

KARTA KURSU (realizowanego w module specjalności)
Data Science

Nazwa	Modelowanie i optymalizacja dla Data Science
Nazwa w j. ang.	Modeling and Optimization for Data Science

Koordynator	dr Roman Czapla	Zespół dydaktyczny
		Dr Roman Czapla
Punktacja ECTS*	3	

Opis kursu (cele kształcenia)

Celem kursu jest zapoznanie studentów z metodami modelowania i technikami optymalizacji stosowanymi w Data Science. Studenci poznają podstawowe i zaawansowane podejścia do budowy modeli analitycznych oraz dobierania optymalnych parametrów i struktur modeli. Zajęcia obejmują zarówno zagadnienia teoretyczne, jak i praktyczne ćwiczenia z wykorzystaniem narzędzi programistycznych typowych dla analizy danych. Kurs przygotowuje do samodzielnego projektowania, weryfikowania i udoskonalania modeli wykorzystywanych w rozwiązywaniu złożonych problemów data science.

Kurs prowadzony jest w języku polskim.

Warunki wstępne

Wiedza	Podstawowa znajomość algebry liniowej, rachunku różniczkowego i całkowego oraz statystyki opisowej i probabilistyki. Znajomość analizy danych. Znajomość zasad działania systemów komputerowych, reprezentacji danych oraz struktur danych i algorytmów.
Umiejętności	Umiejętność programowania w jednym z języków używanych w Data Science (preferowane: Python). Umiejętność pracy z danymi: import, czyszczenie, wstępna analiza i wizualizacja. Umiejętność posługiwania się bibliotekami do analizy danych i modelowania.
Kursy	

Efekty uczenia się

	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
Wiedza	Po zakończeniu kursu student:	SD_W01 - SD_W07 SD_W09
	W01: posiada pogłębioną wiedzę z matematyki i metod analitycznych wykorzystywanych w Data Science, w tym z obszaru optymalizacji, statystyki matematycznej, probabilistyki oraz algebry liniowej, pozwalającą na formułowanie i analizę modeli wykorzystywanych do rozwiązywania złożonych problemów danych; W02: zna zaawansowane technologie, narzędzia i środowiska stosowane w praktyce Data Science, w tym technologie rozproszone (chmurowe i klastrowe), metody przetwarzania dużych zbiorów danych, narzędzia eksploracji danych oraz zasady bezpiecznej, etycznej i prawnej pracy z danymi.	

	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
Umiejętności	<p>Po zakończeniu kursu student:</p> <p>U01: potrafi formułować i rozwiązywać problemy optymalizacyjne pojawiające się w analizie danych, dobierając odpowiednie modele, metody numeryczne oraz narzędzia programistyczne;</p> <p>U02: potrafi implementować i oceniać modele stosowane w Data Science, przeprowadzać analizę ich efektywności oraz interpretować wyniki w kontekście określonego problemu;</p> <p>U03: potrafi pracować w zespole przy realizacji projektów Data Science, prezentować wyniki analiz i modeli w sposób czytelny dla interdyscyplinarnego odbiorcy oraz uzasadniać przyjęte metody i decyzje projektowe.</p>	<p>SD_U01 SD_U02 SD_U03 SD_U05 SD_U06 SD_U08</p>

	Efekt uczenia się dla kursu	Odniesienie do efektów kierunkowych
Kompetencje społeczne	<p>Po zakończeniu kursu student:</p> <p>K01: ma świadomość społecznej roli absolwenta kierunku Data Science oraz odpowiedzialności za skutki wdrażanych rozwiązań analitycznych i optymalizacyjnych;</p> <p>K02: rozumie znaczenie etycznego i profesjonalnego zachowania w pracy z danymi, potrafi identyfikować dylematy zawodowe i stosować zasady etyki oraz ochrony danych w projektach Data Science.</p>	<p>SD_K01 SD_K03</p>

Studia stacjonarne

Organizacja							
Forma zajęć	Wykład (W)	Ćwiczenia w grupach					
		A	K	L	S	P	E
Liczba godzin	15			15			

Studia niestacjonarne

Organizacja							
Forma zajęć	Wykład (W)	Ćwiczenia w grupach					
		A	K	L	S	P	E
Liczba godzin	10			10			

Opis metod prowadzenia zajęć

Kurs prowadzony jest w formie zajęć teoretycznych i praktycznych, łącząc wykłady, laboratoria z zadaniami indywidualnymi oraz projekty grupowe.

