

UČNI NAČRT PREDMETA / COURSE SYLLABUS											
Predmet:	Strojno učenje za podatkovne vede I										
Course title:	Machine learning for data science 1										
Študijski program in stopnja Study programme and level	Študijska smer Study field		Letnik Academic year	Semester Semester							
Interdisciplinarni magistrski študijski program Računalništvo in matematika	ni smeri		1 ali 2	prvi ali drugi							
Interdisciplinary Masters study programme Computer Science and Mathematics	none		1 or 2	first or second							
Vrsta predmeta / Course type	izbirni										
Univerzitetna koda predmeta / University course code:	M2854										
Predavanja Lectures	Seminar Seminar	Vaje Tutorial	Klinične vaje work	Druge oblike študija	Samost. delo Individ. work	ECTS					
45		30			105	6					
Nosilec predmeta / Lecturer:	Blaž Zupan										
Jeziki / Languages:	Predavanja / Lectures:	slovenski/Slovene, angleški/English									
	Vaje / Tutorial:	slovenski/Slovene, angleški/English									
Pogoji za vključitev v delo oz. za opravljanje študijskih obveznosti:	Prerequisites:										
Vsebina:	Content (Syllabus outline):										

<p>Linearni modeli. Linearna regresija.</p> <p>Linearna diskriminantna analiza. Logistična regresija. Gradientni sestop. Stohastični gradientni sestop.</p> <p>Pristop strojnega učenja. Cenovna funkcija. Pristop z zmanjšanjem tveganja.</p> <p>Maksimizacija verjetja. Vrednotenje modelov. Prečno preverjanje.</p> <p>Izbor značilk. Pristopi z iskanjem.</p> <p>Regularizacija.</p> <p>Drevesni modeli. Klasifikacijska in regresijska drevesa. Naključni gozd. Pristop bagging. Gradientni razvoj niza dreves.</p> <p>Gručenje. Metoda voditeljev. Algoritem EM.</p> <p>Nelinearna regresija. Bazne funkcije.</p> <p>Zlepki. Metoda podpornih vektorjev. Trik z jedri.</p>	<p>Linear models. Linear regression.</p> <p>Linear discriminant analysis. Logistic regression. Gradient descent.</p> <p>Stochastic gradient descent.</p> <p>The machine learning approach.</p> <p>Cost functions. Empirical risk minimization. Maximum likelihood estimation. Model evaluation. Crossvalidation.</p> <p>Feature selection. Search-based feature selection. Regularization.</p> <p>Tree-based models. Decision trees.</p> <p>Random forest. Bagging. Gradient tree boosting.</p> <p>Clustering. k-means. Expectation Maximization.</p> <p>Non-linear regression. Basis functions. Splines. Support vector machines. Kernel trick.</p>
--	--

Nevronske mreže. Perceptron. Aktivacijske funkcije. Tehnika vzvratnega razširjanja napak.	Neural networks. Perceptron. Activation functions. Backpropagation.
---	---

Temeljni literatura in viri / Readings:

James G, Witten D, Hastie T, Tibshirani R (2017) An Introduction to Statistical Learning, Springer.

Hastie T, Tibshirani R, Friedman J (2003) The elements of statistical learning, Springer.

Cilji in kompetence:

Predmet je namenjen seznanitvi z matematičnimi in algortimičnimi osnovami strojnega učenja ter vidiki uporabe strojnega učenja pri reševanju praktičnih problemov. Predmet pripravi študente na študij naprednejših metod iz strojnega učenja.

Objectives and competences:

The course aims at familiarizing the student with the fundamentals of machine learning, classical machine learning models, and the practicalities of applying machine learning to real-world problems. The course prepares students for the study of advanced machine learning methods.

Predvideni študijski rezultati:

Po uspešno zaključenem predmetu naj bi bili študentje zmožni:

- Uporabiti pristope strojnega učenja k podatkovni analitiki.
- Evalvirati različne tehnike

Intended learning outcomes:

After successfully completing the course, students should be able to:

- Apply the machine learning approach to data analysis.
- Evaluate different types of models.

<p>modeliranja.</p> <ul style="list-style-type: none"> - Izbrati ustrezen tehniko za dani problem in podatke. - Interpretirati rezultate strojnega učenja. - Prepoznati potencialne probleme. 	<ul style="list-style-type: none"> - Choose the correct model for the problem at hand. - Interpret machine learning results. - Identify potential issues.
--	--

Metode poučevanja in učenja:

Predavanja, vaje, domače naloge in nabor manjših projektov.

Learning and teaching methods:

Lectures, , homework, and a set of smaller projects.

Načini ocenjevanja:

Sprotno preverjanje (domače naloge, projekti)
Končno preverjanje (pisni izpit)
Ocene: 6-10 pozitivno, 5 negativno

Delež (v %) /

Weight (in %)

Assessment:

Continuing (homework, projects)
Final (written exam)
Grading: 6-10 pass, 5 fail

50%
50%

Reference nosilca / Lecturer's references:

Blaž Zupan:

- Staric A, Demsar J, Zupan B (2015) Concurrent software architectures for exploratory data analysis. WIREs Data Mining and Knowledge Discovery 5(4):165-180. [COBISS.SI-ID 1536356035]
- Zitnik M, Nam EA, Dinh C, Kuspa A, Shaulsky G, Zupan B (2015) Gene prioritization

by compressive data fusion and chaining, PLoS Computational Biology

11(10):e1004552. [COBISS.SI-ID 1536572355]

– Stražar M, Žitnik M, Zupan B, Ule J, Curk T (2016) Orthogonal matrix factorization

enables integrative analysis of multiple RNA binding proteins, Bioinformatics 32(10):

1527-35. [COBISS.SI-ID 1537001923]

– Žitnik M, Zupan B (2016) Jumping across biomedical contexts using compressive data

fusion, Bioinformatics 32(12):i90-i100. [COBISS.SI-ID 1537026243]

– Čopar A, Žitnik M, Zupan B (2017) Scalable non-negative matrix tri-factorization,

BioData Mining 10:41. [COBISS.SI-ID 1537708995]