

I. Informacje ogólne

1. Nazwa zajęć/przedmiotu:

Uczenie maszynowe i big data

2. Kod zajęć/przedmiotu:

3. Rodzaj zajęć/przedmiotu (obowiązkowy lub fakultatywny): **fakultatywny**

4. Kierunek studiów: **Biologia i zdrowie człowieka, studia stacjonarne**

5. Poziom studiów (I lub II stopień, jednolite studia magisterskie): **II stopień**

6. Profil studiów (ogólnoakademicki / praktyczny): **ogólnoakademicki**

7. Rok studiów (jeśli obowiązuje): **II**

8. Rodzaje zajęć i liczba godzin (np.: 15 h W, 30 h CW):

Konwersatoria: 30 godzin

9. Liczba punktów ECTS: **3**

10. Imię, nazwisko, tytuł/stopień naukowy, adres e-mail prowadzącego zajęcia

dr hab. Marek Żywicki (marek.zywicki@amu.edu.pl)

11. Język wykładowy: **polski**

12. Zajęcia/przedmiot prowadzone zdalnie (e-learning) (tak [częściowo/w całości] / nie): **nie**

II. Informacje szczegółowe

1. Cele zajęć/przedmiotu

Celem zajęć jest zapoznanie studentów z uczeniem maszynowym, nową dziedziną badań na styku statystyki, sztucznej inteligencji i informatyki, będącej ważnym elementem rozwijającej się dziedziny analityki wielkich zbiorów danych. Celem tych zajęć jest zapoznanie z podstawowymi pojęciami, metodami i teorią uczenia maszynowego.

Na zajęciach omówione zostaną także różne przykłady zastosowania praktycznego uczenia maszynowego w analizie danych. Kurs będzie zorientowany na projekt, z naciskiem na wykorzystanie algorytmów uczenia maszynowego stosowanych w rzeczywistych problemach, wraz z krótkimi raportami opisującymi wyniki.

2. Wymagania wstępne w zakresie wiedzy, umiejętności oraz kompetencji społecznych (jeśli obowiązują)

Wymagana jest wiedza z zakresu środowiska LINUX i znajomość języków skryptowych

3. Efekty uczenia się (EU) dla zajęć i odniesienie do efektów uczenia się (EK) dla kierunku studiów

Symbol EU dla zajęć/przedmiotu	Po zakończeniu zajęć i potwierdzeniu osiągnięcia EU student/ka:	Symbole EK dla kierunku studiów
Efekt_01	Rozumie podstawowe zagadnienia i wyzwania związane z uczeniem maszynowym: dane, wybór modelu, złożoność modelu itp.	K_W01, K_U02, K_U03
Efekt_02	Zna mocne i słabe strony popularnych metod uczenia maszynowego.	K_W01, K_U02, K_U03
Efekt_03	Dostrzega podstawowe zależności i różnice pomiędzy algorytmami uczenia maszynowego	K_W01, K_U02, K_U03
Efekt_04	Potrafi zastosować algorytmy uczenia maszynowego w analizie dużych zbiorów danych	K_W01, K_U02, K_U03, K_U08, K_K01, K_K03
Efekt_06	Potrafi korzystać z bezpłatnych narzędzi / bibliotek oprogramowania typu open source do implementacji algorytmów uczenia maszynowego.	K_W01, K_U02, K_U03, K_U08, K_K01, K_K03
Efekt_07	Rozumie konsekwencje etyczne działania systemów uczenia maszynowego	K_K04

4. Treści programowe zapewniające uzyskanie efektów uczenia się (EU) z odniesieniem do odpowiednich efektów uczenia się (EU) dla zajęć/przedmiotu

Treści programowe dla zajęć/przedmiotu	Symbol EU dla zajęć/przedmiotu
Zagadnienia i wyzwania związane z uczeniem maszynowym: dane, wybór modelu, złożoność modelu, mocne i słabe strony popularnych metod uczenia maszynowego, zależności matematyczne pomiędzy algorytmami, itp.	Efekt_01, Efekt_02, Efekt_03, Efekt_04, Efekt_05, Efekt_06,
Podstawowe modele dyskryminacji i regresji, liniowej i nieliniowej; klasyfikatory i klasteryzacja	Efekt_01, Efekt_02, Efekt_03, Efekt_04, Efekt_05, Efekt_06,
Zastosowanie metod uczenia maszynowego w przykładowych problemach praktycznych z obszaru biologii i zdrowia człowieka	Efekt_03, Efekt_04, Efekt_05, Efekt_06, Efekt_07
Narzędzia i biblioteki oprogramowania typu open source do implementacji algorytmów uczenia maszynowego.	Efekt_03, Efekt_04, Efekt_05, Efekt_06,

