

Syllabus	
Course name	Fundamentals of Machine Learning
Course version	1
A. Location of the course in education system	
Level of education	2
Degree level	MSc
A form of study	
Fields of study	Management
Profile of study	General academic
Specialization	
Administrating unit	Faculty of Management
Coordinatore	Andrzej Wodecki, PhD, DSc
B. General course description	
Block of subjects	
Group of courses	
Level	Advanced
Status	Elective
Language	English
Semestr	2/3
Academic year	2022/2023
Initial student requirements	Technical knowledge to MS Excel middle level and methods of data analysis
Numer of students	- od 15 osób do limitu miejsc w sali audytoryjnej (wykład) - od 8 osób do limitu miejsc w sali laboratoryjnej (laboratorium)
C. Learning outcomes and teaching methods	
Objective of the course	Application of machine learning in Management
Assessment methods	A. Wykład: 1. <i>Ocena formatywna</i> : na podstawie oceny z Laboratorium 2. <i>Ocena sumatywna</i> : na podstawie oceny z Laboratorium C. Laboratorium: 1. <i>Ocena formatywna</i> : projekt, prezentacja 2. <i>Ocena sumatywna</i> : oceny projektu i prezentacji E. Końcowa ocena z przedmiotu: Suma ważona ocen projektu (80%) i prezentacji (20%)
Learning outcomes	Patrz Tabela 1
Form of classes and weekly dimension (semester dimension) [Hours]	Lecture 2 (15) Exercise 0 Labolatory 2 (15) Project 0

Content	<p>Lecture:</p> <ol style="list-style-type: none"> 1. Introduction 2. Proces Data Science <ol style="list-style-type: none"> a. Zrozumienie i sformułowanie problemu b. Pozyskiwanie danych c. Przygotowanie danych do modelowania d. Ocena i poprawa jakości modeli ML e. Komunikacja wyników i przekazanie modelu do wdrożenia produkcyjnego 3. Types of machine learning: <ol style="list-style-type: none"> a. Nauczanie nadzorowane b. Nauczanie nie nadzorowane c. Nauczanie ze wzmocnieniem d. Inne modele uczenie maszynowego 4. Crucial methods and algorithms in machine learning: <ol style="list-style-type: none"> a. Regresja: typowe zastosowania, najważniejsze algorytmy i metody oceny ich efektywności b. Klasyfikacja: typowe zastosowania, najważniejsze algorytmy i metody oceny ich efektywności c. Grupowanie: typowe zastosowania, najważniejsze algorytmy i metody oceny ich efektywności d. Podnoszenie jakości modeli uczenia maszynowego (tuning hiperparametrów, modele zespołowe, etc.) 5. Machine learning in practice <ol style="list-style-type: none"> a. Dobór algorytmu dla danego problemu biznesowego: ogólny schemat postępowania b. Infrastruktura niezbędna do realizacji projektów na różnych etapach analizy danych, modelowania i wdrożenia produkcyjnego c. Wyzwania i czynniki ryzyka implementacji projektów uczenia maszynowego w organizacji 6. Development trends of ML/AI <p>Laboratory:</p> <p>W ramach laboratorium studenci wykorzystają wybraną metodę uczenia maszynowego do rozwiązania konkretnego problemu z zakresu zarządzania. Prace podzielone zostaną na następujące etapy:</p> <ol style="list-style-type: none"> 1. Identyfikacja problemu biznesowego, pogłębiona analiza kontekstu i sformułowanie problemu 2. Pozyskanie i przegląd danych źródłowych 3. Przygotowanie danych: czyszczenie, zmiana kształtu, wzbogacenie, dostosowanie do specyfiki modelu 4. Modelowanie danych: określenie modelu bazowego, wybór różnych modeli, modelowanie, ocena, udoskonalenie i wybór najlepszego 5. Komunikacja wyników prac (przygotowanie scenariusza i odpowiednich wizualizacji). <p>Na koniec zajęć każda z grup przedstawi prezentację swojego projektu.</p>
Learning outcomes evaluation	Patrz Tabela 1
Exam	Nie

