

(pieczęć wydziału)

KARTA PRZEDMIOTU

--	--	--

1. . Nazwa przedmiotu: MACHINE LEARNING		2. Kod przedmiotu:		
3. Karta przedmiotu ważna od roku akademickiego: 2018/2019				
4. Forma kształcenia: studia trzeciego stopnia				
5. Forma studiów: studia stacjonarne				
6. Studia: AIDA Interdyscyplinarne studia doktoranckie w zakresie przetwarzania i analizy danych.				
7. Profil studiów: akademicki				
8. Dyscyplina:				
9. Rok:				
10. Jednostka prowadząca przedmiot:				
11. Prowadzący przedmiot:				
12. Przynależność do grupy przedmiotów: moduł obowiązkowy				
13. Status przedmiotu:				
14. Język prowadzenia zajęć: angielski				
15. Przedmioty wprowadzające oraz wymagania wstępne:				
16. Cel przedmiotu: The aim of the course is making students familiar with problem and methods related to general machine learning problems. The contents of the course are presented in the aspect of a wide spectrum of applications.				
17. Efekty kształcenia:¹				
Nr	Opis efektu kształcenia	Metoda sprawdzenia efektu kształcenia	Forma prowadzenia zajęć	Odniesienie do efektów dla kierunku studiów
	The student understands the notion of the classification problem. Understands applications of classification	Lecture discussions	W	RAU_AIDA_W01

¹ należy wskazać ok. 4 – 5 efektów kształcenia

	in different areas.			
	The student understands relations between machine learning and optimisation problems.	Lecture discussions	W	RAU_AIDA_W04
	Student distinguishes between supervised and unsupervised classification problems.	Lecture discussions	W	RAU_AIDA_U11
	The student has orientation in existing tools for machine learning.	Lecture discussions	W	RAU_AIDA_U10
	The student can validate classifiers.	Lecture discussions	W	RAU_AIDA_U12 RAU_AIDA_U13
	A student can relate the real data analysis problem to known tools	Lecture discussions	W	RAU_AIDA_U09 RAU_AIDA_K06

18. Formy zajęć dydaktycznych i ich wymiar (liczba godzin)

W. 10 Ćw. - L. - P. - Sem. -

19 Treści kształcenia:

1. Introductory information. Applications of machine learning algorithms. Classifiers.
2. Supervised classification algorithms. Linear discriminant classifiers, neural networks, support vector machines, k-nearest neighbour classifiers.
3. Training - validation scenarios for supervised classifiers. Leave-one-out validation. Multiple random validations. Information leak avoidance. Boosting and bagging algorithms.
4. Unsupervised classification. Clustering. Variants of hierarchical clustering algorithms. K-means algorithms. Self-organizing maps. Principal component analyses. Biclustering algorithms. Independent component analysis (ICA).
5. Unsupervised algorithms and dimensionality reduction.

20. Egzamin: brak

21. Literatura podstawowa:

T. Hastie, R. Tibshirani, J. Friedman, (2008), The elements of statistical learning, Springer
S. Theodoridis, K. Koutroumbas, (2003), Pattern Recognition, Elsevier.

22. Literatura uzupełniająca:

R. Duda, P. Hart, D. Stork, (2000), Pattern Classification, Wiley.

23. Nakład pracy studenta potrzebny do osiągnięcia efektów kształcenia

Lp.	Forma zajęć	Liczba godzin kontaktowych / pracy studenta
1	Wykład	10/10
2	Ćwiczenia	/
3	Laboratorium	/
4	Projekt	/
5	Seminarium	/
6	Inne (przygotowanie do zajęć)	0 /15
	Suma godzin	10 / 25

24. Suma wszystkich godzin: 35

25. Liczba punktów ECTS: 1

26. Liczba punktów ECTS uzyskanych na zajęciach z bezpośrednim udziałem nauczyciela akademickiego: 1

27. Liczba punktów ECTS uzyskanych na zajęciach o charakterze praktycznym (laboratoria, projekty):

26. Uwagi:

Zatwierdzono:

.....
(data i podpis kierownika studiów doktoranckich)