



KARTA PRZEDMIOTU

Kod przedmiotu	studia stacjonarne:	Z-ZIP2-U-334
	studia niestacjonarne:	Z-ZIPN2-U-334
Nazwa przedmiotu	Uczenie maszynowe R	
Nazwa przedmiotu w języku angielskim	Machine Learning in R	
Obowiązuje od roku akademickiego	2022/2023	

USYTUOWANIE PRZEDMIOTU W SYSTEMIE STUDIÓW

Kierunek studiów	ZARZĄDZANIE I INŻYNIERIA PRODUKCJI
Poziom kształcenia	II stopień
Profil studiów	Ogólnoakademicki
Forma i tryb prowadzenia studiów	Studia stacjonarne
Zakres	Informatyka w zarządzaniu i modelowaniu
Jednostka prowadząca przedmiot	Katedra Technologii Informatycznych
Koordinator przedmiotu	dr inż. Michał Pajęcki
Zatwierdził	dr hab. inż. Dariusz Bojczuk, prof. PŚk

OGÓLNA CHARAKTERYSTYKA PRZEDMIOTU

Przynależność do grupy/bloku przedmiotów	Przedmiot specjalnościowy	
Status przedmiotu	Obowiązkowy	
Język prowadzenia zajęć	Polski	
Usytuowanie w planie studiów - semestr	studia stacjonarne	Semestr III
	studia niestacjonarne	-
Wymagania wstępne	Wprowadzenie do systemu R	
Egzamin (TAK/NIE)	NIE	
Liczba punktów ECTS	2	

Forma prowadzenia zajęć		wykład	ćwiczenia	laboratorium	projekt	inne
Liczba godzin w semestrze	studia stacjonarne:	15		20		
	studia niestacjonarne:	-	-	-	-	-

EFEKTY UCZENIA SIĘ

Kategoria	Symbol efektu	Efekty uczenia się	Odniesienie do efektów kierunkowych
Wiedza	W01	Student ma pogłębioną wiedzę na temat rodzajów metod uczenia maszynowego według możliwości ich stosowania do analizy danych w obszarach ekonomii i zarządzania.	ZIP2_W04
	W02	Student ma pogłębioną wiedzę na temat procesu analizy danych z wykorzystaniem metod uczenia maszynowego oraz zna narzędzia w R wspomagające ten proces.	ZIP2_W12 ZIP2_W04
	W03	Student ma szeroką wiedzę w zakresie wykorzystania środowiska programistycznego R do implementowania algorytmów uczenia maszynowego.	ZIP2_W12
Umiejętności	U01	Student potrafi samodzielnie ocenić przydatność metod uczenia maszynowego do rozwiązywania praktycznych problemów.	ZIP2_U12
	U02	Student potrafi przy użyciu środowiska programistycznego R przeprowadzić proces uczenia maszynowego w celu rozwiązania praktycznego problemu.	ZIP2_U13
	U03	Student potrafi zinterpretować wyniki procesu uczenia maszynowego i sporządzić dokumentację dotyczącą realizacji zadania.	ZIP2_U04 ZIP2_U13
Kompetencje społeczne	K01	Student rozumie potrzebę śledzenia trendów rozwojowych metod uczenia maszynowego.	ZIP2_K01

TREŚCI PROGRAMOWE

Forma zajęć	Treści programowe
wykład	<ol style="list-style-type: none"> 1. Uczenie maszynowe – definicja i zastosowania. Metody uczenia maszynowego – rodzaje i charakterystyka. 2. Proces analizy danych z wykorzystaniem uczenia maszynowego. Język R w uczeniu maszynowym. 3. Wstępne przetwarzanie danych. Ocena jakości danych (np. poprawność, spójność, wartości brakujące, duplikaty). Normalizacja zmiennych. Podstawowe statystyki dla zmiennych ilościowych i jakościowych. 4. Eksploracyjne wizualizacje danych w środowisku R. 5. Wybrane metody uczenia nadzorowanego i ich implementacja w środowisku R. 6. Wybrane metody uczenia nienadzorowanego i ich implementacja w środowisku R. 7. Dokumentowanie procesu uczenia maszynowego.
laboratorium	<ol style="list-style-type: none"> 1. Wstępne przetwarzanie i przygotowanie danych do analiz w środowisku R: eksploracja danych, ocena jakości danych, transformacje zmiennych, statystyki podsumowujące, miary korelacyjne. 2. Graficzna prezentacja danych w R – funkcje wbudowane i wybrane pakiety. 3. Metody uczenia nadzorowanego w R, np. regresja liniowa i regresja logistyczna. Założenia do budowy wybranego modelu uczenia nadzorowanego. Dobór zmiennych do modelu. 4. Weryfikacja merytoryczna i statystyczna wybranego modelu uczenia nadzorowanego. Ocena jakości modelu. Interpretacja wyników. 5. Metody uczenia nienadzorowanego w R, np. metoda k-średnich i analiza klas ukrytych. Założenia do budowy wybranego modelu uczenia nienadzorowanego. Dobór zmiennych do modelu. 6. Ocena jakości wybranego modelu uczenia nienadzorowanego. Interpretacja wyników. 7. Opracowanie sprawozdań.

