

KARTA PRZEDMIOTU

Nazwa przedmiotu w języku polskim: PODSTAWY UCZENIA MASZYNOWEGO							Kod przedmiotu: KNS/ZR-IIP/AIwB/30				
Nazwa przedmiotu w języku angielskim: INTRODUCTION TO MACHINE LEARNING											
Kierunek studiów: Zarządzanie			Profil: praktyczny				Poziom studiów: II stopień				
Specjalność/specjalizacja: AI w Biznesie			Forma zaliczenia przedmiotu: zaliczenie na ocenę				Semestr studiów: 3				
Nazwa grupy zajęć: zajęcia specjalnościowe			Język w jakim prowadzone są zajęcia: polski								
Tryb studiów	Forma zajęć							Ogólna liczba godzin	Liczba punktów ECTS:		
	W	Ćw.	Konw.	Lab.	Proj.	Sem.	Zajęcia terenowe				
	Tryb stacjonarny	15	-	-	15	-	-			-	30
	Tryb niestacjonarny	9	-	-	15	-	-			-	24
Jednostka realizująca przedmiot, wydział: Kolegium Nauk Społecznych											
Odpowiedzialny za opracowanie karty przedmiotu (tytuł/stopień naukowy, imię i nazwisko, adres e-mail): dr hab. Małgorzata Przybyłą-Kasperek, mprzybyla-kasperek@wszop.edu.pl											
CEL PRZEDMIOTU											
C1.	Zapoznanie studentów z podstawowymi algorytmami uczenia maszynowego.										
C2.	Praktyczne zastosowanie metod uczenia nadzorowanego i nienadzorowanego.										
C3.	Rozwijanie umiejętności analizy danych i interpretacji wyników w kontekście biznesowym.										
WYMAGANIA WSTĘPNE											
1.	Podstawy sztucznej inteligencji w biznesie										
2.	Podstawowe umiejętności pracy z danymi (arkusz kalkulacyjny) oraz podstawy statystyki opisowej.										

PRZEDMIOTOWE EFEKTY UCZENIA SIĘ		METODY WERYFIKACJI EFEKTÓW UCZENIA SIĘ	ODNIESIENIE DO:	
			TREŚCI PROGRAMOWYCH	KIERUNKOWYCH EFEKTÓW UCZENIA SIĘ
EU1	Student posiada wiedzę z zakresu podstawowych zagadnień uczenia maszynowego, w tym metod nadzorowanych i nienadzorowanych, przetwarzania danych oraz oceny jakości modeli.	kolokwium całościowe sprawozdania z pracy indywidualnej	W1-W5 L1-L6	ZII K_W 09
EU2	Student potrafi samodzielnie realizować zadania typowe dla pracy analitycznej w dziale danych lub projektach biznesowych wykorzystujących uczenie maszynowe, w tym przygotowywać dane, trenować modele, analizować wyniki i interpretować je w kontekście decyzji biznesowych.	sprawozdania z pracy indywidualnej + prezentacja	L1-L6	ZII K_U 02
EU3	Student potrafi obsługiwać środowisko Microsoft Azure Machine Learning, w tym implementować, testować i ewaluować modele. Stosuje zasady etyki zawodowej, bezpieczeństwa danych i odpowiedzialnego wykorzystania narzędzi ML w kontekście biznesowym.	sprawozdania z pracy indywidualnej + prezentacja	L1-L6	ZII K_U 10 ZII K_K 05
TREŚCI PROGRAMOWE				
L.p.	WYKŁAD	Liczba godzin		
		S	N	
W1	Wprowadzenie do uczenia maszynowego – definicje, historia, rodzaje uczenia (nadzorowane, nienadzorowane, wzmacniające). Zastosowania ML w biznesie i nauce. Podstawy pracy z danymi – typy danych, struktura datasetów, eksploracja danych (EDA), metody czyszczenia braków i transformacji danych.	3	2	
W2	Regresja liniowa – teoria, funkcja kosztu, metoda najmniejszych kwadratów, metryki oceny modelu (MSE, RMSE). Drzewa decyzyjne i ensemble methods – drzewo decyzyjne, Random Forest, bagging, boosting.	3	2	
W3	KNN i inne klasyfikatory – K-nearest neighbors, SVM, podstawy działania i zastosowania. Klasteryzacja i redukcja wymiarowości – K-Means, hierarchiczna klasteryzacja, PCA, wizualizacja grup.	3	2	
W4	Ewaluacja modeli ML – metryki oceny klasyfikacji i regresji, cross-validation, confusion matrix, overfitting/underfitting.	3	2	
W5	Automatyzacja i narzędzia ML w chmurze – AutoML, Azure ML Studio, HyperDrive, pipeline'y, monitoring modeli.	3	1	
RAZEM		15	9	
FORMA I KRYTERIA ZALICZENIA WYKŁADU: kolokwium całościowe – ocena ilościowa.				

