Ekonomski fakultet / EKONOMIJA / METODE DUBINSKE ANALIZE PODATAKA

Uslovljenost drugim predmetima	Nema
Ciljevi izučavanja predmeta	Upoznavanje sa inteligentnim metodama za dubinsku analizu - rudarenje podataka (data mining) i njihovim primjenama u ekonomiji
Ime i prezime nastavnika i saradnika	Prof dr Ljiljana Kašćelan
Metod nastave i savladanja gradiva	Predavanja, vježbe, praktični rad u kompjuterskoj učionici i konsultacije
I nedjelja, pred.	Big Data – pojam, karakteristike, primjeri
I nedjelja, vježbe	-II-
II nedjelja, pred.	Rudarenje podataka (Data Mining-DM) / Rapid Miner
II nedjelja, vježbe	-II-
III nedjelja, pred.	DM funkcije i metode / Rapid Miner
III nedjelja, vježbe	-II-
IV nedjelja, pred.	Priprema podataka za DM proces/ Rapid Miner
IV nedjelja, vježbe	-II-
V nedjelja, pred.	Proces mašinskog (induktivnog) učenja / Rapid Miner
V nedjelja, vježbe	-II-
VI nedjelja, pred.	Linearna regresija/ Rapid Miner
VI nedjelja, vježbe	-II-
VII nedjelja, pred.	Klasterizacija – K-means metod/ Rapid Miner
VII nedjelja, vježbe	-II-
VIII nedjelja, pred.	Klasifikacija – metod Drvo odlučivanja (Decision Tree-DT)/ Rapid Miner
VIII nedjelja, vježbe	-II-
IX nedjelja, pred.	Klasifikacija klasterizacije / Rapid Miner
IX nedjelja, vježbe	-II-
X nedjelja, pred.	Primjeri/Rapid Miner
X nedjelja, vježbe	-II-
XI nedjelja, pred.	Kolokvijum
XI nedjelja, vježbe	-II-
XII nedjelja, pred.	Projektni zadatak- definisanje studije; izbor metoda; priprema podataka/ Rapid Miner
XII nedjelja, vježbe	-II-
XIII nedjelja, pred.	Projektni zadatak- izgradnja modela/ Rapid Miner
XIII nedjelja, vježbe	-II-
XIV nedjelja, pred.	Projektni zadatak- evaluacija modela i tumačenje rezultata/ Rapid Miner
XIV nedjelja, vježbe	-II-
XV nedjelja, pred.	Prezentacija projekta
XV nedjelja, vježbe	-II-
Obaveze studenta u toku nastave	Prisustvo predavanjima i vježbama, aktivnost na času i izrada projekta
Konsultacije	U terminima istaknutim na sajtu
Opterećenje studenta u casovima	Nedjeljno 4 kredita x 40/30 = 5 sati 20 minuta Struktura: 1 sat i 30 minuta za predavanja 1 sat i 30 minuta za vježbe 2 sata i 20 minuta samostalnog rada studenta, uključujući i konsultacije. U semestru Ukupno opterećenje za predmet 4 x 30 = 120 sati Struktura: Nastava i završni ispit: 5 sati 20 min x 16 nedelja= 85 sati 20 min Neophodne pripreme prije početka semestra (administracija, upis, ovjera): 5 sati 20 min x 2 = 10 sati 40 minuta . Dopunski rad za pripremu i polaganje ispita u popravnom roku: 24 sata.

Literatura	1. Dietrich, D., Data science and big data analytics: discovering, analyzing, visualizing and presenting data. John Wiley & Sons, 2015 2. RapidMiner Studio Manual
Oblici provjere znanja i ocjenjivanje	- Domaći zadaci 20 bodova - Kolokvijum 30 bodova - Završni ispit (projekat) 50 bodova
Posebne naznake za predmet	
Napomena	
Ishodi učenja	Nakon što student položi ovaj ispit, biće u mogućnosti da: 1. Kompetentno objašnjava osnovne data mining (DM) metode i kombinuje ih dizajnirajući modele za probleme iz ekonomije 2. Kasifikuje i bira DM metode zavisno od vrste ekonomskog problema 3. Integriše i preuređuje podatke iz različitih izvora i priprema u odgovarajućem formatu za analizu 4. Kreira analitičke i prediktivne modele pomoću DM alata i objašnjava njihove performanse 5. Formuliše i objašnjava tumačenje i interpretaciju DM modela