

S V E U Č I L I Š T E U S P L I T U

Prirodoslovno-matematički fakultet u Splitu

ELABORAT O STUDIJSKOM PROGRAMU

SVEUČILIŠNI DIPLOMSKI STUDIJ PODATKOVNA ZNANOST I INŽENJERSTVO

Split, siječanj 2025

OSNOVNE INFORMACIJE O VISOKOM UČILIŠTU

Naziv visokog učilišta	Prirodoslovno-matematički fakultet u Splitu
Adresa	Ruđera Boškovića 33, 21000, Split, Hrvatska
OIB	20858497843
Telefon	021/619 222
E-mail adresa	dekanat@pmfst.hr
Web stranica	http://www.pmfst.unist.hr/

OPĆE INFORMACIJE O STUDIJSKOM PROGRAMU

Naziv studijskog programa	Podatkovna znanost i inženjerstvo
Nositelj studijskoga programa	Sveučilište u Splitu
Sunositelj studijskoga programa	-
Izvoditelj/i studijskog programa	Prirodoslovno-matematički fakultet u Splitu
Vrsta	Sveučilišni
Razina	Diplomski
Razina HKO-a/EQF-a/QF-EHEA	HKO: 7.1.sv/EQF: 7/QF-EHEA: 2
Znanstveno ili umjetničko područje i polje studija	Područje: Prirodne znanosti, Polje: Matematika
Prema klasifikaciji ISCED FoET	0613
Trajanje studija (godina)	2
Broj ECTS bodova koji se stječu završetkom studija	120
Akademski/stručni naziv koji se stječe po završetku studija	sveučilišni magistar podatkovne znanosti i inženjerstva/sveučilišna magistra podatkovne znanosti i inženjerstva
Jezik izvođenja studija	Hrvatski
Mjesto izvođenja studija	Split
Način izvođenja studija (klasično, hibridno, online)	Klasično
Upisna kvota (za studente u redovitom i u izvanrednom statusu)	20

1. UVOD

1.1. Analiza usklađenosti studija sa strateškim ciljevima visokog učilišta

Sveučilišni diplomski studij Podatkovna znanost i inženjerstvo usklađen je sa strateškim ciljevima Strategije razvoja Prirodoslovno - matematičkog fakulteta u Splitu za razdoblje od 2023.- 2030. i Strategije Sveučilišta u Splitu 2021.-2025.
U Strategiji razvoja Prirodoslovno – matematičkog fakulteta misija Fakulteta uključuje organiziranje diplomskih studija te je posebno istaknuta tradicionalno prisutna misija Fakulteta koja uključuje unaprjeđivanje obrazovanja u osnovnim i srednjim školama iz matematike, fizike, kemije, biologije, informatike i politehnike u Republici Hrvatskoj i široj zajednici. Jedan od ključnih strateških ciljeva je Unaprjeđenje studijskih programa, uključujući suvremene metode studiranja te razvoj vještina koje jačaju konkurentnost na tržištu rada.
U svojoj strategiji Sveučilište u Splitu kao misiju navodi čuvanje znanja kao javnog dobra te stalno stvaranje i unaprjeđenje istraživanjem i inovacijama i ugrađivanje u lokalnu i širu društvenu zajednicu, naročito u gospodarstvo transferom znanja i tehnologija. Ključna aktivnost je privlačiti i motivirati studente da najbolje iskoriste priliku edukacije te ih stalno poticati na istraživački rad, inovacije, stvaralačke izazove i posebno na preuzimanje vodstva u struci i društvu.

1.2. Analiza minimalnih institucionalnih pretpostavki za usporedivost predloženih studijskih programa sa srodnim akreditiranim studijskim programima u Republici Hrvatskoj i u zemljama Europske unije

Prirodoslovno-matematički fakultet Sveučilišta u Splitu permanentno prati razvoj visokog obrazovanja u svijetu, a posebno u Europi. Tako se i pri izradi nastavnog plana i programa diplomskog studija Podatkovna znanost i inženjerstvo vodilo računa o usklađivanju nastavnih programa i kolegija s drugim uglednim inozemnim učilištima kako bi se potakla mobilnost studenata i nastavnog osoblja. Utvrđen je visok stupanj usporedivosti predloženog programa s programima sljedećih visokoškolskih institucija:

· „Master's of Computer and Data Science" koji organizira University of Ljubljana, Faculty of computer and information science, Slovenija (više o studijskom programu može se naći na stranicama https://datascience.fri.uni-lj.si/masters/).
· „Data Science" koji organizira EIT Digital Master School u obliku dvostrukog programa kod kojeg se mogu birati dvije europske zemlje u kojima se može studirati. Ovakav način organizacije studija omogućuje dinamičko kreiranje kurikuluma (više o studijskom programu može se naći na stranicama https://masterschool.eitdigital.eu/programmes/dsc/).
Studij se organizira u suradnji sljedećih 17 tehničkih europskih sveučilišta:
- Aalto University (Aalto)
- Budapest University of Technology and Economics (BME)
- Eindhoven University of Technology (TUE)
- Eötvös Lorand University (ELTE)

- EURECOM
- Politecnico di Milano (POLIMI)
- KTH Royal Institute of Technology (KTH)
- Sorbonne University (SU)
- Tallinn University of Technology (TalTech)
- Technical University of Berlin (TUB)
- Technical University of Madrid (UPM)
- Université Côte d'Azur (UCA) - former UNS
- University of Rennes 1 (UR1)
- University of Trento (UNITN)
- University of Turku (UTU)
- University of Twente (UT)
- Université Paris-Saclay (UPS) - (formerly Université Paris Sud)

· Osim navedenog, predloženi studijski program usporediv je sa studijskim programom pod nazivom „Master of Computer Science: Data Science" koji organizira University of Antwerp, Belgija (više o studijskom programu može se naći na stranicama https://www.uantwerpen.be/en/study/education-and-training/master-data-science/study-programme/).
U ovom trenutku u Hrvatskoj ne postoji sveučilišni studijski program sličan našem prijedlogu. Naš studijskih program je jedinstven u Hrvatskoj, a većim dijelom i u širem kontekstu regije, osim značajnog primjera iz Slovenije (Ljubljana) i izvan sveučilišne subspecijalizacije [Algebra]. Iako je naš program u principu nov u nacionalnom i regionalnom kontekstu, ranije smo u tekstu naveli da trenutni kapacitet tržišta za apsorpcijom podatkovnih znanstvenika i inženjera uvelike nadmašuje naš trenutni kapacitet za obrazovanjem ovih stručnjaka. Stoga se nadamo da će naš prijedlog poslužiti jačanju šire međusveučilišne inicijative za reviziju postojećih diplomskih studija računarstva i usmjeriti ih prema analizi podataka i strojnom učenju.

1.3. Mehanizmi osiguravanja horizontalne i vertikalne mobilnosti studenata u nacionalnom i europskom prostoru visokog obrazovanja

Prirodoslovno-matematički fakultet Sveučilišta u Splitu podržava otvorenost studija i studentske pokretljivosti unutar Republike Hrvatske i u širem europskom obrazovnom prostoru, u skladu sa zahtjevima Bolonjske deklaracije. Horizontalna mobilnost studenata omogućena je organizacijom nastave po semestrima (svi kolegiji su jednosemestralni), te mogućnošću polaganja ispita odmah nakon što je kolegij odslušan tj. studiranjem „godina za godinu". Vertikalna, ali i horizontalna, mobilnost među sveučilištima u Hrvatskoj se potiče raznovrsnom i komplementarnom ponudom izbornih i obaveznih kolegija u odnosu na slične studije u Hrvatskoj, a moguća je zbog kompatibilnih studija na preddiplomskoj razini potrebnih za upis ovog studija.
Jedan od važnih elemenata poticanja mobilnosti studenata, kao i provođenja bolonjskog procesa u cijelosti je dinamika studiranja (studiranje godina za godinu) što će se potaknuti na nekoliko načina:
- Primjerenom opterećenošću studenata
- Pojačanim angažmanom nastavnika i studenata u pogledu redovitog prisustva nastavi te učestalim provjerama znanja studenata pomoću testova, kolokvija i drugih

metoda.
Navedenim se studente potiče na kontinuiran rad tijekom trajanja nastave iz određenog kolegija i pruža im se mogućnost polaganja istog odmah nakon što je odslušan.
Predloženi program sveučilišnog diplomskog studija i njegova usporedivost sa srodnim studijima u Republici Hrvatskoj i zemljama EU omogućava pokretljivost studenata i nastavnog osoblja. Pokretljivost se može realizirati kroz upis pojedinih predmeta na studijima drugih fakulteta, cijelog semestra na srodnim fakultetima ili kroz izradu diplomskog rada.
Fakultet je potpisnik ERASMUS sporazuma za mobilnost nastavnika i studenata s:
Vienna University of Technology, Charles University in Prague, Staffordshire University, Université Paul Sabatier Toulouse II, Universite Claude Bernard LYON01,
Alexandar Technological Educational Institute of Thessaloniki, University of the Aegean, University of Trieste, Universita' degli studi di Genova, Universita' degli studi di Genova, Universita degli studi di Perugia, Universita degli studi del Sannio, Vytautas Magnus University, University of Skopje, University of Bremen, Coburg University of Applied Sciences and Arts, Kiel University, University of Bielsko-Biala, AGH University of Science and Technology, Czestochowa University of Technology, University of Ljubljana, University of Maribor, Lund University, Slovak University of Technology in Bratislava, University of Niš, Abant Izzet Baysal University, Izmir Institute of Technology, Istanbul Medeniyet University, Giresun University.

