

UČNI NAČRT PREDMETA / COURSE SYLLABUS							
<b>Predmet:</b>		Napredno strojno učenje					
<b>Course title:</b>		Advanced Machine Learning					
<b>Študijski program in stopnja</b> Study programme and level		<b>Študijska smer</b> Study field			<b>Letnik</b> Academic year		<b>Semester</b> Semester
Magistrski študijski program Matematika		ni smeri			1 ali 2		prvi ali drugi
Master's study programme Mathematics		none			1 or 2		first or second
<b>Vrsta predmeta / Course type</b>					izbirni		
<b>Univerzitetna koda predmeta / University course code:</b>					M2742		
<b>Predavanja</b> Lectures	<b>Seminar</b> Seminar	<b>Vaje</b> Tutorial	<b>Klinične vaje</b> work	<b>Druge oblike študija</b>	<b>Samost. delo</b> Individ. work	<b>ECTS</b>	
30	15	30			105	6	
<b>Nosilec predmeta / Lecturer:</b>		Ljupčo Todorovski, doc. Matija Pretnar					
<b>Jeziki / Languages:</b>		<b>Predavanja / Lectures:</b> slovenski/Slovene, angleški/English					
		<b>Vaje / Tutorial:</b> slovenski/Slovene, angleški/English					
<b>Pogoji za vključitev v delo oz. za opravljanje študijskih obveznosti:</b>				<b>Prerequisites:</b>			
<b>Vsebina:</b>				<b>Content (Syllabus outline):</b>			

<p>Primerjava zmogljivosti algoritmov strojnega učenja na več podatkovnih množicah hkrati: frekventistični in Baesov pristop.</p> <p>Učenje iz podatkovnih tokov: sprotno učenje, zadržano in zaporedno vrednotenje modelov, mehanizmi za zaznavanje sprememb, sestavljanje algoritmov za učenje iz podatkovnih tokov.</p> <p>Meta učenje: izrek o brezplačnem kosilu za strojno učenje, učenje o učenju, atributni opis podatkovnih množic, parametrizacija učnih algoritmov, optimizacija vrednosti parametrov učnih algoritmov, nadomestni modeli.</p> <p>Upoštevanje predznanja pri učenju: odkrivanje enačb iz podatkov in predznanja, relacijsko učenje in induktivno logično programiranje, hierarhično urejeno predznanje (taksonomije), predznanje in (globoke) umetne nevronske mreže.</p> <p>Izbrane teme iz učenja (globokih) umetnih nevronske mreže: poljubne ciljne funkcije in vzvratno razširjanje napake, izbrane topologije nevronske mreže (avtoenkoderji, vstavitve ne-ali pol-strukturiranih podatkov), delno nadzorovano učenje.</p>	<p>Comparing the performance of machine learning algorithms on multiple data sets: frequentist and Bayesian approach.</p> <p>Learning from data streams: online learning, evaluating model performance on data streams, change detection mechanisms, composing algorithms for machine learning from data streams.</p> <p>Meta learning: no-free lunch theorem for machine learning, learning about learning, attribute representation of data sets, parametrization of learning algorithms, optimizing the parameter settings of learning algorithms, surrogate models.</p> <p>Handling background knowledge in machine learning: equation discovery from data and knowledge, relational learning and surrogate models, hierarchically structured background knowledge (taxonomies), background knowledge and (deep) artificial neural networks.</p> <p>Selected topics in deep learning: handling different objective functions and back propagation, special topologies of deep neural networks (autoencoders, embeddings of unstructured and semi-structured data), semi-supervised learning.</p>
---	--

**Temeljni literatura in viri / Readings:**

Hastie T, Tibshirani R, Friedman J (2009) The Elements of Statistical Learning (2nd edition). New York: Springer-Verlag.

Flach P (2012) Machine learning: the art and science of algorithms that make sense of data. Cambridge: Cambridge University Press.

De Raedt L (2008) Logical and Relational Learning. Berlin: Springer-Verlag.

Predavatelj poleg tega izbere tudi primerne novejšje raziskovalne članke iz znanstvenih revij.

#### **Cilji in kompetence:**

Študent spozna napredne metode strojnega učenja, kot so strojno učenje iz podatkovnih tokov, meta učenje in avtomatska konfiguracija učnih algoritmov, upoštevanje predznanja pri strojnem učenju in učenje modelov dinamičnih sistemov. Študenti v okviru domačih in seminarskih nalog pridobljeno znanje praktično utrjujejo z nadgradnjo obstoječih algoritmov strojnega učenja in samostojno reševanje praktičnih problemov gradnje napovednih modelov iz podatkov in predznanja.