METODY WERYFIKACJI EFEKTÓW UCZENIA SIĘ

Symbol efektu	Metody sprawdzania efektów kształcenia (zaznaczyć X)					
	Egzamin ustny	Egzamin pisemny	Kolokwium	Projekt	Sprawozdanie	Inne
W01			X			
W02			X			
W03			X			
U01					X	
U02					X	
U03					X	
K01						X

FORMA I WARUNKI ZALICZENIA

Forma zajęć	Forma zaliczenia	Warunki zaliczenia
wykład	zaliczenie z oceną	Uzyskanie co najmniej 50% punktów ze sprawdzianu końcowego.
laboratorium	zaliczenie z oceną	Uzyskanie co najmniej 50% punktów z realizacji i raportowania zadań na ćwiczeniach, będąc członkiem zespołu.

NAKŁAD PRACY STUDENTA

Bilans punktów ECTS													
Lp.	Rodzaj aktywności	Obciążenie studenta										Jednostka	
		studia stacjonarne					studia niestacjonarne						
		W	C	L	P	S	W	C	L	P	S		
1.	Udział w zajęciach zgodnie z planem studiów	15		20			-	-	-	-	-	h	
2.	Inne (konsultacje, egzamin)	2		2			-	-	-	-	-	h	
3.	Razem przy bezpośrednim udziale nauczyciela akademickiego	39					-					h	
4.	Liczba punktów ECTS, którą student uzyskuje przy bezpośrednim udziale nauczyciela akademickiego	1,6					-					ECTS	
5.	Liczba godzin samodzielnej pracy studenta	11					-					h	
6.	Liczba punktów ECTS, którą student uzyskuje w ramach samodzielnej pracy	0,4					-					ECTS	
7.	Nakład pracy związany z zajęciami o charakterze praktycznym	29					-					h	
8.	Liczba punktów ECTS, którą student uzyskuje w ramach zajęć o charakterze praktycznym	1,2					-					ECTS	
9.	Sumaryczne obciążenie pracą studenta	50					-					h	
10.	Punkty ECTS za moduł <i>1 punkt ECTS=25 godzin obciążenia studenta</i>	2										ECTS	

LITERATURA

1. Burger S.V. (2018), *Introduction to Machine Learning with R: Rigorous Mathematical Analysis*. O'Reilly Media, California.
2. Cichosz P. (2000), *Systemy uczące się*. Wydawnictwa Naukowo-Techniczne, Warszawa.
3. Conway D., White J. M. (2015), *Uczenie maszynowe dla programistów*. Helion, Gliwice.
4. Hand D., Mannila H., Smyth P. (2005), *Eksploracja danych*. Wydawnictwa Naukowo-Techniczne, Warszawa.
5. Lander J. P. (2018), *R dla każdego. Zaawansowane analizy i grafika statystyczna*. APN Promise, Warszawa.
6. Lantz B. (2015), *Machine Learning with R: Expert techniques for predictive modeling to solve all your data analysis problem*. Packt Publishing, United Kingdom.
7. Larose D. T. (2006), *Odkrywanie wiedzy z danych. Wprowadzenie do eksploracji danych*. Wydawnictwo Naukowe PWN, Warszawa.
8. Larose D. T. (2008), *Metody i modele eksploracji danych*. Wydawnictwo Naukowe PWN, Warszawa.
9. Morzy T. (2013), *Eksploracja danych. Metody i algorytmy*. Wydawnictwo Naukowe PWN, Warszawa.
10. Szeliga M. (2017), *Data Science i uczenie maszynowe*. Wydawnictwo Naukowe PWN, Warszawa.
11. Szeliga M. (2019), *Praktyczne uczenie maszynowe*. Wydawnictwo Naukowe PWN, Warszawa.