



KARTA OPISU PRZEDMIOTU - SYLABUS

Nazwa przedmiotu

Wprowadzenie do sieci neuronowych i uczenia maszynowego [N1Inf1>SNUM]

Przedmiot

Kierunek studiów
Informatyka

Rok/Semestr
4/8

Studia w zakresie (specjalność)
–

Profil studiów
ogólnoakademicki

Poziom studiów
pierwszego stopnia

Język oferowanego przedmiotu
polski

Forma studiów
niestacjonarne

Wymagalność
obligatoryjny

Liczba godzin

Wykład
20

Laboratorium
20

Inne
0

Ćwiczenia
0

Projekty/seminaria
0

Liczba punktów ECTS

4,00

Koordynatorzy

dr inż. Iwo Błądek
iwo.bladek@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, tensorflow), 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

Program modułu obejmuje następujące zagadnienia:

- 1) Zadanie uczenia maszynowego i jego praktyczne zastosowania
- 2) Reprezentacja i wstępne przetwarzanie danych uczących
- 3) Ocena jakości klasyfikatorów i zjawisko przeuczenia
- 4) Przekleństwo wymiarowości i metody selekcji atrybutów
- 5) Wybrane algorytmy uczenia nadzorowanego
- 6) Wybrane algorytmy uczenia nienadzorowanego
- 7) Wprowadzenie do sztucznych sieci neuronowych

Tematyka zajęć

Program wykładu obejmuje następujące zagadnienia:

- 1) Zadanie uczenia maszynowego i jego praktyczne zastosowania
- 2) Reprezentacja i wstępne przetwarzanie danych uczących

- normalizacja danych
- radzenie sobie z brakującymi wartościami
- 3) Ocena jakości klasyfikatorów i zjawisko przeuczenia
 - trafność klasyfikacji, macierz pomyłek, precyzja, wrażliwość, specyficzność
 - zagadnienie oceny klasyfikatora dla danych niezbalansowanych
- 4) Przekleństwo wymiarowości i metody selekcji atrybutów
 - metody typu filter
 - metody typu wrapper
 - podstawy ekstrakcji cech
- 5) Wybrane algorytmy uczenia nadzorowanego
 - uczenie drzew decyzyjnych: ID3, C4.5, pre- i post-pruning drzew decyzyjnych, obsługa wartości ciągłych
 - k najbliższych sąsiadów (k-NN)
- 6) Wybrane algorytmy uczenia nienadzorowanego
 - k-średnich (k-means)
 - grupowanie gęstościowe: DBSCAN
 - grupowanie hierarchiczne
- 7) Wprowadzenie do sztucznych sieci neuronowych
 - definicja neuronu i sieci neuronowej, rodzaje funkcji aktywacji
 - algorytm spadku gradientu, wsteczna propagacja błędów, algorytm stochastycznego spadku gradientu
 - podstawy regularyzacji
 - sieci konwolucyjne
 - autoenkodery

Program laboratorium oparty jest na praktycznym ćwiczeniu zagadnień omawianych na wykładach, i obejmuje następujące zagadnienia:

- 1) Środowisko WEKA
- 2) Biblioteki numpy i sklearn (Python)
- 3) Algorytmy indukcji drzew decyzyjnych ID3 i C4.5
- 4) Algorytm k najbliższych sąsiadów (k-NN)
- 5) Algorytm k-średnich (k-means)
- 6) Biblioteka tensorflow (Python)
- 7) Implementacja i uczenie sieci neuronowych, w tym sieci konwolucyjnych i autoenkoderów

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	40	2,00
Praca własna studenta (studia literaturowe, przygotowanie do zajęć laboratoryjnych/ćwiczeń, przygotowanie do kolokwiiw/egzaminu, wykonanie projektu)	60	2,00