1.4. Uvjeti upisa na studij, uvjeti upisa u idući semestar, trimestar ili studijsku godinu te uvjeti upisa drugih studijskih obveza

Sveučilišni diplomski studij Podatkovna znanost i inženjerstvo mogu upisati kandidati sa završenim sveučilišnim ili iznimno stručnim prijediplomskim studijem sa stečenih minimalno180 ECTS bodova (razina 6.sv ili 6.st u Hrvatskom kvalifikacijskom okviru, razina 6 u Europskom kvalifikacijskom okviru (EQF).
Uvjeti upisa na studij utvrđuju se odlukom Fakultetskog vijeća za svaku godinu i sastavni su dio javnog natječaja za upise. Uvjeti upisa u iduću akademsku godinu te uvjeti upisa drugih studijskih obveza na sveučilišnom diplomskom studiju detaljno su propisani Pravilnikom o studiju i studiranju na prijediplomskim i diplomskim studijima na Prirodoslovno – matematičkom fakultetu u Splitu (19.07.2024.).

1.5. Kompetencije koje se stječu završetkom modula studija i studija

Diplomski studij Podatkovne znanosti i inženjerstva osposobljava magistre za neposredno uključivanje u radna okruženja u kojima je nužno upravljanje i analiza velikih količina podataka, primjena metoda strojnog učenja te razvoj podatkovno utemeljenih rješenja. Program je ujedno kvalitetna priprema za poslijediplomski znanstveni ili stručni studij u području podatkovnih znanosti, umjetne inteligencije i računalne znanosti.
Završetkom studija magistri stječu kompetencije potrebne za rješavanje složenih problema obrade podataka, uključujući matematičko modeliranje, razvoj i primjenu algoritama strojnog učenja, implementaciju sustava za pohranu i analizu velikih skupova podataka te vizualizaciju i interpretaciju rezultata. Kroz projektno orijentirane kolegije i praktični rad studenti razvijaju sposobnosti samostalnog i

timskog rada na interdisciplinarnim projektima, uz pridržavanje visokih etičkih standarda u radu s podacima.

1.6. Ustroj i oblik izvođenja nastave

Nastava se ustrojava po semestrima i izvodi prema rasporedu sukladno akademskom kalendaru. O održanoj nastavi i prisustvovanju studenata svim oblicima nastave vodi se elektronička evidencija.
Sveučilišni diplomski studij traje 4 semestara, obuhvaća obvezne i izborne kolegije, a temelji se na aktivnom sudjelovanju studenata u svim oblicima nastave (predavanja, auditorne vježbe, vježbe u praktikumu, seminari, stručna praksa i slično).
Oblici izvođenja nastave određeni su studijskim programom i detaljnije propisane obveze studenata izvedbenim planom i Pravilnikom o studiju i studiranju na prijediplomskim i diplomskim studijima na Prirodoslovno – matematičkom fakultetu u Splitu (19.07.2024.).

1.7. Završetak studija

Način završetka studija	Diplomski rad
Uvjeti za prijavu završnog/diplomskog rada i/ili završnog diplomskog ispita	Obrani Diplomskog rada može pristupiti student koji je položio sve ispite i ispunio druge obveze utvrđene studijskim programom i čiji je napisani rad pozitivno ocjenjen od strane Povjerenstva za ocjenu i obranu diplomskog rada. .
Postupak vrjednovanja završnog/diplomskog ispita te vrjednovanje i obrane završnog/diplomskoga rada	Postupak vrjednovanja Diplomskog rada propisan je Pravilnikom o studiju i studiranju na prijediplomskim i diplomskim studijima na Prirodoslovno – matematičkom fakultetu u Splitu (19.07.2024.)

2. POPIS I OPIS KOLEGIJA

2.1. Popis obaveznih i izbornih kolegija

Popis kolegija							
Godina studija: 1.							
Semestar: 1.							
Status	Kod	Kolegij	Nositelj/i kolegija	Sati u semestru			ECTS
				P	S	V	
Obvezni		Linearna algebra, optimizacija i statistika	Damir Vukičević	30	0	30	7
	PMIH21	Strojno učenje	Saša Mladenović	30	0	30	5
	PMIH25	Uvod u podatkovnu znanost	Divna Krpan	30	0	30	5
	PMIH24	Uvod u podatkovnu znanost - primjeri dobre prakse	Divna Krpan	15	45	15	5
	PMID16	Znanstveno programiranje	Dino Nejašmić	45	0	45	8
	Ukupno obvezni			150	45	150	30
Izborni							
*P=Predavanja, S=Seminari, V=Vježbe							

Popis kolegija							
Godina studija: 1.							
Semestar: 2.							
Status	Kod	Kolegij	Nositelj/i kolegija	Sati u semestru			ECTS
				P	S	V	
Obvezni	PMIH*	Odabrana poglavlja relacijskih baza podataka	Monika Mladenović	0	30	0	2
	PMIH70	Podaci i etika	Marko Rosić	30	30	0	5
	PMIZ15	Projekt - prva godina	Saša Mladenović	0	30	30	8
	PMIH12	Raspodijeljene i nerelacijske baze podataka	Monika Mladenović	30	0	30	5
	PMIH29	Strojno učenje - trendovi i teme istraživanja	Saša Mladenović	15	45	15	5
	Ukupno obvezni			75	135	75	25
Izborni	Student upisuje barem 5 ECTS bodova.						
	PMIE20	Algoritmi u bioinformatici	Damir Vukičević	30	0	30	5
	PMIK25	Analitika učenja	Ani Grubišić	30	0	30	5
	PMIH27	Analiza mreža	Hrvoje Kalinić, Nikola Balić	30	0	30	5
*P=Predavanja, S=Seminari, V=Vježbe							

Popis kolegija							
Godina studija: 2.							
Semestar: 3.							
Status	Kod	Kolegij	Nositelj/i kolegija	Sati u semestru			ECTS
				P	S	V	
Obvezni	PMII15	Arhitekture neuronskih mreža	Goran Zaharija	30	0	30	5
	PMIZ56	Diplomski rad - priprema	Saša Mladenović	0	30	0	5
	PMID40	Paralelno programiranje	Tonći Dadić	30	0	30	5
	PMII65	Vizualizacija podataka	Goran Zaharija	30	0	30	5
	Ukupno obvezni			90	30	90	20
Izborni	Student upisuje barem 10 ECTS bodova.						
	PMII45	Obrada prirodnog jezika	Branko Žitko	30	0	30	5
	PMIH28	Poslovna analitika	Marko Rosić	30	0	30	5
	PMIH22	Strojno učenje u bioinformatici i medicini	Dino Nejašmić	30	0	30	5
*P=Predavanja, S=Seminari, V=Vježbe							

Popis kolegija							
Godina studija: 2.							
Semestar: 4.							
Status	Kod	Kolegij	Nositelj/i kolegija	Sati u semestru			ECTS
				P	S	V	
Obvezni	PMIZ55	Diplomski rad		0	0	0	30
	Ukupno obvezni			0	0	0	30
Izborni							
*P=Predavanja, S=Seminari, V=Vježbe							

2.2. Opis kolegija

Naziv kolegija	Linearna algebra, optimizacija i statistika					
Kod		Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Damir Vukičević	Bodovna vrijednost (ECTS)	7.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	0	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija			
Ciljevi kolegija			
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij			
Ishodi učenja			
Vrste izvođenja nastave	☐ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐
Obveze studenata			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu			

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	-		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja			
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Strojno učenje</td></tr>
<tr><td>Kod</td><td>PMIH21</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Saša Mladenović</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">25%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj predmeta je upoznati polaznike sa granom umjetne inteligencije koja se bavi oblikovanjem algoritama temeljenih na prikupljenim podacima. Osnove strojnog učenja nalaze svoju primjenu pri raspoznavanju uzoraka, rudarenja podataka, bioinformatike, obrade prirodnog jezika, robotike, autonomnih vozila s čime će se polaznici upoznati. Kroz kolegij polaznici će se upoznati s metodama nadziranog i nenadziranog učenja koje će primijeniti na područje od interesa.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Položen kolegij Uvod u umjetnu inteligenciju.
Položen kolegij Strukture podataka i algoritmi.
Položen Algoritmi u primjeni.
Dobro poznavanje objektno orijentirane paradigme programiranja
Dobro poznavanje područja primijenjene statistike</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Definirati temeljne pojmove strojnog učenja

Objasniti prednosti i nedostatke temeljnih algoritama strojnog učenja za odabrano područje od interesa

Vrednovati uspješnost različitih modela

Oblikovati i primijeniti algoritme klasifikacije i grupiranja podataka i vrednovati ih

Na primjeru izrađene aplikacije iz područja od interesa pokazati mogućnosti primjene strojnog učenja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Uvod u strojno učenje i motivacija za primjenu strojnog učenja

Različiti pristupi strojnom učenju i okruženja za primjenu

Dimenzionalnost problema, pristranost, generalizacija i problem uvježbavanja

Probabilistički modeli. Bayesov klasifikator.

