



Karta przedmiotu

Nazwa i kod przedmiotu	Uczenie maszynowe, PG_00053337						
Kierunek studiów	Inżynieria biomedyczna, Inżynieria biomedyczna, Inżynieria biomedyczna						
Data rozpoczęcia studiów	luty 2023 r.		Rok akademicki realizacji przedmiotu		2022/2023		
Poziom kształcenia	II stopnia		Grupa zajęć		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	1		Język wykładowy		polski		
Semestr studiów	1		Liczba punktów ECTS		3.0		
Profil kształcenia	ogólnoakademicki		Forma zaliczenia		egzamin		
Jednostka prowadząca	Wydział Elektroniki, Telekomunikacji i Informatyki -> Katedra Inżynierii Biomedycznej						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot		prof. dr hab. inż. Jacek Rumiński				
	Prowadzący zajęcia z przedmiotu		mgr inż. Natalia Szarwińska mgr inż. Szymon Zaporowski prof. dr hab. inż. Jacek Rumiński				
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	0.0	15.0	0.0	0.0	45
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	45		4.0		26.0	75
Cel przedmiotu	Celem przedmiotu jest zdobycie przez studentów wiedzy i umiejętności w zakresie algorytmów uczenia maszynowego, metod wstępnego przetwarzania danych oraz metryk i metod postępowania w ocenie wyników stosowanych algorytmów i modeli.						

Efekty uczenia się przedmiotu	Efekt kierunkowy	Efekt z przedmiotu	Sposób weryfikacji i oceny efektu
	[K7_W01] zna i rozumie w pogłębionym stopniu matematykę w zakresie niezbędnym do formułowania i rozwiązywania złożonych zagadnień związanych z kierunkiem studiów	Efektem procesu uczenia jest zdobycie przez studenta wiedzy w zakresie rozumienia definicji algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych.	[SW1] Ocena wiedzy faktograficznej
	[K7_W04] zna i rozumie w zaawansowanym stopniu zasady, metody i techniki programowania oraz zasady tworzenia oprogramowania komputerów albo programowania urządzeń lub sterowników wykorzystujących mikroprocesory albo inne elementy lub układy programowalne, specyficznych dla kierunku studiów, a także organizację pracy systemów wykorzystujących komputery lub te urządzenia	Efektem procesu uczenia jest zdobycie przez studenta wiedzy w zakresie implementacji lub wykorzystania bibliotek programistycznych dotyczących praktycznego zastosowania algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych w szczególności w zastosowaniach biomedycznych, bezpieczeństwa osób, prewencji zdrowia, itd.	[SW1] Ocena wiedzy faktograficznej
	[K7_U01] potrafi wykorzystywać posiadaną wiedzę matematyczną przy formułowaniu i rozwiązywaniu złożonych i nietypowych problemów związanych z kierunkiem studiów, poprzez: – właściwy dobór informacji źródłowych oraz dokonywanie ich krytycznej analizy, syntezy oraz twórczej interpretacji i prezentacji tych informacji, – zastosowanie właściwych metod i narzędzi	Efektem procesu uczenia jest zdobycie przez studenta umiejętności praktycznego zastosowania algorytmów uczenia maszynowego, wzorów z zakresu funkcji kosztów, metryk oceny jakości modeli, itp., w celu rozwiązywania zagadnień dotyczących klasyfikacji danych, detekcji obiektów, generacji charakterystyk uogólniających czy modeli regresyjnych w szczególności w zastosowaniach biomedycznych, bezpieczeństwa osób, prewencji zdrowia, itd.	[SU1] Ocena realizacji zadania
	[K7_U05] potrafi planować i przeprowadzać eksperymenty związane z kierunkiem studiów, w tym pomiary i symulacje komputerowe, interpretować uzyskane wyniki i wyciągać wnioski	Efektem procesu uczenia jest zdobycie przez studenta umiejętności praktycznego zastosowania zaplanowania eksperymentu badawczego związanego z uczeniem maszynowym, doboru danych i parametrów oraz miar oceny modelu, interpretacji wyników jak również wprowadzania zmian do eksperymentu czy opracowanego modelu.	[SU1] Ocena realizacji zadania