L.p.	LABORATORIUM	Liczba godzin	
		S	N
L1	Wprowadzenie do ML i Azure Konfiguracja workspace w Azure, wgranie pierwszego datasetu, przegląd AML Studio. Eksploracja i przygotowanie danych. Data wrangling w AutoML i Azure Notebooks, wizualizacja danych, czyszczenie braków.	3	3
L2	Regresja liniowa i logistyczna Implementacja modelu w AML Studio, analiza błędu MSE, wizualizacja wyników. Klasyfikacja binarna z AutoML, interpretacja wyników.	3	3
L3	Drzewa decyzyjne, Random Forest, KNN i inne klasyfikatory Trening i wizualizacja modeli, feature importance w Azure, Porównanie modeli, automatyczne strojenie hiperparametrów (HyperDrive).	3	3
L4	Klasteryzacja (K-Means) oraz Redukcja wymiarowości (PCA) Segmentacja klientów, wizualizacja grup w AML Studio. Analiza danych w Notebooks, uproszczenie modeli, wizualizacja komponentów.	3	3
L5	Ewaluacja modeli Dashboard AML, analiza metryk, confusion matrix, cross-validation	1	1
L6	Sprawozdanie końcowe Implementacja wybranego projektu ML w Azure, przygotowanie raportu i prezentacji wyników	2	2
RAZEM		15	15

FORMA I KRYTERIA ZALICZENIA LABORATORIUM: Sprawozdanie z pracy indywidualnej, prezentacja – ocena jakościowa.

METODY I FORMY DYDAKTYCZNE

1.	wykład informacyjny
2.	objaśnienie
3.	ćwiczenia laboratoryjne
4.	Praca z programem – praca zespołowa.
5.	Praca z programem – praca samodzielna.

NARZĘDZIA DYDAKTYCZNE

1.	prezentacja multimedialna
2.	platforma e-learningowa
3.	środowisko chmurowe Azure Machine Learning (workspace, compute)

OPROGRAMOWANIE

1.	MS Powerpoint
2.	Microsoft Office Professional Edition 2019
3.	Azure Machine Learning Studio

OBCIĄŻENIE STUDENTA PRACĄ

Forma aktywności		Liczba godzin na zrealizowanie aktywności	
		tryb stacjonarny	tryb niestacjonarny
1.	godziny kontaktowe z nauczycielem akademickim	30	24
2.	samodzielne przygotowanie się do zajęć	7	13
3.	przygotowanie do zaliczenia/egzaminu	5	5
4.	konsultacje	2	2
5.	zapoznanie się z literaturą	6	6
6.	zaliczenie/egzamin	-	-
SUMA GODZIN		50	50
LICZBA PUNKTÓW ECTS		2	2

LITERATURA PODSTAWOWA

1.	M. Muraszkiewicz, R. Nowak, <i>Sztuczna inteligencja dla inżynierów. Metody ogólne</i> , Oficyna Wydawnicza Politechniki Warszawskiej, 2022
2.	K. Śledziewska, R. Włoch, <i>Gospodarka cyfrowa</i> , Uniwersytet Warszawski, 2020

3.	Microsoft Docs: <i>Azure Machine Learning Documentation</i> (docs.microsoft.com)
LITERATURA UZUPEŁNIAJĄCA I ŹRÓDŁA PRAWA	
1.	J. Wiktorowicz, M.M. Grzelak, K. Grzeszkiewicz-Radulska, Analiza statystyczna z IBM SPSS Statistics, Wydawnictwo Uniwersytetu Łódzkiego, 2020
2.	J. Niedbalski, Komputerowe wspomaganie analizy danych jakościowych. Zastosowanie oprogramowania NVivo i Atlas.ti w projektach badawczych opartych na metodologii teorii ugruntowanej, Wydawnictwo Uniwersytetu Łódzkiego, 2014
3.	J. Urbański, GIS w badaniach przyrodniczych, Wydawnictwo Uniwersytetu Gdańskiego, 2008
INNE PRZYDATNE INFORMACJE O PRZEDMIOCIE:	
1.	PLATFORMA MOODLE zawiera: ▪ materiały dydaktyczne do przedmiotu ▪ przedmiotowe efekty uczenia się ▪ zalecaną literaturę ▪ warunki i kryteria zaliczenia przedmiotu
2.	BIBLIOTEKA WSZOP zapewnia literaturę podstawową do przedmiotu oraz wybrane pozycje literatury uzupełniającej, w tym dostęp do zbiorów cyfrowych i Platformy IBUK Libra
3.	ELEKTRONICZNY NIEZBĘDNIK STUDENTA zawiera: ▪ kierunkowe efekty uczenia się ▪ karty przedmiotów ▪ terminy konsultacji nauczycieli akademickich
4.	WIRTUALNY DZIEKANAT zawiera: ▪ harmonogram zajęć na bieżący semestr ▪ harmonogram sesji egzaminacyjnej ▪ ogłoszenia dotyczące organizacji roku akademickiego
5.	Ocena osiągnięcia zakładanych efektów uczenia się z wykorzystaniem metod weryfikacji wymagających oceny jakościowej oznacza, że zakładane efekty zostały osiągnięte: ▪ w pełni – ocena bardzo dobry ▪ z niewielkimi niedociągnięciami – ocena dobry plus ▪ z brakami, które można uzupełnić – ocena dobry ▪ z istotnymi brakami, które można uzupełnić – ocena dostateczny plus ▪ z istotnymi brakami na minimalnym poziomie – ocena dostateczny lub ▪ nie zostały osiągnięte – ocena niedostateczny.
6.	Ocena osiągnięcia zakładanych efektów uczenia się z wykorzystaniem metod weryfikacji wymagających oceny ilościowej oznacza, że zakładane efekty zostały osiągnięte: ▪ 91-100% sumy – ocena bardzo dobry ▪ 81-90% – ocena dobry plus ▪ 71-80% – ocena dobry ▪ 61-70% – ocena dostateczny plus ▪ 51-60% – ocena dostateczny lub ▪ 50% i mniej – ocena niedostateczny.
7.	Terminy egzaminów uzgadnia starosta roku z prowadzącym zajęcia
8.	Karta przedmiotu obowiązuje od roku akademickiego 2025/26