ECTS KATALOG SA ISHODIMA UČENJA
Univerzitet Crne Gore

Elektrotehnički fakultet / RAČUNARI / Osnovi mašinskog učenja i vještačke inteligencije

Naziv predmeta:	Osnovi mašinskog učenja i vještačke inteligencije			
Šifra predmeta	**Status predmeta**	**Semestar**	**Broj ECTS kredita**	**Fond časova** (P+V+L)
12804	Obavezan	1	5	3+1+1
Studijski programi za koje se organizuje	RAČUNARI			
Uslovljenost drugim predmetima	Ekspertni sistemi			
Ciljevi izučavanja predmeta	Izučavanjem ovog predmeta studenti treba da steknu fundamentalna znanja iz inženjerski atraktivne oblasti vještačke inteligencije - mašinskog učenja. Predmet je fokusiran na principe, tehnike i metode mašinskog učenja koje se široko koriste u rješavanju praktičnih problema. Pored detaljnog izučavanja prateće teorije, razmatrane tehnike mašinskog učenja se implementiraju na računaru u programskom jeziku Python, i njihov značaj demonstrirana u rješavanju konkretnih problema. U sklopu predmeta vrši se detaljna analiza performansi razmatranih tehnika, diskutuje se njihova upotrebljivost, ograničenja i izazovi koje ih prate.			
Ishodi učenja	Nakon što student položi ovaj ispit biće u mogućnosti da: formira model problema koji želi riješiti primjenom tehnika mašinskog učenja; razumije algoritme mašinskog učenja, mogućnosti i nedostatke njihove primjene pri rješavanju konkretnih problema; primijeni adekvatnu matematičku aparaturu, algoritme i tehnike mašinskog učenja na konkretne podatke i u rješavanju konkretnih problema, te izvrši njihovo prilagođavanje i modifikovanje u slučaju potrebe; opiše i interpretira rezultate primjene tehnika mašinskog učenja; razumije matematičke i teorijske koncepte na kojima počivaju algoritmi mašinskog učenja; modeluje i simulira podatke i eksperimente neophodne za analizu, verifikaciju i komparaciju kako postojećih tako i modifikovanih, odnosno, novorazvijenih tehnika mašinskog učenja.			
Ime i prezime nastavnika i saradnika	nastavnik: Prof. dr Vesna Popović-Bugarin saradnik: Danilo Planinić, Spec. Sci. Elektronika, telekomunikacije i računari			
Metod nastave i savladanja gradiva	Metod nastave i savladavanja gradiva: Predavanja, računske i laboratorijske vježbe, konsultacije, samostalni rad.			
Plan i program rada				
Pripremne nedjelje	Priprema i upis semestra			
I nedjelja, pred.	Uvod. Podjela (nadgledano, nenadgledano učenje i učenje sa podrškom).			
I nedjelja, vježbe	Kratki kurs Python-a.			
II nedjelja, pred.	Linearna i polinomijalna regresija, metod gradijentnog spusta.			
II nedjelja, vježbe	Python: Grafika i NumPy biblioteka			
III nedjelja, pred.	Logistička regresija. Regularizacija.			
III nedjelja, vježbe	Realizacija zadate regularizacije u Python-u.			
IV nedjelja, pred.	Neuralne mreže, arhitektura i propagacija unaprijed.			
IV nedjelja, vježbe	Realizacija zadate regularizacije u Python-u.			
V nedjelja, pred.	Učenje neuralnih mreža. Algoritam za propagaciju unazad (backpropagation).			
V nedjelja, vježbe	Realizacija neuralnih mreža u Python-u.			
VI nedjelja, pred.	Teorija mašinskog učenja: procjena hipoteze, bias, varijansa i regularizacija, kriva učenja.			
VI nedjelja, vježbe	Unaprijeđenje algoritma mašinskog učenja realizovanog u Python-u primjenom teorije mašinskog učenja.			
VII nedjelja, pred.	Dizajn sistema za mašinsko učenje. Analiza i metrike grešaka.			
VII nedjelja, vježbe	Unaprijeđenje algoritma mašinskog učenja realizovanog u Python-u primjenom teorije mašinskog učenja.			
VIII nedjelja, pred.	Kolokvijum			
VIII nedjelja, vježbe	Kolokvijum			
IX nedjelja, pred.	Metoda potpornih vektora (Support vector machine).			
IX nedjelja, vježbe	Realizacija metode potpornih vektora u Python-u.			
X nedjelja, pred.	Stabla odlučivanja. Random Forest algoritam.			
X nedjelja, vježbe	Realizacija decision tree i random forest algoritma korišćenjem Python-a.			