Linearan model regresije, Logistički model regresije, prednosti i nedostaci.

Linearno razdvojivi problemi, perceptron i poopćenje razdvojivosti temeljeno na višeslojnom perceptronu.

Stroj potpornih vektora, jezgrene funkcije i regresija.</td></tr>
</table>

	Neparametrijski postupci i regresija. Algoritam k-najbližih susjeda. Stabla odluke. Odabir značajki, vizualizacije podataka i rezultata uvježbavanja. Grupiranje podataka, algoritam k-srednjih vrijednosti, hijerarhijsko grupiranje. Aktualna područja primjene strojnog učenja Kako do podataka? Način prikupljanja podataka. Etička pitanja primjene strojnog učenja.

Vrste izvođenja nastave			
	☑ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐

Obveze studenata	
	Pohađanje nastave. Redovito rješavanje domaćih radova i izrada projektnog zadatka. Samostalni rad u izradi i prezentiranju projekta i istraživanja na zadanu temu..

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave	1	Istraživanje	0.5	Praktični rad	1
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji	0.5	Usmeni ispit			
Pismeni ispit	0.5	Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Kanber, Burak. Hands-on Machine Learning with JavaScript: Solve complex computational web problems using machine learning. Packt Publishing Ltd, 2018.		
	Ng, A. "Machine learning yearning: Technical strategy for ai engineers in the era of deep learning." (2019).		
	Ethem Alpaydin; Introduction to Machine Learning, Fourth Edition; MIT press, 2020.		

Dopunska literatura	
	Prema odabranoj temi projekta

Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	
	Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.

Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Uvod u podatkovnu znanost</td></tr>
<tr><td>Kod</td><td>PMIH25</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Divna Krpan</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">20%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Podatci su u današnjem društvu dostupni u dosad neviđenom i neprekidno rastućem opsegu, te u različitim oblicima (tekst, slika, multimedija) i razinama strukturiranosti. Cilj je kolegija u teorijskom dijelu predstaviti podatkovnu znanost, koja obuhvaća suvremene pristupe prikupljanju, strukturiranju, analizi, i zaključivanju povrh raznorodnih masivnih skupova podataka.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5"></td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">- opisati osnovne pristupe podatkovne znanosti kao primijenjene matematike i statistike, te primijenjene računalne znanosti
- primijeniti metode podatkovne znanosti na raznorodne masivne skupove tekstnih i multimedijskih podataka
- pronalaziti znanje u skupovima podataka pomoću vlastitih programskih rješenja temeljenih na principima podatkovne znanosti
- koristiti programske biblioteke za obradu velikih skupova podataka, prije svega one temeljene na metodama znanstvenog računanja
- vizualizirati pronalaske u velikim kolekcijama podataka
- prepoznati mogućnosti uporabe podatkovne znanosti u širokom skupu znanstvenih, tehnoloških, industrijskih, i društvenih primjena
- raspravljati o tehnološkom i društvenom utjecaju podatkovne znanosti, posebno s obzirom na odnos tehnološkog razvoja i etičkih ograničenja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Podatkovna znanost i znanstvena metoda (2+2)
Osnove dohvata, pripreme, i strukturiranja podataka (2+2)
Preliminarno istraživanje i tumačenje podataka (i) (2+2)
Istraživanje (ii): Varijabilnost, uzorkovanje, vizualizacija (2+2)
Predviđanje nad podatcima (i) (2+2)
Predviđanje (ii): Korelacija, regresija, klasifikacija (2+2)
Statističko zaključivanje iz podataka (i) (2+2)
Zaključivanje (ii): Testiranje hipoteza, pouzdanost, pogreške u zaključivanju (2+2)
Praktično strojno učenje za obradu podataka (2+2)
Pristupi obradi masivnih skupova podataka (2+2)
Primjene podatkovne znanosti u obradi slike i teksta (2+2)
Podatkovna znanost u društvenim istraživanjima (2+2)
Etička pitanja u podatkovnoj znanosti (2+2)
Ograničenja i aktivna područja istraživanja (2+2)
Priprema za ispit (2+2)</td></tr>
<tr><td>Vrste izvođenja nastave</td><td colspan="2">☑ Predavanja</td><td colspan="2">☐ Terenska nastava</td><td>☐</td></tr>
</table>

	☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje		☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad		☐ ☐ ☐	
Obveze studenata	Usmeni ispit Izrada seminarskih radova Samostalni zadaci					
Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)	Pohađanje nastave	0.5	Istraživanje		Praktični rad	0.5
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	0.5		
	Kolokviji		Usmeni ispit	2.5		
	Pismeni ispit	0.5	Projekt	0.5		
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Usmeni ispit (70%), seminari (30%)					

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Grus: Data Science from Scratch--- First Principles with Python. 2015.		
	Hastie, Tibshirani, Friedman. The Elements of Statistical Learning: Data Mining, Inference, and Prediction. 2013.		
	Igual, Segui: Introduction to Data Science. 2017.		

Dopunska literatura	Znanstveni radovi i popularni radovi iz područja podatkovne znanosti.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="3">Uvod u podatkovnu znanost - primjeri dobre prakse</td></tr>
<tr><td>Kod</td><td>PMIH24</td><td>Godina studija</td><td>1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Divna Krpan</td><td>Bodovna vrijednost (ECTS)</td><td>5.0</td></tr>
<tr><td>Suradnici</td><td></td><td>Način izvođenja nastave (broj sati u semestru)</td><td>P: 15 | S: 45 | V: 15 | T: 0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td>40%</td></tr>
<tr><td colspan="4">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="3">Podatci su u današnjem društvu dostupni u dosad neviđenom i neprekidno rastućem opsegu, te u različitim oblicima (tekst, slika, multimedija) i razinama strukturiranosti. Cilj je kolegija u teorijskom dijelu predstaviti primjere dobre prakse uporabe podatkovne znanosti za rješavanje problema iz različitih domena. Naglasak se stavlja na izradu seminara koja obuhvaća pregled suvremenih pristupa prikupljanju, strukturiranju, analizi, i zaključivanju povrh raznorodnih masivnih skupova podataka za odabrano područje primjene.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="3"></td></tr>
<tr><td>Ishodi učenja</td><td colspan="3">- opisati osnovne pristupe podatkovne znanosti rješavanju problema iz konkretnog područja

- primijeniti metode podatkovne znanosti na raznorodne masivne skupove tekstnih i multimedijskih podataka na primjeru analize i razumijevanja teksta

- pronalaziti znanje u skupovima podataka pomoću vlastitih programskih rješenja temeljenih na principima podatkovne znanosti na primjeru bankovnih podataka

- koristiti programske biblioteke za obradu velikih skupova podataka, prije svega one temeljene na metodama znanstvenog računanja na primjeru društvenih mreža

- vizualizirati pronalaske u velikim kolekcijama podataka na primjeru društvenih mreža

- prepoznati mogućnosti uporabe podatkovne znanosti u širokom skupu znanstvenih, tehnoloških, industrijskih, i društvenih primjena od medicine, prometa, financija, analize i sinteze teksta</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="3">Podatkovna znanost i znanstvena metoda u industriji

Osnove dohvata, pripreme, i strukturiranja podataka u financijskom sektoru

Preliminarno istraživanje i tumačenje podataka na primjeru zdravstva
(i) Istraživanje (ii): Varijabilnost, uzorkovanje, vizualizacija

