

Karta przedmiotu

Nazwa i kod przedmiotu	AI i Machine Learning, PG_00178723						
Kierunek studiów	Informatyka i ekonometria (O)						
Data rozpoczęcia studiów	październik 2025 r.		Rok akademicki realizacji przedmiotu		2026/2027		
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	niestacjonarne		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	16.0	8.0	16.0	0.0	0.0	40
	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	40		2.0		133.0	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_U06] Student potrafi wykorzystywać i integrować uporządkowaną i szczegółową wiedzę z zakresu nauk o zarządzaniu i jakości oraz ekonomii i finansów na potrzeby rozstrzygania 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
	[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_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_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

Treści przedmiotu	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. Wybrane modele uczenia nadzorowanego i nienadzorowanego: Drzewa klasyfikacyjne i regresyjne (algorytmy podziału, kryteria zatrzymania podziału, ewaluacja modelu, przycinanie krawędzi) Podejście wielomodelowe do drzew klasyfikacyjnych i regresyjnych (bagging, boosting, random forest, gradient boosting) Multivariate Adaptive Regression Splines (MARS) Algorytm k-najbliższych sąsiadów Wybrane modele regresji. 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. Maszyny wektorów nośnych SVM: liniowe i nieliniowe, Ewaluacja modeli ML: testowanie modeli ML, wariancja i obciążenie modeli, problem nadmiernego dopasowania i metody regularyzacji, metryki oceny modeli ML (techniczne i biznesowe).											
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><tr><td>Sposób oceniania (składowe)</td><td>Próg zaliczeniowy</td><td>Składowa oceny końcowej</td></tr><tr><td>projekt semestralny</td><td>51.0%</td><td>50.0%</td></tr><tr><td>egzamin pisemny</td><td>51.0%</td><td>50.0%</td></tr></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	<table><tr><td>Podstawowa lista lektur</td><td> 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 </td></tr><tr><td>Uzupełniająca lista lektur</td><td> T. Rashid, Make your own neural network, CreateSpace Independent Publishing Platform, 2016 Charu C. Aggarwal, Neural Networks and Deep Learning, Springer, 2023 </td></tr><tr><td>Adresy eZasobów</td><td></td></tr></table>	Podstawowa lista lektur	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	T. Rashid, Make your own neural network, CreateSpace Independent Publishing Platform, 2016 Charu C. Aggarwal, Neural Networks and Deep Learning, Springer, 2023	Adresy eZasobów						
Podstawowa lista lektur	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	T. Rashid, Make your own neural network, CreateSpace Independent Publishing Platform, 2016 Charu C. Aggarwal, Neural Networks and Deep Learning, Springer, 2023											
Adresy eZasobów												
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania												
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy											

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.