



Karta przedmiotu

Nazwa i kod przedmiotu	Metody analityczne w uczeniu statystycznym i maszynowym, PG_00057625						
Kierunek studiów	Matematyka						
Data rozpoczęcia studiów	październik 2023 r.	Rok akademicki realizacji przedmiotu			2024/2025		
Poziom kształcenia	II stopnia	Grupa zajęć					
Forma studiów	stacjonarne	Sposób realizacji			na uczelni		
Rok studiów	2	Język wykładowy			polski		
Semestr studiów	4	Liczba punktów ECTS			3.0		
Profil kształcenia	ogólnoakademicki	Forma zaliczenia			zaliczenie		
Jednostka prowadząca	Wydział Fizyki Technicznej i Matematyki Stosowanej -> Instytut Matematyki Stosowanej -> Zakład Analizy Nieliniowej						
Imię i nazwisko wykładowcy (wykładowców)	Odpowiedzialny za przedmiot	dr hab. Karol Dziędziul					
	Prowadzący zajęcia z przedmiotu	Kazimierz Najmajer dr hab. Karol Dziędziul					
Formy zajęć i metody nauczania	Forma zajęć	Wykład	Ćwiczenia	Laboratorium	Projekt	Seminarium	RAZEM
	Liczba godzin zajęć	30.0	0.0	0.0	0.0	30.0	60
	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	60	0.0	0.0	60		
Cel przedmiotu	celem przedmiotu jest wzbogacenie podejścia statystycznego o metody optymalizacyjne. Daje to kolejną metodę uczenia maszynowego. wszystko to zanurzone jest we współczesnych metodach analitycznych jak np. framki, hipoteza Kadisona Singera						
Efekty uczenia się przedmiotu	Efekt kierunkowy		Efekt z przedmiotu		Sposób weryfikacji i oceny efektu		

Treści przedmiotu	<p>strona http://www.mif.pg.gda.pl/homepages/kdz/RKHS/RHS.pdf</p> <ol style="list-style-type: none"> 1., problem poprawnie postawiony 2. teoria Moora Penrosea 3 Zagadnienia uczenia statystycznego i maszynowego 4. {Przestrzeń Hilberta framki Parsevala 5. Przestrzeń Hilberta z jądrem reprodukcującym 6. Rozwiązanie best least squares approximant czyli Representer theorem 7 Rozwiązanie Tikhonov Regularization 8. Mercer theorem 9. The maximal margin classifie 10. Weavers Theorem and Open problem 11. Podejście Vapnik Czerwonenkis 12. S. Smale, Y. Yao Online Learning Algorithms 								
Wymagania wstępne i dodatkowe	Rachunek prawdopodobieństwa, statystyka I, Statystyka II, statystyka z SAS								
Sposoby i kryteria oceniania osiągniętych efektów uczenia się	<table border="1"> <thead> <tr> <th>Sposób oceniania (składowe)</th> <th>Próg zaliczeniowy</th> <th>Składowa oceny końcowej</th> </tr> </thead> <tbody> <tr> <td>wykład 50% lab 50%</td> <td>50.0%</td> <td>100.0%</td> </tr> </tbody> </table>	Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej	wykład 50% lab 50%	50.0%	100.0%		
Sposób oceniania (składowe)	Próg zaliczeniowy	Składowa oceny końcowej							
wykład 50% lab 50%	50.0%	100.0%							
Zalecana lista lektur	<p>Podstawowa lista lektur</p> <p>Uzupełniająca lista lektur</p> <p>Adresy eZasobów</p>	<p>PAULSEN, MRINALRAGHUPATHI An Introduction to the Theory. of Reproducing Kernel Hilbert Spaces .Cambridge University Press 2016</p> <p>Heinz Werner Engl, Martin Hanke, A. Neubauer Regularization of Inverse Problems</p> <p>Springer Science \& Business Media, 31 lip 1996</p> <p>S. Smale, Y. Yao Online Learning Algorithms, Found. Comput. Math. 145170 (2006), Springer</p> <p>Vapnik V., The Nature of Statistical Learning Theory, Springer, 2000. s. 38</p> <p>A. Christmann and I. Steinwart. Support Vector Machines. Springer, Berlin, 2008</p>	<p>Adresy na platformie eNauczanie:</p>						

Przykładowe zagadnienia/ przykładowe pytania/ realizowane zadania	Opracować dane korzystając z metod przedstawionych na wykładzie i lab.
Praktyki zawodowe w ramach przedmiotu	Nie dotyczy

Dokument wygenerowany elektronicznie. Nie wymaga pieczęci ani podpisu.