5. Zalecana literatura

Wydawnictwa książkowe (wybrane fragmenty wskazane przez prowadzącego)
D. Larose, Odkrywanie wiedzy z danych, PWN, 2006

6. Informacja o tym, gdzie można zapoznać się z materiałami do zajęć, instrukcjami do laboratorium, itp.

III. Informacje dodatkowe

1. Metody i formy prowadzenia zajęć umożliwiające osiągnięcie założonych EK (proszę wskazać z proponowanych metod właściwe dla opisywanego modułu lub/i zaproponować inne)

Metody i formy prowadzenia zajęć	
Wykład z prezentacją multimedialną wybranych zagadnień	
Wykład konwersatoryjny	
Wykład problemowy	
Dyskusja	
Praca z tekstem	
Metoda analizy przypadków	
Uczenie problemowe (Problem-based learning)	
Gra dydaktyczna/symulacyjna	
Rozwiązywanie zadań (np.: obliczeniowych, artystycznych, praktycznych)	TAK
Metoda ćwiczeniowa	TAK
Metoda laboratoryjna	
Metoda badawcza (dociekania naukowego)	
Metoda warsztatowa	TAK
Metoda projektu	TAK
Pokaz i obserwacja	
Demonstracje dźwiękowe i/lub video	
Metody aktywizujące (np.: „burza mózgów”, technika analizy SWOT, technika drzewka decyzyjnego, metoda „kuli śniegowej”, konstruowanie „map myśli”)	
Praca w grupach	TAK

2. Sposoby oceniania stopnia osiągnięcia EK (proszę wskazać z proponowanych sposobów właściwe dla danego EK lub/i zaproponować inne)

Sposoby oceniania	Symbole EK dla modułu zajęć/przedmiotu
-------------------	--

	EK_1	EK_2	EK_3	EK_4	EK_5	EK_6	EK_7
Egzamin pisemny							
Egzamin ustny							
Egzamin z „otwartą książką”							
Kolokwium pisemne							
Kolokwium ustne							
Test							
Projekt	TAK	TAK	TAK	TAK	TAK	TAK	TAK
Esej							
Raport	TAK	TAK	TAK	TAK	TAK	TAK	TAK
Prezentacja multimedialna							
Egzamin praktyczny (obserwacja wykonawstwa)							
Portfolio							

3. Nakład pracy studenta i punkty ECTS

Forma aktywności	Średnia liczba godzin na zrealizowanie aktywności	
	studia stacjonarne	studia niestacjonarne
Godziny zajęć (wg planu studiów) z nauczycielem	30	0
Praca własna studenta		
Przygotowanie do zajęć	15	0
Czytanie wskazanej literatury		0
Przygotowanie pracy pisemnej, raportu, prezentacji, demonstracji, itp.	5	0
Przygotowanie projektu	25	0
Przygotowanie pracy semestralnej		0
Przygotowanie do egzaminu / zaliczenia		0
SUMA GODZIN	75	0
LICZBA PUNKTÓW ECTS DLA MODUŁU ZAJĘĆ/PRZEDMIOTU	3	0

4. Kryteria oceniania wg skali stosowanej w UAM

- bardzo dobry (bdb; 5,0): Student zna i swobodnie korzysta z metod uczenia maszynowego do analizy dużych zbiorów danych.
- dobry plus (+db; 4,5): Student zna i potrafi skorzystać z metod uczenia maszynowego do analizy dużych zbiorów danych.
- dobry (db; 4,0): Student zna najważniejsze metody uczenia maszynowego i potrafi z nich skorzystać do analizy dużych zbiorów danych.
- dostateczny plus (+dst; 3,5): student zna sztanarowe metody uczenia maszynowego i potrafi z nich skorzystać z wykorzystaniem pomocy literaturowych.
- dostateczny (dst; 3,0): Student potrafi w ograniczonym zakresie zna metody uczenia maszynowego i potrafi z nich korzystać jedynie w ograniczonym stopniu.
- niedostateczny (ndst; 2,0): Student nie zna i nie potrafi korzystać nawet z podstawowych metod uczenia maszynowego.