#### **Objectives and competences:**

Students master advanced machine learning methods, such as, machine learning from data streams, meta learning and automatic configuration of learning algorithms, knowledge-intensive learning and learning models of dynamical systems. Students through seminars and homework apply the mastered knowledge on various tasks of upgrading existing algorithms and building predictive models from data and formalized knowledge.

#### **Predvideni študijski rezultati:**

Znanje in razumevanje: Razumevanje konceptov in gradnikov algoritmov za strojno učenje.

Uporaba: Uporaba obstoječih algoritmov in razvoj nagrajenih algoritmov za reševanje praktičnih problemov iz različnih področij inženirstva in znanosti.

Refleksija: Kritični vpogled v delovanje algoritmov strojnega učenja in ugotavljanje možnosti za izboljšave, formalizacija praktičnih

#### **Intended learning outcomes:**

Knowledge and understanding: Understanding concepts and components of the machine learning algorithms.

Application: Applying existing algorithms and tailoring/upgrading algorithms for solving practical problems in various scientific and engineering fields.

Reflection: Critical insight into the inner workings of the machine learning algorithms and identifying opportunities for their

problemov, ki omogoča njihovo reševanje s strojnimi učenjem.

Prenosljive spretnosti – niso vezane le na en predmet: Sposobnost identifikacije, formulacije in reševanja praktičnih problemov. Sposobnost snovanja napovednih modelov z algoritmi strojnega učenja. Kritično razumevanje domače in tuje znanstvene literature. Privajanje na samostojno raziskovalno delo.

improvement, formal representation of practical problems that allow for solutions based on machine learning.

Transferable skills: Ability to identify, formulate and solve practical problems. Ability to design predictive models with machine learning algorithms. Critical assessment of scientific literature.

**Metode poučevanja in učenja:**

predavanja, seminarji, vaje, domače naloge in konzultacije

**Learning and teaching methods:**

lectures, seminars, excercises, homework and consultations

**Načini ocenjevanja:**

Delež (v %) /  
Weight (in %)

**Assessment:**

Domače naloge		Homework
Ustni izpit	60%	Oral exam
(ocene: 5 (negativno), 6-10 (pozitivno), ob upoštevanju Statuta UL)	40%	grading: 5 (fail), 6-10 (pass) (according to the Statute of UL)

**Reference nosilca / Lecturer's references:**

Ljupčo TODOROVSKI:

KUZMANOVSKI, Vladimir, TODOROVSKI, Ljupčo, DŽEROSKI, Sašo. Extensive evaluation of the

generalized relevance network approach to inferring gene regulatory networks. GigaScience, ISSN 2047-217X, [in press] 2018, 21 str., doi: 10.1093/gigascience/giy118.

LUKŠIČ, Žiga, TANEVSKI, Jovan, DŽEROSKI, Sašo, TODOROVSKI, Ljupčo. General meta-model framework for surrogate-based numerical optimization. V: YAMAMOTO, Akihiro (ur.). Discovery science : 20th International Conference, DS 2017, Kyoto, Japan, October 15-17, 2017 : proceedings, (Lecture notes in artificial intelligence, ISSN 0302-9743, LNAI 10558). Cham: Springer. 2017, INAI 10558, str. 51-66.

ŠEMROV, Darja, MARSETIČ, Rok, ŽURA, Marijan, TODOROVSKI, Ljupčo, SRDIČ, Aleksander. Reinforcement learning approach for train rescheduling on a single-track railway. Transportation research. Part B, Methodological, ISSN 0191-2615. [Print ed.], 2016, letn. 86, št. apr., str. 250-267, ilustr., doi: 10.1016/j.trb.2016.01.004.

SIMIDJIEVSKI, Nikola, TODOROVSKI, Ljupčo, DŽEROSKI, Sašo. Predicting long-term population dynamics with bagging and boosting of process-based models. Expert systems with applications, ISSN 0957-4174. [Print ed.], 2015, vol. 42, no. 22, str. 8484-8496, doi: 10.1016/j.eswa.2015.07.004.

Matija PERTNAR:

– PLOTKIN, Gordon, PRETNAR, Matija. Handling algebraic effects. Logical methods in computer science, ISSN 1860-5974, 2013, vol. 9, iss. 4, paper 23 (str. 1-36) [COBISS.SI-ID 16816729]

– PRETNAR, Matija. Inferring algebraic effects. Logical methods in computer science, ISSN 1860-5974, 2014, vol. 10, iss. 3, paper 21 (str. 1-43) [COBISS.SI-ID 17190745]

– BAUER, Andrej, PRETNAR, Matija. An effect system for algebraic effects and handlers. Logical methods in computer science, ISSN 1860-5974, 2014, vol. 10, iss. 4, paper 9 (str. 1-29). <http://arxiv.org/pdf/1306.6316> [COBISS.SI-ID 17191001]