<p>Treści przedmiotu</p>	<p>Wprowadzenie do uczenia maszynowego (czyż jest uczenie maszynowe, klasyfikacje metod uczenia maszynowego)</p> <p>Metody pozyskiwania i przygotowywania danych: oczyszczanie danych, transformacje danych, standaryzacja i normalizacja danych</p> <p>Metody pozyskiwania i przygotowywania danych: integracja i redukcja danych</p> <p>Metody redukcji wielowymiarowości (m.in. PCA, ICA, itp.)</p> <p>Metody reprezentacji danych dla potrzeb uczenia maszynowego</p> <p>Proces pozyskiwania wiedzy z danych</p> <p>Metody generacji charakterystyk uogólniających</p> <p>Metody indukcji reguł i parametry oceny reguł</p> <p>Metody klasyfikacji (wprowadzenie) i metody oceny jakości klasyfikacji (miary, itp.)</p> <p>Metody klasyfikacji nadzorowanej (drzewa decyzyjne, lasy losowe)</p> <p>Metody klasyfikacji nadzorowanej (od Bayesa do klasyfikacji minimalno-odległościowej)</p> <p>Metody klasyfikacji nadzorowanej (SVM)</p> <p>Metody klasyfikacji nienadzorowanej (k-means, ISO-DATA, itp.)</p> <p>Metody optymalizacji charakterystyka</p> <p>Metody optymalizacji metody gradientowe</p> <p>Regresja liniowa</p> <p>Regresja logistyczna</p> <p>Sztuczne sieci neuronowe wprowadzenie, perceptron, uczenie</p> <p>Sztuczne sieci neuronowe MLP, funkcje aktywacji, uczenie cz.1.</p> <p>Sztuczne sieci neuronowe MLP cz.2.</p>														
<p>Wymagania wstępne i dodatkowe</p>	<ul style="list-style-type: none"> <li>- zna podstawy algebry liniowej, analizy matematycznej oraz rachunku prawdopodobieństwa z uwzględnieniem twierdzenia Bayesa</li> <li>- zna podstawy inżynierii oprogramowania (cykl życia oprogramowania, projektowanie oprogramowania, testowanie, itp.).</li> <li>- zna podstawy metod analizy danych</li> <li>- zna podstawy języka Python</li> <li>- potrafi projektować i modelować obiektowo</li> <li>- potrafi wykorzystywać bazy danych</li> </ul>														
<p>Sposoby i kryteria oceniania osiągniętych efektów uczenia się</p>	<table border="1" style="width: 100%; border-collapse: collapse;"> <thead> <tr> <th style="width: 33%;">Sposób oceniania (składowe)</th> <th style="width: 33%;">Próg zaliczeniowy</th> <th style="width: 33%;">Składowa oceny końcowej</th> </tr> </thead> <tbody> <tr> <td>Laboratorium</td> <td>50.0%</td> <td>50.0%</td> </tr> <tr> <td>Zadania domowe</td> <td>50.0%</td> <td>10.0%</td> </tr> <tr> <td>Egzamin</td> <td>50.0%</td> <td>40.0%</td> </tr> </tbody> </table>			Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	Laboratorium	50.0%	50.0%	Zadania domowe	50.0%	10.0%	Egzamin	50.0%	40.0%
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej													
Laboratorium	50.0%	50.0%													
Zadania domowe	50.0%	10.0%													
Egzamin	50.0%	40.0%													

Zalecana lista lektur	Podstawowa lista lektur	Deisenroth Marc Peter, Mathematics for Machine Learning, Cambridge University Press, 2020  Sebastian Raschka, Vahid Mirjalili, Python Machine Learning, Packt Publishing, 2019.  Aurélien Géron, Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems O'Reilly Media; 2nd edition, 2019.
	Uzupełniająca lista lektur	Chris A. Mattmann , Machine Learning with TensorFlow, Second Edition, Manning, 2020
	Adresy eZasobów	Adresy na platformie eNauczanie:
Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania		
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy	