

Karta przedmiotu

Nazwa i kod przedmiotu	AI i Machine Learning, PG_00177506						
Kierunek studiów	Informatyka i ekonometria (O)						
Data rozpoczęcia studiów	październik 2026 r.	Rok akademicki realizacji przedmiotu			2027/2028		
Poziom kształcenia	II stopnia	Grupa zajęć			Grupa zajęć obowiązkowych z zakresu kierunku studiów Grupa zajęć fakultatywnych Grupa zajęć powiązanych z prowadzonymi badaniami naukowymi w dziedzinie nauki związanej z kierunkiem - profil ogólnoakademicki		
Forma studiów	stacjonarne	Sposób realizacji			na uczelni		
Rok studiów	2	Język wykładowy			polski		
Semestr studiów	3	Liczba punktów ECTS			7.0		
Profil kształcenia	ogólnoakademicki	Forma zaliczenia			egzamin		
Jednostka prowadząca	Rektor -> Wydział Zarządzania -> Katedra Statystyki						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot	dr hab. Krzysztof Najman					
	Prowadzący zajęcia z przedmiotu						
Formy zajęć	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	15.0	30.0	0.0	0.0	75
	W tym liczba godzin zajęć na odległość: 0.0						
Aktywność studenta i liczba godzin pracy	Aktywność studenta	Udział w zajęciach dydaktycznych, objętych planem studiów		Udział w konsultacjach		Praca własna studenta	RAZEM
	Liczba godzin pracy studenta	75		4.0		96.0	175
Cel przedmiotu	Celem przedmiotu jest przekazanie podstawowej wiedzy na temat wybranych metod Machine Learning i wybranych modeli sztucznych sieci neuronowych, a także umiejętności posługiwania się nimi w rozwiązywaniu wybranych problemów społeczno ekonomicznych.						

Efekty uczenia się przedmiotu	Efekt kierunkowy	Efekt z przedmiotu	Sposób weryfikacji i oceny efektu
	[[liEMU2_W08] Student w pogłębionym stopniu zna i rozumie metody, uwarunkowania, kierunki rozwoju oraz dylematy związane z zastosowaniem zaawansowanych narzędzi ekonometrycznych, informatycznych lub statystycznych, w kontekście dynamicznych zmian otoczenia.	Student zna teoretyczne podstawy Machine Learning i SSN oraz podstawowe narzędzia do ich budowy, uczenia, optymalizacji i weryfikacji.	[SW4] test/egzamin - ustny lub pisemny [SW2] prezentacja/projekt/referat/raport
	[[liEMU2_W10] Student w pogłębionym stopniu zna i rozumie fundamentalne dylematy współczesnej cywilizacji, w szczególności w obliczu rozwoju technologii informatycznych.	Student rozumie dylematy związane z zastosowaniem metod ML i SSN w badaniach społeczno ekonomicznych.	[SW4] test/egzamin - ustny lub pisemny [SW2] prezentacja/projekt/referat/raport
	[[liEMU2_U03] Student potrafi pozyskiwać i weryfikować dane z właściwie dobranych źródeł, gromadzić je, przetwarzać i wizualizować za pomocą nowoczesnych narzędzi ekonometrycznych, informatycznych lub statystycznych.	Student gromadzi, weryfikuje i przygotowuje dane do zastosowania wybranych metod ML i SSN.	[SU2] prezentacja/projekt/referat/raport
	[[liEMU2_U06] Student potrafi wykorzystywać i integrować uporządkowaną i szczegółową wiedzę z zakresu nauk o zarządzaniu i jakości oraz ekonomii i finansów na potrzeby rozstrzygnięcia dylematów i opracowywania innowacyjnych rozwiązań złożonych lub nietypowych problemów, pojawiających się w pracy zawodowej.	Student buduje, optymalizuje i ocenia wybrane modele ML i SSN dla wybranych zastosowań społeczno - ekonomicznych.	[SU2] prezentacja/projekt/referat/raport
	[[liEMU2_W06] Student ma uporządkowaną i podbudowaną teoretycznie wiedzę z zakresu procesów, metod i narzędzi projektowania, tworzenia, rozwoju i zapewnienia odpowiednich warunków użytkowania narzędzi informatycznych, ekonometrycznych lub statystycznych.	Student zna proces budowy, optymalizacji, weryfikacji i wdrażania wybranych modeli ML i SSN dla wybranych zastosowań społeczno - ekonomicznych.	[SW4] test/egzamin - ustny lub pisemny [SW2] prezentacja/projekt/referat/raport

Treści przedmiotu	<p>ML zagadnienia wstępne: definicja ML, Koncepcja uczenia algorytmicznego, modele uczenia: logiczne, geometryczne i probabilistyczne. Metody ML: nadzorowane, nienadzorowane, uczenie ze wzmocnieniem. Cykl życia modeli ML. Dziedziny zastosowań. Zalety i wady metod ML. Etyczne i prawne problemy stosowania modeli ML i AI.</p> <p>Wybrane modele uczenia nadzorowanego i nienadzorowanego:</p> <p>Drzewa klasyfikacyjne i regresyjne (algorytmy podziału, kryteria zatrzymania podziału, ewaluacja modelu, przycinanie krawędzi)</p> <p>Podejście wielomodelowe do drzew klasyfikacyjnych i regresyjnych (bagging, boosting, random forest, gradient boosting)</p> <p>Multivariate Adaptive Regression Splines (MARS)</p> <p>Algorytm k-najbliższych sąsiadów</p> <p>Wybrane modele regresji.</p> <p>Sztuczne sieci neuronowe - zagadnienia wstępne: wprowadzenie do obliczeń neuronowych, perceptron, sieci warstwowe jednokierunkowe, sieci rekurencyjne i samouczące się, algorytmy wstecznej propagacji błędów: gradientowa, gradientów sprzężonych, BroydenFletcherGoldfarbShanno (BFGS), Lavenberga Marquardta, Autoenkodery, wybrane modele uczenia ze wzmocnieniem, wybrane modele SSN stosowane przetwarzaniu obrazów i w analizie dokumentów tekstowych.</p> <p>Maszyny wektorów nośnych SVM: liniowe i nieliniowe,</p> <p>Ewaluacja modeli ML: testowanie modeli ML, wariancja i obciążenie modeli, problem nadmiernego dopasowania i metody regularyzacji, metryki oceny modeli ML (techniczne i biznesowe).</p>											
Wymagania wstępne i dodatkowe	Podstawy algebry liniowej, analizy matematycznej, statystyki opisowej, wstępnego przygotowania danych do analiz statystycznych. Podstawy programowania w języku Python.											
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table border="1" data-bbox="448 1256 1477 1361"> <thead> <tr> <th data-bbox="448 1256 794 1294">Sposób oceniania (składowe)</th> <th data-bbox="794 1256 1141 1294">Próg zaliczeniowy</th> <th data-bbox="1141 1256 1477 1294">Składowa oceny końcowej</th> </tr> </thead> <tbody> <tr> <td data-bbox="448 1294 794 1323">projekt semestralny</td> <td data-bbox="794 1294 1141 1323">51.0%</td> <td data-bbox="1141 1294 1477 1323">50.0%</td> </tr> <tr> <td data-bbox="448 1323 794 1361">egzamin pisemny</td> <td data-bbox="794 1323 1141 1361">51.0%</td> <td data-bbox="1141 1323 1477 1361">50.0%</td> </tr> </tbody> </table>			Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	projekt semestralny	51.0%	50.0%	egzamin pisemny	51.0%	50.0%
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej										
projekt semestralny	51.0%	50.0%										
egzamin pisemny	51.0%	50.0%										
Zalecana lista lektur	Podstawowa lista lektur	<ol style="list-style-type: none"> 1. K. Migdał-Najman, K. Najman, Samouczące się sztuczne sieci neuronowe w grupowaniu i klasyfikacji danych. Teoria i zastosowania w ekonomii, Wydawnictwo Uniwersytetu Gdańskiego, 2013. 2. G. Aurelien - Uczenie maszynowe z użyciem Scikit-Learn, Keras i TensorFlow, Helion, 2023 3. John D. Kelleher, B. Mac Namee, A. D'Arcy, Fundamentals of Machine Learning for Predictive Data Analytics: Algorithms, Worked Examples, and Case Studies, MIT Press, 2020. 4. G. James i inni, An Introduction to Statistical Learning with Applications in Python 										
	Uzupełniająca lista lektur	<p>T. Rashid, Make your own neural network, CreateSpace Independent Publishing Platform, 2016</p> <p>Charu C. Aggarwal, Neural Networks and Deep Learning, Springer, 2023</p>										
	Adresy eZasobów											
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania												
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy											

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.