Bibliography	<p><i>Basic:</i></p> <ol style="list-style-type: none"> 1. Wodecki A., 2018. <i>Sztuczna inteligencja w kreowaniu wartości organizacji</i>, Kraków: Edu-Libri 2. Szeliga M., 2017, <i>Data Science i uczenie maszynowe</i>, Warszawa: PWN 3. Géron A., 2020. <i>Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow : concepts, tools, and techniques to build intelligent systems</i>, O'Reilly, <p><i>Supplementary:</i></p> <ol style="list-style-type: none"> 1. Boschetti A., Massaron L., 2017. <i>Python. Podstawy nauki o danych. Wydanie II</i>, Gliwice: Helion
Objective of the course	www.olaf.wz.pw.edu.pl
D. Nakład pracy studenta	
ECTS credits	2 ECTS
ECTS credits delivered by teacher direct participation	1 ECTS
ECTS credits delivered by without teacher direct participation	1 ECTS
E. Informacje dodatkowe	
Metody, techniki, narzędzia wykorzystywane w trakcie prowadzenia zajęć	<p>Wykład: <i>Metody dydaktyczne:</i> wykład informacyjny, problemowy i konwersatoryjny <i>Narzędzia i techniki I-K:</i> prezentacja multimedialna, platforma Moodle, poczta elektroniczna; w formie zdalnej: aplikacja MS Teams</p> <p>Ćwiczenia: <i>Metody dydaktyczne:</i> klasyczna metoda problemowa, metoda projektu <i>Narzędzia i techniki I-K:</i> narzędzia: oprogramowanie wspomagające obliczenia (np. MS Excel), platforma Moodle, poczta elektroniczna; w formie zdalnej: aplikacja MS Teams</p> <p>klasyczna metoda problemowa, metoda projektu</p>
Uwagi	-
Data ostatniej aktualizacji	02.02.2022

Tabela 1

Profil ogólnoakademicki		
Efekty przedmiotowe		Odniesienie do efektów kierunkowych
Wiedza		
Efekt:	Student ma świadomość na najważniejszych wyzwaniach związanych z analizą i drążeniem danych	Z2_WG1
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt:	Student zna różne sposoby wykorzystania metod uczenia maszynowego i sztucznej inteligencji do usprawnienia procesów biznesowych organizacji	Z2_WG4
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt:	Student zna najważniejsze metody i algorytmy uczenia maszynowego	Z2_WG4
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	

Umiejętności		
Efekt:	Potrafi pozyskać dane z różnych, cyfrowych źródeł zewnętrznych	Z2_UW1
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt:	Student potrafi zaprojektować uzasadnienie biznesowe dla projektu wykorzystującego uczenie maszynowe i sztuczną inteligencję	Z2_UW1
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt;	Absolwent potrafi wykorzystywać posiadaną wiedzę do posługiwania się językiem obcym na poziomie B2+ Europejskiego Systemu Opisu Kształcenia Językowego oraz terminologią z zakresu Business English zakresu uczenia maszynowego	Z2_UW8
Weryfikacja:	Laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt:	Student potrafi zaplanować projekt wdrożenia rozwiązania ML/AI w organizacji	Z2_UW1
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Kompetencje Społeczne		
Efekt:	Jest gotów do współpracy w zespole nad zaawansowanymi zagadnieniami analitycznymi z zakresu uczenia maszynowego	Z2_KO6
Weryfikacja:	Wykład i laboratorium- dokumentacja i prezentacja projektu końcowego	
Efekt:	Absolwent jest gotów do ustawicznego pogłębiania swoich umiejętności językowych z zakresu uczenia maszynowego oraz samodzielnego wykorzystywania w tym celu dostępnych mu źródeł i ich krytycznej oceny pod względem przydatności do swojej pracy zawodowej.	Z2_KK2
Weryfikacja:	Laboratorium- dokumentacja i prezentacja projektu końcowego	