Predviđanje nad podatcima na primjeru vremenskih serija</td></tr>
</table>

	(i) Predviđanje (ii): Korelacija, regresija, klasifikacija Statističko zaključivanje iz podataka (i) Zaključivanje (ii): Testiranje hipoteza, pouzdanost, pogreške u zaključivanju Praktično strojno učenje za obradu podataka Pristupi obradi masivnih skupova podataka Primjene podatkovne znanosti u obradi slike i teksta na primjeru medicinske dijagnostike Podatkovna znanost u društvenim istraživanjima na primjeru ponašanja skupine Etička pitanja u podatkovnoj znanosti na primjeru osiguravajućih društava

Vrste izvođenja nastave			
	☑ Predavanja ☑ Seminari ☑ Vježbe ☐ On line u cijelosti ☑ Mješovito e-učenje	☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☑ Mentorski rad	☑ Domaće zadaće ☐ ☐ ☐

Obveze studenata
Usmeni ispit Prikazi seminarskih radova Samostalni zadaci

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave	0.5	Istraživanje		Praktični rad	0.5
Eksperimentalni rad		Referat			
Esej		Seminarski rad	1		
Kolokviji		Usmeni ispit	2		
Pismeni ispit		Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu
Praktični dio (projekt i seminar) (70%), usmeni ispit(30%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Kleppmann, Martin. Designing data-intensive applications: The big ideas behind reliable, scalable, and maintainable systems. " O'Reilly Media, Inc.", 2017.	0	
	Consoli, Sergio, Diego Reforgiato Recupero, and Michaela Saisana. Data Science for Economics and Finance: Methodologies and Applications. Springer Nature, 2021.	0	

	Consoli, Sergio, D. Reforgiato Recupero, and Milan Petkovic. Data science for healthcare. Berlin: Springer International Publishing, 2019	0	
Dopunska literatura	Znanstveni radovi i popularni radovi iz područja podatkovne znanosti.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Znanstveno programiranje</td></tr>
<tr><td>Kod</td><td>PMID16</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>Dino Nejašmić, pred.</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">8.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>45</td><td>0</td><td>45</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">25%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj kolegija je naučiti kako koristiti računalo kao sredstvo za automatizaciju procesa
i pravljenje velikih, brzih i skalabilnih rješenja te korištenje složenih algoritama. Kolegij
govori o vizualizaciji kao i upravljanju podacima i kodom, kao sastavnim dijelom
znanstvenog programiranja. Posebno se raspravlja o integraciji i multiprocesiranju
kao sredstvu za analizu velikih količina (numeričkih) podataka te o skalabilnosti
rješenja s velikim brojem podataka</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5"></td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Primjeniti odgovarajuće stukture podataka i algoritama za zadani problem
2. Primjeniti paradigmu svojstvenih paralelnom/funkcijskom programiranju
3. Vizualizirati rezultate i izvještavanje rezultata kodom
4. Primjeniti numeričke biblioteke za rješavanje algebarskih i statističkih problema
5. Analizirati složenosti algoritma
6. Organizirati program u funkcije i module
7. Razumjeti internu strukturu operacijskog sustava i njegovu jezgre
8. Napisati skriptu za izvršavanje u jezgri operacijskog sustava</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Uvod u računarstvo, operacijske sustave i jezgru operacijskog sustava
2. Datotečni sustav, privilegije i uloge, Unix ljuska, redirekcija
3. Napredne naredbe za rad u ljusci: bash, grep, awk...
4. Python: varijable, vrste vrijednost, strukture i iteracije
5. Python: funkcije, imenovanja, dosezi i moduli
6. Objektno orjentirano programiranje u Python-u
7. Python: labda račun, liste, funkcijsko programiranje
8. Python za linearnu algebru i numeričko računanje: numpy, scipy...
9. Strukture podataka, dohvat i pohrana podataka
10. Python za analizu podataka: pandas, sklearn...
11. Python u primjeni: sklearn, pandas...
12. Plotting za izvještavanje: matplotlib i jupyter
13. Upravljanje verzijama koda, integracija i optimizacija koda
14. Osnove paralelizacije koda u Unix ljusci i Pythonu; skalabilnos</td></tr>
<tr><td>Vrste izvođenja nastave</td><td colspan="2">☑ Predavanja
☐ Seminari</td><td colspan="2">☐ Terenska nastava
☑ Samostalni zadaci</td><td>☐
☐</td></tr>
</table>

	☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Multimedija ☑ Laboratorij ☐ Mentorski rad	☐ ☐
Obveze studenata	Prisustvo na predavanjima i vježbama, aktivno sudjelovanje na nastavnim aktivnostima, izrada domaćih radova, ispit.		

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
	Pohađanje nastave	2	Istraživanje		Praktični rad	2
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit	1.5		
	Pismeni ispit	1.5	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	C. Hill: Learning Scientific programming with Python	1	
	C. Fuehrer, J.E. Solem, O. Verdier: Scientific Computing with Python 3	1	
	M. Kerrisk: The Linux Programming Interface	1	
	H. P. Langtangen: A Primer on Scientific Programming with Python		da

Dopunska literatura	
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata na kolegiju, samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Algoritmi u bioinformatici</td></tr>
<tr><td>Kod</td><td>PMIE20</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Damir Vukičević</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="3">0%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj kolegija je, na osnovi usvojenog znanja u prethodnim kolegijima, uvesti osnovne pojmove i metode računarskih znanosti u primjenama u biomedicini i biologiji. Odnosno, upoznati studente s osnovnim algoritmima u bioinformatici.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Osnove struktura podatka te osnove programiranja.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Od studenata/ica se nakon odrađenog kolegija očekuje da:

znaju kako upotrijebiti dinamičko programiranje (DP) kod usporedbe znakovnih nizova

znaju kako pomoću dinamičkog programiranja mogu poravnavati višestruke znakovne nizove

znaju kako primijeniti pohlepne algoritme u primjenama u bioinformatici

znaju kako se k-mer indeksi definiraju te kako ih mogu upotrijebiti za egzaktno i aproksimativno pretraživanje znakovnih nizova

znaju kako sastavljanje genoma radi

znaju što su Markovljevi lanci te skriveni Markovljevi lanci te kako se mogu primijeniti kod modeliranja svojstava znakovnih nizova

su sposobni implementirati poznate algoritme i strukture podataka u bioinformatici te ih primijeniti na stvarnim podacima

prepoznati različite oblike poznatih problema te primijeniti, odnosno prilagoditi, algoritme varijantama tih problema

odabrati između različitih metoda onu koja je najprimjerenija danom problemu u bioinformatici</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Uvod u osnove biologije (genomike)

Osnove statistike u bioinformatici

Sekvencioniranje genoma

Dinamičko programiranje

Pohlepni algoritmi</td></tr>
</table>

	Udaljenost među nizovima znakova (stringovima) Prepoznavanje motiva Poravnanje nizova znakova (stringova) Taksonomska klasifikacija (Clustering) Metagenomika i sastavljanje genoma
Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	Pohađanje nastave.

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)					
Pohađanje nastave	1	Istraživanje		Praktični rad	
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji		Usmeni ispit	2		
Pismeni ispit	2	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Tijekom semestra studentu pišu dva kolokvija. Uspješno položeni kolokviji oslobađaju od pismenog dijela ispita na samo jednom, po volji izabranom, ispitnom roku. Konačna ocjena se formira kao aritmetička sredina ocjene na pismenom dijelu ispita i ocjene na usmenom dijelu ispita.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	P.Compeau, P. Pevzner, “Bioinformatics Algorithms: An Active Learning Approach”, 2018, Active Learning Publishers		

