



Студијски програм: Мастер академске студије информатике					
Назив предмета: МАШИНСКО УЧЕЊЕ 1					
Статус предмета: Обавезан на модулу Наука о подацима, изборан на модулу Рачунарске науке					
Број ЕСПБ: 6					
Услов: Уписан одговарајући семестар					
Циљ предмета Оспособљавање студената за разумевање и практичну примену концепата надгледаног машинског учења у домену регресије и класификације.					
Исход предмета Савладано градиво омогућава студенту да: <ul style="list-style-type: none">• Разуме кључне појмове машинског учења (теоријске претпоставке, математичке основе, предности и недостатке алгоритама надгледаног и ненадгледаног машинског учења).• Разликује базне приступе машинском учењу (параметарски/непараметарски, фреквентистички/Бајесовски)• Примени поступак избора и евалуације оптималних модела за дати проблем.• Ефикасно примени фундаменталне алгоритме регресије и класификације на проблеме средње сложености.					
Садржај предмета <i>Теоријска настава</i> Области примене. Концепти машинског учења. Надгледано учење. Ненадгледано учење. Предикција. Модели. Учење хипотеза. Сложеност модела. Шум. Унакрсна провера. Функција губитка. Функција грешке. Регресија. Средња квадратна грешка. Пробабалистичка интерпретација. Метод најмањих квадрата. Алгоритми учења. Параметри и хиперпараметри. Правило уланчавања. Градијенти спуст. Перцептрон. Регресија и класификација са линеарним моделима. Линеарни модели. Вишеструке линеарне регресије. Бинарна класификација. Сигмоидна функција. Логистичка регресија. Грешка унакрсне ентропије. Градијенти спуст логистичке регресије. Њутн-Рафсонова метода. Бајесов класификатор. Мултиномијална класификација. Стабла одлучивања. ID3 алгоритам. Непараметарски модели. Методе најближих суседа. k-NN (k-Nearest Neighbors). Нелинеарна класификација и регресија. Вештачке неуронске мреже са простирањем унапред. Overfitting. Underfitting. Регуларизација. Активационе функције у ANN. Softmax функција. Алгоритам backpropagation. Језгрене функције. RBF језгра. Методе вектора подршке (Support Vector Machine-SVM). Проблем максималне маргине. Квадратно програмирање. Лагранжеова дуалност. Оптимизација максималне маргине. Дуални модел SVM-а. Вредновање класификатора. Конфузиона матрице. Гласање. „No free lunch” теорема. Stacking. Bagging. Boosting. Boosted regression trees.					
<i>Практична настава</i> Примена софтверских алата и имплементација решења у R окружењу (пакети: neuralnet, base пакет, MASS, H2o, Keras, Tensorflow, MXnet, e1071, class...). Рад на вежбама подразумева примену стеченог знања на решавање конкретних задатака у домену надгледаног машинског учења.					
Литература <ol style="list-style-type: none">1. Ethem Alpaydın , Introduction to Machine Learning, Third Edition, The MIT Press Cambridge, Massachusetts, London, England, 2014.2. John D. Kelleher, Brian Mac Namee, Aoife D’Arcy, Fundamentals of machine learning for predictive data analytics, Algorithms, Worked Examples, and Case Studies, The MIT Press Cambridge, Massachusetts, London, England, 2015.3. Kevin P. Murphy, Machine Learning: A Probabilistic Perspective, The MIT Press Cambridge, Massachusetts, London, England, 2012.4. Stuart Russel, Peter Norwig, Veštačka inteligencija, savremeni pristup, prevod trećeg izdanja, RAF Računarski fakultet, Beograd/ CET Computer Equipment and Trade, Beograd / Portalibris, Beograd, 2011.					
Број часова	активне наставе	Теоријска настава:	2	Практична настава:	1 + 2
Методе извођења наставе Проблемски-оријентисана настава, практична настава и вежбе уз софтверску подршку, самостални рад студената и консултације.					
Оцена знања (максимални број поена 100)					
Предиспитне обавезе	70	поена	Завршни испит	30	поена
активност у току предавања			писмени испит		20
практична настава	20		усмени испит		10
колоквијум-и	20				
семинар-и	30				