XI nedjelja, pred.	Nenadgledano učenje. K-means klasterizacija. Redukcija dimenzionalnosti. Analiza primarne komponente (Principal component analysis). Rekonstrukcija iz kompresovane reprezentacije.
XI nedjelja, vježbe	Realizacija k-means algoritma, redukcije dimenzionalnosti i rekonstrukcije korišćenjem Python-a.
XII nedjelja, pred.	Detekcija anomalija.
XII nedjelja, vježbe	Realizacija detekcije anomalija korišćenjem Python-a.
XIII nedjelja, pred.	Sistemi za davanje preporuka.
XIII nedjelja, vježbe	Realizacija sistema za davanje podrške odlučivanju korišćenjem Python-a.
XIV nedjelja, pred.	Učenje sa podrškom (Reinforcement learning).
XIV nedjelja, vježbe	Praktični rad sa velikom količinom podataka.
XV nedjelja, pred.	Kritička i etička razmatranja u mašinskom učenju i vještačkoj inteligenciji.
XV nedjelja, vježbe	Paralelizacija
Opterećenje studenta	5 kredita x 40/30 = 8 sati Struktura: 3 sata predavanja 1 sat računskih vježbi 1 sat laboratorijskih vježbi 3 sata samostalnog rada, uključujući konsultacije

Nedjeljno	**U toku semestra**
5 kredita x 40/30=6 sati i 40 minuta 3 sat(a) teorijskog predavanja 1 sat(a) praktičnog predavanja 1 vježbi **1 sat(a) i 40 minuta** samostalnog rada, uključujući i konsultacije	Nastava i završni ispit: **6 sati i 40 minuta x 16 =106 sati i 40 minuta** Neophodna priprema prije početka semestra (administracija, upis, ovjera): **6 sati i 40 minuta x 2 =13 sati i 20 minuta** Ukupno opterećenje za predmet: **5 x 30=150 sati** Dopunski rad za pripremu ispita u popravnom ispitnom roku, uključujući i polaganje popravnog ispita od 0 do 30 sati (preostalo vrijeme od prve dvije stavke do ukupnog opterećenja za predmet) **30 sati i 0 minuta** Struktura opterećenja: **106 sati i 40 minuta (nastava), 13 sati i 20 minuta (priprema), 30 sati i 0 minuta (dopunski rad)**
Obaveze studenta u toku nastave	Redovno prisustvo nastavi, primjereno vladanje, pohađanje provjera znanja.
Konsultacije	Nakon predavanja, a po potrebi po dogovoru.
Literatura	Materijali sa predavanja, Stuart Russell & Peter Norvig, (2009). Artificial Intelligence – A Modern Approach.
Oblici provjere znanja i ocjenjivanje	Laboratorijske vježbe 20 poena Miniprojekti 50 poena Završni ispit 30 poena
Posebne naznake za predmet	
Napomena	

Ocjena:	F	E	D	C	B	A
Broj poena	manje od 50 poena	više ili jednako 50 poena i manje od 60 poena	više ili jednako 60 poena i manje od 70 poena	više ili jednako 70 poena i manje od 80 poena	više ili jednako 80 poena i manje od 90 poena	više ili jednako 90 poena