Dopunska literatura	M. Rocha, P.G. Ferreira, “Bioinformatics Algorithms: Design and Implementation in Python”, 2018, Academic Press http://rosalind.info
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Statistika ispitnih rezultata i studentsko evaluiranje putem anonimne ankete na kraju izvedbe predmeta. Anketa se provodi prema pravilniku Sveučilišta u Splitu.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Analitika učenja</td></tr>
<tr><td>Kod</td><td>PMIK25</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Ani Grubišić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="3">30%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj je steći znanja o primjeni analitike učenja u računalom potpomognutom procesu učenja i poučavanja.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Uvjeti za upis: nema ih.
Ulazne kompetencije: poznavanje osnova rada na računalu.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Opisati analitiku učenja i usporediti je s rudarenjem podataka u obrazovanju (eng. educational data mining).
2. Analizirati, planirati i postaviti analitiku učenja za malo pilot istraživanje, naglasiti namjeru i navesti alate koji će se koristiti za ostvarivanje ciljeva analize.
3. Razviti matricu istaknutih alata za analitiku učenja s istaknutim strategijama analize.
4. Vrednovati trenutno stanje tehnologija za analitiku učenja te opisati prednosti i nedostatke open source alata i komercijalnih alata.
5. Vrednovati i opisati ulogu analitike učenja u sustavima za e-učenje.
6. Provesti osnovne analitičke aktivnosti (npr. uvoz i vizualizacija podataka) putem open source alata (npr. R ili Python).
7. Interpretirati podatke prikupljene u sustavima za e-učenje.
8. Ispitati skupove podataka da bi se dobo uvid o tome kako su studenti uključeni u sustavima e-učenja.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Analitika učenja: definicija, dimenzije, okruženje (2h P)
2. Modeliranje predviđanja u analitici učenja: veliki skupovi podataka (eng. Big Data) i obrazovanje, regresori, klasifikatori (4h P, 4h V)
3. Vrednovanje modela: pouzdanost, dijagnostika, prekomjerna specijalizacija (4h P, 4h V)
4. Otkrivanje uzoraka ponašanja, usklađivanje podataka, inženjerstvo znanja (2h P, 2h V)
5. Zaključivanje iz podataka: Bayesove metode, analiza čimbenika (4h P, 4h V)
6. Rudarenje odnosa: korelacije, pronalaženje kauzalnosti, otkrivanje slijednih obrazaca, analiza mreža (4h P, 4h V)
7. Grupiranje i faktorska analiza: algoritmi grupiranja, validacija i odabir, faktorska analiza (4h P, 4h V)
8. Nadzorna ploča analitike učenja: krivulje učenja, grafovi i dijagrami stanja, vizualizacija podataka (4h P, 4h V)
9. Korištenje podataka za omogućavanje personalizirane podrške učenicima (2h P, 4h V)</td></tr>
<tr><td>Vrste izvođenja nastave</td><td colspan="2">☑ Predavanja
☐ Seminari</td><td colspan="2">☐ Terenska nastava
☑ Samostalni zadaci</td><td>☐
☐</td></tr>
</table>

<table>
<tr><td></td><td>☑ Vježbe
☐ On line u cijelosti
☐ Mješovito e-učenje</td><td>☐ Multimedija
☐ Laboratorij
☐ Mentorski rad</td><td>☐
☐</td></tr>
<tr><td>Obveze studenata</td><td colspan="3">Pohađanje nastave, izrada projekta</td></tr>
<tr><td>Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td colspan="3">
<table>
<tr><td>Pohađanje nastave</td><td>2</td><td>Istraživanje</td><td>0.5</td><td>Praktični rad</td><td>1</td></tr>
<tr><td>Eksperimentalni rad</td><td></td><td>Referat</td><td></td><td></td><td></td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td></td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td>0.5</td><td>Usmeni ispit</td><td>0.5</td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td>0.5</td><td>Projekt</td><td></td><td></td><td></td></tr>
</table>
</td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="3">1. Domaće zadaće (25%)
2. Izvještaj o projektu (25%)
3. Pisani ispit (50%)</td></tr>
<tr><td>Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3">
<table>
<tr><th>Naslov</th><th>Broj primjeraka u knjižnici</th><th>Dostupnost putem ostalih medija</th></tr>
<tr><td>The Handbook of Learning Analytics, Editors: Charles Lang, George Siemens, Alyssa Wise, Dragan Gašević, ISBN: 978-0-9952408-0-3, DOI: 10.18608/hla17</td><td></td><td>Online</td></tr>
<tr><td>Baker, R.S. (2018) Big Data and Education. 4th Edition. Philadelphia, PA: University of Pennsylvania.</td><td></td><td>Online</td></tr>
</table>
</td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">Nisbet, R., Elder, J., Miner, G. (2009). Handbook of Statistical Analysis & Data Mining Applications. Elsevier, Inc: London UK. ISBN-13: 978-0123747655
Sclater, N. (2017). Learning Analytics Explained. New York, USA: Taylor & Francis.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

Naziv kolegija	Analiza mreža					
Kod	PMIH27	Godina studija	1.			
Nositelj/i kolegija	Nikola Balić izv. prof. dr. sc. Hrvoje Kalinić	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	0	30	0
Status kolegija	Izborni	Postotak primjene e-učenja	30%			

Opis kolegija	
Ciljevi kolegija	Kompleksne mreže modeliraju velik broj društvenih, znanstvenih i inženjerskih fenomena kojima je zajednička ogromna količina podataka te dinamika i interakcija velikih razmjera. Predmet predstavlja praktičan uvod u opis, izradu, analizu i primjenu kompleksnih mreža u stvarnom svijetu
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Kombinatorna i diskretna matematika. Uvod u podatkovnu znanost.
Ishodi učenja	Po usvajanju kolegija, studenti će biti osposobljeni: 1. prepoznati različite vrste kompleksnih mreža 2. opisati stvarne kompleksne mreže kao grafove 3. izraditi programski kod za stvaranje, pohranu i analizu mreža 4. analizirati dinamiku kompleksnih mreža 5. trenirati i predviđati modelima strojnog učenja za kompleksne mreže 6. primijeniti kompleksne mreže na stvarne probleme
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod i pregled kolegija 2. Kompleksne mreže u znanosti i društvu 3. Kompleksne mreže kao grafovi: osnovni pojmovi 4. Osnovne metrike za analizu mreža 5. Svojstva stvarnih kompleksnih mreža 6. Modeli kompleksnih mreža 7. Strojno učenje i predviđanje nad mrežama 8. Pronalaženje zajednica u mrežama 9. Dinamika mreža: rast, razvoj, restrukturiranje 10. Propagacija kroz mreže: utjecaji i epidemije 11. Mreže i pretraživanje 12. Evolucija kompleksnih mreža 13. Implementacijski izazovi sa stvarnim kompleksnim mrežama 14. Napredne teme: višerazinske i temporalne mreže, igre na mrežama 15. Prikazi grupnih radova i priprema za ispit
Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	Usmeni ispit. Prikazi seminarskih radova.
Praćenje rada studenata (*upisati udio u ECTS*	Pohađanje nastave 1.5 | Istraživanje | Praktični rad

bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	1.5		
	Kolokviji		Usmeni ispit	2		
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	1. Domaće zadaće (25%) 2. Izvještaj o projektu (25%) 3. Pisani ispit (50%		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Barabasi, A. 2018. Network Science (online textbook)		
	Newman, M. 2010. Networks: An Introduction. Oxford University Press, 1st edition.		
Dopunska literatura	Kopal, R.; Korkut, D.; Krnjašić, S.: Analiza (socijalnih) mreža: praktična primjena, Zagreb, 2016. znanstveni radovi i popularni radovi iz podrucja analize kompleksnih mreža		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Odabrana poglavlja relacijskih baza podataka</td></tr>
<tr><td>Kod</td><td>PMIH*</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Monika Mladenović</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">2.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>0</td><td>30</td><td>0</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">35%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Razumjeti prednosti i ograničenja obrade velike količine podataka pohranjene u relacijsku bazu podataka. Proširenja znanja o relacijskim bazama podataka. Složeni tipovi podataka. Na primjeru pretraživanje teksta u relacijskim bazama podataka uočiti prednosti i ograničenja ovog modela. Upoznati napredno korištenje SQL-a Upotrijebiti sustave za upravljanje relacijskim bazama podataka. Za zadani problem iz realnog svijeta opisan prirodnim jezikom kreirati primjereni relacijski podatkovni model te ostvariti bazu podataka primjenom izabranog modela.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Uvjeti za upis: nema ih.

Ulazne kompetencije: korisnička razina upotrebe operacijskog sustava, poznavanje pojmova objektnog programiranja, osnovno znanje jezika C#.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Student će moći:

1. objasniti prednosti i mane relacijskih baza podataka

2. definirati osnovne pojmove relacijskog modela podataka

3. upotrijebiti i demonstrirati izvršavanje SQL upita.

5. oblikovati relacijski model problema iz realnog svijeta opisanih prirodnim jezikom.

6. upotrijebiti SQL upitni jezik pri pretraživanju i ažuriranju relacijske baze podataka

7. razumjeti plan izvršavanja SQL upita i ulogu indeksa pri tome

8. Upotrijebiti spremljene procedure, funkcije i okidače (engl. triggers).

9. Definirati skladište podataka (data warehouse), ciljevi i svrhu skladištenja podataka.

10. Modelirati skladište podataka</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Pojmovi modela relacijskih podataka. Relacijska algebra: operacije spajanja, presjek, razlike, projekcije i ograničenja. Nepotpune informacije i NULL vrijednost. Svojstva jezika relacijskog upita SQL.

