- a) Wykład: na podstawie odpowiedzi na pytania dotyczące materiału omawianego na wykładach.
- b) Laboratoria: na podstawie oceny bieżącego postępu realizacji zadań.

#### Ocena podsumowująca:

- a) Wykład: na podstawie testu obejmującego materiał omówiony na wykładzie. By uzyskać pozytywną ocenę z wykładu student(ka) musi uzyskać przynajmniej połowę punktów możliwych do uzyskania z testu.
- b) Laboratoria: po każdym zajęciach studenci mają do zrealizowania zadanie domowe, za które można dostać pewną liczbę punktów. By uzyskać pozytywną ocenę na koniec student(ka) musi uzyskać przynajmniej połowę możliwej do uzyskania sumy punktów.

### Treści programowe

Wybrane metody z zakresu maszynowego uczenia się (ang. machine learning):

- 1) Nadzorowane uczenie się: kryteria oceny systemów klasyfikujących, miary oraz metody ich eksperymentalnej oceny. Zjawisko przeuczenia i sposoby jego unikania. Indukcja drzew decyzyjnych. Wybrane aspekty praktycznego przygotowania reprezentacji przykładów (przetwarzanie wstępne, inżynieria cech, wybory podzbiorów przykładów uczących). Algorytm k-NN. Sztuczne sieci neuronowe, algorytm wstecznej propagacji błędów, sieci konwolucyjne.
- 2) Algorytmy uczenia nienadzorowanego: gęstościowe algorytmy, k-means, grupowanie hierarchiczne.

### Tematyka zajęć

Wybrane metody z zakresu maszynowego uczenia się (ang. machine learning):

- 1) Nadzorowane uczenie się: kryteria oceny systemów klasyfikujących, miary oraz metody ich eksperymentalnej oceny. Zjawisko przeuczenia i sposoby jego unikania. Indukcja drzew decyzyjnych. Wybrane aspekty praktycznego przygotowania reprezentacji przykładów (przetwarzanie

wstępne,  
inżynieria cech, wybory podzbiorów przykładów uczących). Algorytm k-NN. Sztuczne sieci neuronowe, algorytm wstecznej propagacji błędów, sieci konwolucyjne.  
2) Algorytmy uczenia nienadzorowanego: gęstościowe algorytmy, k-means, grupowanie hierarchiczne.

## Metody dydaktyczne

Wykład: prezentacja multimedialna, prezentacja ilustrowana przykładami, rozwiązywanie prostych zadań, demonstracja użycia wybranego oprogramowania.

Laboratoria: rozwiązywanie zadań, ćwiczenia praktyczne wraz z ograniczonym programowaniem wykorzystującym wskazane biblioteki, wykonywanie eksperymentów, studia przypadków, dyskusja.

## Literatura

Podstawowa:

1. Machine Learning: The Art and Science of Algorithms that Make Sense of Data, P.Flach, Cambridge University Press, 2012.
2. Pattern recognition and machine learning. Ch. Bishop, Springer, 2006.
3. Introduction to machine learning. E. Alpaydin, MIT Press (3rd ed.), 2014.

Uzupełniająca:

1. Statystyczne systemy uczące się. J.Koronacki, J.Ćwik, EXIT, Warszawa 2008.
2. Uczenie maszynowe i sieci neuronowe, K.Krawiec, J.Stefanowski, Wydawnictwo PP, Poznań, 2004 .

## Bilans nakładu pracy przeciętnego studenta

|  | Godzin | ECTS |
|--|--------|------|
| Łączny nakład pracy  | 100    | 4,00 |
| 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) | 40     | 1,50 |