Formy sprawdzania efektów uczenia się

	E – learning	Gry dydaktyczne	Ćwiczenia w szkole	Zajęcia terenowe	Praca laboratoryjna	Projekt indywidualny	Projekt grupowy	Udział w dyskusji	Referat	Praca pisemna (esej)	Egzamin ustny	Egzamin pisemny	Inne
W01					X	X	X	X					
W02					X	X	X	X					
U01					X	X	X	X					
U02					X	X	X	X					
U03					X	X	X	X					
K01						X	X	X					
K02						X	X	X					

Kryteria oceny	<p>Osiągnięcie efektów kształcenia podanych powyżej uprawnia studentów do uzyskania oceny nie wyższej niż dostateczna. Ocenę dobrą lub bardzo dobrą może uzyskać student, który:</p> <ul style="list-style-type: none"> • potrafi samodzielnie formułować i rozwiązywać złożone problemy optymalizacyjne oraz analityczne w Data Science, • prawidłowo dobiera modele, metody i narzędzia do analizy danych o różnym stopniu złożoności, • implementuje i ocenia poprawność modeli, w tym stosuje techniki optymalizacji parametrów, • potrafi efektywnie współpracować w zespole przy projektach grupowych i jasno prezentować wyniki analiz, • interpretuje wyniki w kontekście problemu i potrafi wskazać mocne i słabe strony zastosowanych rozwiązań.
----------------	---

Uwagi	
-------	--

Treści merytoryczne (wykaz tematów)

1.	Wprowadzenie do Data Science i przegląd narzędzi analizy danych.
2.	Modelowanie matematyczne w analizie danych.
3.	Metody optymalizacji i rozwiązywanie problemów analitycznych.
4.	Statystyka, probabilistyka i eksploracja danych.
5.	Implementacja i optymalizacja modeli w Python/R.
6.	Etyka i bezpieczeństwo danych w praktyce analitycznej.

Wykaz literatury podstawowej

1.	Géron, A. <i>Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow</i> , 3rd Edition, O'Reilly, 2022.
2.	VanderPlas, J. <i>Python Data Science Handbook</i> , 2nd Edition, O'Reilly, 2020.
3.	Raschka, S., Mirjalili, V. <i>Python Machine Learning</i> , 3rd Edition, Packt, 2020.

Wykaz literatury uzupełniającej

1. R. S. Michalski, *Optymalizacja i metody numeryczne w analizie danych*, PWN, 2018.
2. P. Biecek, *Praktyczny przewodnik po analizie danych w R*, Helion, 2019.

Bilans godzinowy zgodny z CNPS (Całkowity Nakład Pracy Studenta) **studia stacjonarne**

liczba godzin w kontakcie z prowadzącymi	Wykład	15
	Konwersatorium (ćwiczenia, laboratorium itd.)	15
	Pozostałe godziny kontaktu studenta z prowadzącym	15
liczba godzin pracy studenta bez kontaktu z prowadzącymi	Lektura w ramach przygotowania do zajęć	15
	Przygotowanie krótkiej pracy pisemnej lub referatu po zapoznaniu się z niezbędną literaturą przedmiotu	
	Przygotowanie projektu lub prezentacji na podany temat (praca w grupie)	15
	Przygotowanie do egzaminu/zaliczenia	
Ogółem bilans czasu pracy		75
Liczba punktów ECTS w zależności od przyjętego przelicznika		3

Bilans godzinowy zgodny z CNPS (Całkowity Nakład Pracy Studenta) **studia niestacjonarne**

liczba godzin w kontakcie z prowadzącymi	Wykład	10
	Konwersatorium (ćwiczenia, laboratorium itd.)	10
	Pozostałe godziny kontaktu studenta z prowadzącym	20
liczba godzin pracy studenta bez kontaktu z prowadzącymi	Lektura w ramach przygotowania do zajęć	15
	Przygotowanie krótkiej pracy pisemnej lub referatu po zapoznaniu się z niezbędną literaturą przedmiotu	
	Przygotowanie projektu lub prezentacji na podany temat (praca w grupie)	20
	Przygotowanie do egzaminu/zaliczenia	
Ogółem bilans czasu pracy		75
Liczba punktów ECTS w zależności od przyjętego przelicznika		3