SQL sintaksa i semantika: odabir odakle. Često korištene funkcije u upitima. Operacije s NULL vrijednostima.</td></tr>
</table>

	Relacijska algebra: theta i prirodno spajanje, operacije agregacije. SQL sintaksa i semantika: unutarnji spoj, lijevi i desni vanjski spoj i potpuni spoj. Upiti za vježbe za pripremljenu bazu podataka. Pogledi. DDL dio SQL jezika. Coddova pravila. Struktura tipičnog sustava upravljanja relacijskim bazama podataka. SQL sintaksa i semantika: umetanje u, ažuriranje, brisanje, stvaranje, mijenjanje i ispuštanje. Oblikovanje modela relacijskih podataka. Integritet i dosljednost baze podataka. Ograničenja za očuvanje integriteta. Sažeci SQL -a. Skupljanje SQL upita: grupiranje prema – having. Skladište podataka. Modeliranje i realizacija Ovisnost o funkcionalnim podacima. Postupci normalizacije. Normalni oblici: 1NF, 2NF i 3NF, Boyce-Codd, 4NF4 i 5NF. Predstavljanje SQL plana izvođenja. ER model: Određivanje entiteta i njihovih atributa. Vrste veza između entiteta. Dekompozicija veze M: N. Rekurzivna veza. Izrada ER modela na temelju analize problema prirodnog jezika. Indeksi. Optimizacija SQL upita. Materijalizirani pogledi. Optimizacija SQL upita.

Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐
Obveze studenata	Pohađanje predavanja 70%, pohađanje vježbi 70%, 3 domaće zadaće, 2 kolokvija, pismeni ispit i usmeni ispit. Studenti koji su uspješni na kolokvijima oslobađeni su pismenog ispita.		

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave	0.5	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad				
Kolokviji	0.5	Usmeni ispit	0.5			
Pismeni ispit	0.5	Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Aktivnost studenata na predavanjima i vježbama (prisutnost na predavanjima i vježbama, rješavanje zadataka iz domaćih zadaća) (20 %). Pismeni dio ispita (40 %) Usmeni dio ispita (40%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija

	Ardeleanu, Stefan. Relational database programming: a set-oriented approach. Apress, 2016.		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Podaci i etika</td></tr>
<tr><td>Kod</td><td>PMIH70</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Marko Rosić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>30</td><td>0</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">20%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Proširivanje područja razmatranja pri analizi novih podatkovnih tehnologija u svijetu
informacijsko-komunikacijske tehnologije kroz etičke i sigurnosne aspekte. Podići
razinu prepoznavanja i poštivanja intelektualnog vlasništva unutar svijeta
informacijske i komunikacijske tehnologije. Uvođenje razmatranja sigurnosti osobnih
podataka pojedinaca pri razvoju sustava gdje ova prava mogu biti ugrožena.
Usvajanje elemenata upravljanja rizikom unutar promatranog područja.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5"></td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Analizirati problem, odnosno situaciju vezano za etička pitanja u promatranom području
2. Razlučivati bitno od nebitnog (apstrahirati) unutar promatranog područja
3. Kritički vrednovati probleme, situacije, procese i rješenja u poslovnom
okruženju vezano za korištenje velikih skupova podataka
4. Vrednovati računalne modele i sa stajališta područja koja se obrađuju unutar
ovog kolegija
5. Definirati potencijalna područja rizika pri razvoju sustava IKT-a (unutar tema
obrađenih kolegijem).</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Kibernetički pogled na ljudsku prirodu (3)
2. Računarstvo i ljudske vrijednosti (3)
3. Informacijsko bogatstvo i siromaštvo (2)
4. Prava pristupa digitalnim sadržajima (2)
5. Prava privatnosti, pravila dijeljenja osobnih informacija, transparentnost
prema korisnicima (2)
6. Pitanja tehnologija koje se mogu koristiti za nadzor pojedinca (2)
7. Pitanja strojnog odlučivanje (granice i područja gdje se odlučivanje može
prepustiti strojevima, izbjegavanje stvaranja nejednakosti uslijed strojnog
odlučivanja) (4)
8. Postoji li „preautomatiziranost“ (granica kada automatizacija smanjuje</td></tr>
</table>

<table>
<tr><td></td><td>kvalitet života) (2)
9. Problem vječnih digitalnih zapisa (2)
10. Sigurnost (Tko odlučuje je li nova tehnologija sigurna?) (4)
11. Samomodificirajuće i samorepli cirajuće tehnologije (4)</td></tr>
<tr><td>Vrste izvođenja nastave</td><td>☑ Predavanja
☑ Seminari
☐ Vježbe
☐ On line u cijelosti
☑ Mješovito e-učenje
☐ Terenska nastava
☐ Samostalni zadaci
☐ Multimedija
☐ Laboratorij
☐ Mentorski rad
☐
☐
☐
☐</td></tr>
<tr><td>Obveze studenata</td><td>Pohađanje nastave, izrada seminarskog rada te njegovo izlaganje.</td></tr>
<tr><td>Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td>
<table>
<tr><td>Pohađanje nastave</td><td>1.5</td><td>Istraživanje</td><td></td><td>Praktični rad</td><td></td></tr>
<tr><td>Eksperimentalni rad</td><td></td><td>Referat</td><td></td><td></td><td></td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td>1.5</td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td></td><td>Usmeni ispit</td><td>2</td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td></td><td>Projekt</td><td></td><td></td><td></td></tr>
</table>
</td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td>Sudjelovanje u aktivnostima (40%), Usmeni ispit (60%</td></tr>
<tr><td>Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>
<table>
<tr><th>Naslov</th><th>Broj primjeraka u knjižnici</th><th>Dostupnost putem ostalih medija</th></tr>
<tr><td>Bynum T. 2015 Computer and information ethics. In The Stanford encyclopedia of philosophy (ed. EN Zalta), Winter 2015. See http://plato.stanford.edu/archives/win 2015/entries/et hicscomputer/.</td><td></td><td></td></tr>
<tr><td>Floridi L. 2013 The ethics of information. Oxford, UK: Oxford University Press.</td><td></td><td></td></tr>
</table>
</td></tr>
<tr><td>Dopunska literatura</td><td></td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td>Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu,
samoanaliza</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td></td></tr>
</table>

Naziv kolegija	Projekt - prva godina					
Kod	PMIZ15	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Saša Mladenović	Bodovna vrijednost (ECTS)	8.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	30	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Primijeniti znanje i vještine prikupljene za vrijeme studija u rješavanju specifičnih problema.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	nema preduvjeta
Ishodi učenja	1. Procijeniti mogućnost primjene podatkovne znanosti i inženjerstva s osvrtom na socijalne i etičke aspekte primjenjive u temeljnoj struci. 2. Analizirati i procijeniti mogućnosti i ograničenja podatkovne znanosti i inženjerstva, njihovu ulogu u društvu i odgovornost pojedinca za njihovo korištenje, 3. Primijeniti vještine potrebne za sudjelovanje u primjeni i istraživanju podatkovne znanosti i inženjerstvu. 4. Samostalno provoditi istraživanja i primijeniti rezultate istraživanja u temeljnoj struci koristeći postupak rješavanja problema primjeren podatkovnoj znanosti i inženjerstvu. 5. Izraditi projektnu dokumentaciju prema pravilima struke uzimajući u obzir objašnjivost projekta.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Temelji metodologije istraživanja u umjetnoj inteligenciji 2. Kako izraditi informatički projekt 3. Priprema za rad na projektu i pripadajuća dokumentacija te seminar 4. Priprema prezentacije projekta
Vrste izvođenja nastave	☐ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☑ Mentorski rad
Obveze studenata	Pohađajte seminara i vježbi, rješavanje domaće zadaće i drugih zadataka

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
	Pohađanje nastave	1.5	Istraživanje	1	Praktični rad	2.5
	Eksperimentalni rad		Referat		Obrana projekta	1
	Esej		Seminarski rad		Izrada dokumentacije	1
	Kolokviji		Usmeni ispit			
	Pismeni ispit		Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Projekt i seminar 40% Usmeno izlaganje i obrana projekta 60%		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Software Engineering (10th edition) Authors: Ian Sommerville Publisher: Pearson 2016.		
	Empirical Methods for Artificial Intelligence Author: Paul R. Cohen		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor sa studentima, aktivno sudjelovanje, evaluacija mentora i povjerenstva		
Ostalo (prema mišljenju predlagatelja)	Anonimna anketa, izravna povratna informacija, uspjeh na ispitu, samoprocjena		

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Raspodijeljene i nerelacijske baze podataka</td></tr>
<tr><td>Kod</td><td>PMIH12</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Monika Mladenović</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">35%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Razumjeti problem obrade velike količine podataka – Big data. Upotrijebiti sustave za upravljanje relacijskim te nerelacijskim bazama podataka. Za zadani problem iz realnog svijeta opisan prirodnim jezikom odabrati primjereni podatkovni model (relacijski, dokument, ključ-vrijednost, usmjeren kolonama ili graf orijentiran) te ostvariti bazu podataka primjenom izabranog modela.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Položen kolegij Baze podataka.
Za studente koji nemaju navedeni kolegij u svom studijskom programu nužno je ovladati kompetencijama koje navedeni kolegij pružaju kako bi uspješno pratili kolegij.
Ulazne kompetencije: korisnička razina upotrebe operacijskog sustava.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Student će moći:
1. objasniti razliku između relacijskih i nerelacijskih (NoSQL) baza podataka
2. objasniti ograničenja prema CAP teoremu.
3. definirati osnovne pojmove relacijskog i nerelacijskog modela podataka
4. upotrijebiti i demonstrirati izvršavanje ACID i BASE raspodijeljenih transakcija.
5. oblikovati relacijski model jednostavnijih problema iz realnog svijeta opisanih prirodnim jezikom.
6. upotrijebiti SQL upitni jezik pri pretraživanju i ažuriranju relacijske baze podataka
7. razumjeti plan izvršavanja SQL upita i ulogu indeksa pri tome
8. Upotrijebiti spremljene procedure, funkcije i okidače (engl. triggers).
9. Ostvariti distribuciju relacijske baze podataka.
10. Upotrijebiti NoSQL bazu podataka.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1.Uvod u temu. Podaci i informacije. Uloga baza podataka u informacijskom sustavu.
Povijesni razvoj baza podataka: datotečne, hijerarhijske, mrežne, relacijske i NoSQL.
Veliki podaci - problem obrade petabajta podataka. Distribucija podataka poslužiteljima u klasteru.
Ograničenja prema teoremu CAP.
2.Transakcija, log i oporavak (engl. Recovery)
3. Spremljene procedure i funkcije
4. Okidači (engl. Trigger) i pogledi (engl. View)
5. Primjer raspodijeljene relacijske baze podataka
6. Mongo DB
7. Upiti u mongo DB
9. Indeksiranje i agregiranje u Mongo DB</td></tr>
</table>

	11. Napredni Mongo DB: raspodjela podataka i praćenje performansi 12. Ključ-vrijednost baza podataka 13. Stupčaste baze podataka 14. Graf baze podataka 15. Neki primjeri upotrebe NoSQL baza podataka

Vrste izvođenja nastave			
	☑ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐

Obveze studenata	Pohađanje predavanja, pohađanje vježbi, domaće zadaće, kolokviji, pismeni ispit te izrada i obrana projekta.

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave	1	Istraživanje		Praktični rad	1
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji		Usmeni ispit	2		
Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Aktivnost studenata na predavanjima i vježbama (prisutnost na predavanjima i vježbama, rješavanje zadataka iz domaćih zadaća), kolokvij, projekt i obrana.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Pramod J. Sadalage, Martin Fowler: NoSQL Distilled, Addison-Wesley, Pearson Education, Upper Saddle River, New Jersey 07458, ISBN-13: 978-0-321-82662-6		
	Sullivan, Dan. NoSQL for mere mortals. Addison-Wesley Professional, 2015.		

Dopunska literatura	
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Strojno učenje - trendovi i teme istraživanja</td></tr>
<tr><td>Kod</td><td>PMIH29</td><td>Godina studija</td><td colspan="3">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Saša Mladenović</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>15</td><td>45</td><td>15</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">35%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj predmeta je upoznati polaznike s trendovima i temama istraživanja u području strojnog učenja kao jedne od grana umjetne inteligencije koja se bavi oblikovanjem algoritama temeljenih na prikupljenim podacima. Mnoštvo istraživanja u posljednjem desetljeću dovelo je do eksponencijalnog rasta broja objavljenih znanstvenih radova iz područja strojnog učenja. Kako bi se mogli usredotočiti na radove od interesa za vlastito istraživanje nužno je upoznati se s trendovima i temama kojima se bavi strojno učenje. Iako osnovne ideje algoritama strojnog učenja ostaju očuvane, sami algoritmi značajno se razlikuju s obzirom na temu istraživanja i trend. Kroz kolegij polaznici će se upoznati s metodama tehnikama i alatima koje će primijeniti pri realizaciji vlastitog istraživanja.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">1. Položen kolegij Uvod u umjetnu inteligenciju
2. Dobro poznavanje osnovnih algoritama strojnog učenja
3. Dobro poznavanje područja primijenjene statistike

Napomena: Ovi uvjeti i kompetencije su potrebni kako bi se osigurala čvrsta osnova za razumijevanje i učinkovito sudjelovanje u gradivu koje se obrađuje na kolegiju.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Definirati teme istraživanja strojnog učenja
2. Izraditi pregled istraženosti područja od interesa za istraživanje
3. Objasniti prednosti i nedostatke odabranih algoritama strojnog učenja s obzirom na temu istraživanja
4. Objasniti trendove u istraživanju pri uporabi strojnog učenja za rješavanje problema za zadanu temu istraživanja
5. Vrednovati uspješnost različitih modela s obzirom na oblik i dostupnost podataka
6. Oblikovati, primijeniti i vrednovati algoritme strojnog učenja s obzirom na trendove i teme istraživanja
7. Pripremiti pregledni rad i predstaviti vlastito istraživanje u obliku pogodnom za objavu.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Metodologija pregleda istraženosti područja od interesa.
Uvod u teme istraživanja strojnog učenja
Trendovi koji utječu na:
budućnost poslovanja, medija, bankarstva, uprave, rada, obrazovanja i društva
oblikovanje budućnosti zabave, igara, oglašavanja, medija, ugostiteljstva, zdravstva i drugih sektora.
novinarstvo, medije i poslovne modele koji podržavaju zabavu i vijesti
budućnost zdravstva, medicine i farmaceutskih proizvoda.</td></tr>
</table>

	potrošačku elektroniku, automatizaciju kućanstava i digitalni život. budućnost lanaca opskrbe, logistiku, robotiku, automobilsku industriju i transport. zakonodavce, vlast, geopolitiku i kibernetičku sigurnost. Različiti pristupi pretraživanju i vrednovanju znanstvenih članaka i drugih publikacija. Ponovljivost, valjanost i pouzdanost istraživanja. Pristranost i netransparentnost kao element vrednovanja etičnosti primjene strojnog učenja. Podaci i njihova dostupnost. Priprema rezultata istraživanja za objavu. Napomena: Navedene teme organizirane prema rasporedu nastave za kolegij
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☑ Mentorski rad ☑ Domaće zadaće ☐ ☐ ☐
Obveze studenata	Pohađanje nastave. Redovito rješavanje domaćih radova i izrada projektnog zadatka. Samostalni rad u izradi i prezentiranju projekta i istraživanja na zadanu temu.
Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)	Pohađanje nastave: 1 | Istraživanje: 1 | Praktični rad: Eksperimentalni rad: | Referat: | Esej: | Seminarski rad: 2 | Kolokviji: | Usmeni ispit: 1 | Pismeni ispit: | Projekt: |
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Cohen, Paul R. Empirical methods for artificial intelligence. Vol. 139. Cambridge: MIT press, 1995. (Broj primjeraka u knjižnici: ; Dostupnost putem ostalih medija:) Riezler, Stefan, and Michael Hagmann. "Validity, Reliability, and Significance: Empirical Methods for NLP and Data Science." Synthesis Lectures on Human Language Technologies 14.6 (2021): 1-165. (Broj primjeraka u knjižnici: ; Dostupnost putem ostalih medija:)
Dopunska literatura	Prema odabranoj temi projekta
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Arhitekture neuronskih mreža</td></tr>
<tr><td>Kod</td><td>PMII15</td><td>Godina studija</td><td colspan="4">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Goran Zaharija</td><td>Bodovna vrijednost (ECTS)</td><td colspan="4">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="4">0%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Umjetne neuronske mreže i dubinsko strojno učenje (en. deep learning) u novije su vrijeme iz temelja izmijenili područje strojnog učenja, posebno s obzirom na raspon primjena u kojima nude vrhunske performanse, a također gledajući njihov industrijski potencijal. Ovaj kolegij nudi praktični pregled suvremenih metoda strojnog učenja, zasnovanih na dubinskom učenju pomoću umjetnih neuronskih mreža.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">-</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Po usvajanju kolegija, studenti će biti osposobljeni:

1. prepoznati osnovne modele dubinskog strojnog učenja: konvolucijske neuronske mreže (CNN), povratne i rekurzivne neuronske mreže (RNN, LSTM, GRU), te generativne neuronske mreže (GAN)

2. opisati osnovne algoritme za učenje u dubinskim neuronskim mrežama, temeljene na gradijentnom spustu (BP, BPTT)

3. objasniti principe robustnog dubinskog učenja pomoću regularizacije u neuronskim mrežama (L1, L2, dropout, blackout)

4. analizirati i vrjednovati neuronske mreže intrinzično i ekstrinzično

5. implementirati rješenja temeljena na dubinskom učenju pomoću suvremenih programskih biblioteka (Keras , TensorFlow)

6. oblikovati rješenja temeljena na dubinskim neuronskim mrežama, s primjenom na obradu slike, teksta, i sličnih nestrukturiranih masivnih izvora podataka</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Uvod i pregled kolegija (2+2)

2. Višeslojni perceptron (en. multilayer perceptron, MLP) i unazadna propagacija (en. backpropagation, BP) (2+2)

3. Pristupi regularizaciji neuronskih mreža (2+2)

4. Optimizacija učenja neuronskim mrežama (2+2)

5. Konvolucijske neuronske mreže (en. convolutional neural networks, CNN) (2+2)</td></tr>
</table>

6. Povratne neuronske mreže (en. recurrent neural networks, RNN) i učenje unazadnom propagacijom kroz vrijeme (en. backpropagation through time, BPTT) (2+2)

7. Rekurzivne neuronske mreže (2+2)

8. Problem nestajućih gradijenata i napredne varijante povratnih neuronskih mreža (en. long short-term memory, LSTM, en. gated recurrent unit, GRU) (2+2)

9. Generativni neuralni modeli dubinskog učenja (en. generative adversarial networks, GAN) (2+2)

10. Simultano učenje neuronskim mrežama (en. multi-task learning, MTL) (2+2)

11. Učenje vektorskih opisa podataka (2+2)

12. Praktično dubinsko učenje, parametri, i vrjednovanje (2+2)

13. Dubinsko učenje u obradi slike, teksta, i govora (2+2)

14. Ograničenja dubinskog učenja i aktivna područja istraživanja (2+2)

15. Priprema za ispit (2+2)

Vrste izvođenja nastave

☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐

Obveze studenata

Usmeni ispit

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)

Pohađanje nastave	1.5	Istraživanje		Praktični rad	
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji	0.5	Usmeni ispit			
Pismeni ispit	2	Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu

Zadaci (25%)
Projekt (25%)
Pisani ispit (50%)
Studenti trebaju položiti svaku od komponenti.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)

Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Murphy. Machine Learning: A Probabilistic Perspective. MIT Press, 2012.		
Bishop. Pattern Recognition and Machine Learning. Springer, 2010.		
Goodfellow, Bengio, Courville: Deep learning. 2016.		

	Daume III: A Course in Machine Learning. 2015.		
Dopunska literatura	Znanstveni radovi i popularni radovi iz područja dubinskog strojnog učenja.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Diplomski rad - priprema</td></tr>
<tr><td>Kod</td><td>PMIZ56</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Saša Mladenović</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>0</td><td>30</td><td>0</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">0%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">1. Demonstrirati razumijevanje različitih tehnika i pristupa u prikupljanju informacija.
2. Identificirati i formulirati problemska pitanja.
3. Pokazati sposobnost sintetiziranja informacija.
4. Prikupiti literaturu i izvore potrebne za izradu diplomskog rada.
5. Osmisliti i predstaviti strukturu i sažetak diplomskog rada.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5"></td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Osmisliti i provesti samostalno istraživanje određene problematike vezane uz podatkovnu znanost i inženjerstvo/ umjetnu inteligenciju.
2. Formulirati istraživačka pitanja.
3. Sintetizirati rezultate istraživanja.
4. Analizirati određenu problematiku odabira prikladne metode, tehnike i alata.
5. Raspraviti rezultate znanstveno-istraživačkog rada.
6. Formulirati postupke i tijek znanstveno-istraživačkog rada.
7. Kritički prosuditi izvore podataka i bibliografiju prilikom znanstveno-istraživačkog rada.
8. Prezentirati rezultate vlastitog istraživanja.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Uvod u kolegij. 2h
2. Uvod u znanstvena istraživanja u području umjetne inteligencije 2h
3. Metodologija istraživanja u umjetnoj inteligenciji 4h
4. Odabir područja i teme diplomskog rada 2h
5. Procedure vezane uz diplomski rad: od prijave teme do obrane diplomskog rada. Izrada i obrana teme diplomskog rada. 2h
6. Pronalazak i vrednovanje literature i izvora i njihovo navođenje u diplomskom radu. 4h
7. Uređivanje diplomskog rada. 2h
8. Definiranje koncepta rada, određivanje ciljeva i hipoteza. Odabir metodologije u skladu s ciljevima istraživanja. 4h
9. Problematika pripreme i/ili izrada baze podataka. Obrada podataka. 2h
8. Interpretacija rezultata. 2h
9. Izlaganja teme diplomskog rada. 4h</td></tr>
<tr><td>Vrste izvođenja nastave</td><td colspan="2">☐ Predavanja
☑ Seminari
☐ Vježbe
☐ On line u cijelosti
☐ Mješovito e-učenje</td><td colspan="2">☐ Terenska nastava
☑ Samostalni zadaci
☐ Multimedija
☐ Laboratorij
☑ Mentorski rad</td><td>☐
☐
☐
☐</td></tr>
</table>

<table>
<tr><td>Obveze studenata</td><td colspan="6"></td></tr>
<tr><td>Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td colspan="6"><table>
<tr><td>Pohađanje nastave</td><td>2</td><td>Istraživanje</td><td>2</td><td>Praktični rad</td><td></td></tr>
<tr><td>Eksperimentalni rad</td><td></td><td>Referat</td><td></td><td></td><td></td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td>1</td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td></td><td>Usmeni ispit</td><td></td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td></td><td>Projekt</td><td></td><td></td><td></td></tr>
</table></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="6"></td></tr>
<tr><td>Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="6"><table>
<tr><th>Naslov</th><th>Broj primjeraka u knjižnici</th><th>Dostupnost putem ostalih medija</th></tr>
<tr><td colspan="3">-</td></tr>
</table></td></tr>
<tr><td>Dopunska literatura</td><td colspan="6"></td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="6">Statistika ispitnih rezultata i studentska evaluacija putem anonimne ankete na kraju izvedbe predmeta. Anketa se provodi prema pravilniku Sveučilišta u Splitu.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="6"></td></tr>
</table>

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Paralelno programiranje</td></tr>
<tr><td>Kod</td><td>PMID40</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>dr. sc. Tonći Dadić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">0%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Razumijevanje paralelnog izvršavanja programa te stjecanje znanja i vještine radi ostvarenja programa zasnovanih na paralelnim algoritmima.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Objektno orijentirano programiranje.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Studenti će moći:
1. Objasniti modele paralelnog izvršavanja programa.
2. Razumjeti i objasniti pojmove procesa, niti (engl. thread), nadmetanja niti radi pristupa zajedničkim podacima, kritičnog odsječka, sinkronizacije niti te potpunog zastoja.
3. Primijeniti Amdahlov zakon radi procjene ubrzanja paralelnim izvršavanjem zadanog programa.
4. Samostalno izgraditi neke jednostavne paralelne algoritme.
5. Razumjeti neke naprednije paralelne algoritme i primijeniti ih u zadanim problemima.
6. Implementirati i vrednovati paralelne programe.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Tjedan 1:

Osnove paralelnog programiranja

Zašto paralelno programiranje?

Mooreov zakon i višejezgreni procesori

Simultano izvršavanje programa

Ciljevi paralelizacije

Kriteriji ocjene paralelnog algoritma

Amdalov zakon ubrzanja paralelnog programa

Tjedan 2:

Osnove paralelnog programiranja (nastavak)

Paralelizam, komunikacija i koordinacija programa

Programske konstrukcije za koordinaciju simultanih programa

Programske greške specifične za paralelne programe</td></tr>
</table>

	Natjecanje za pristup zajedničkim podacima (konkurentno čitanje / pisanje te pisanje / pisanje) Izostanak napredovanja programa: potpuni zastoj i izgladnjivanje niti Tjedan 3: Paralelne arhitekture računala Višejezgreni procesori Dijeljena i distribuirana memorija Arhitekture SIMD i vektorsko procesiranje Arhitektura MIMD Tjedan 4: Paralelne arhitekture računala (nastavak) Nazivlje po Flynnu Model sinkronog PRAM računala Model asinkronog PRAM računala Procesorske instrukcije nedjeljivih ciklusa čitanja i pisanja radne memorije Tjedan 5: Paralelni algoritmi, analiza i programiranje Ubrzanje i skalabilnost Prirodno paralelni algoritmi Paralelni pristupi: podijeli i vladaj, reduciraj, vođa-pratitelji Tjedan 6: Paralelni algoritmi, analiza i programiranje (nastavak) Neki specifični algoritmi: Merge i Quick sort Paralelni algoritmi pretraživanja grafa Paralelne matrične operacije Proizvođač – potrošač Tjedan 7: Algoritam redukcije za proizvoljan broj procesora Algoritam zbroja prefiksa za proizvoljni broj procesora

	Algoritam redukcije za ograničeni broj procesora Algoritam zbroja prefiksa za ograničeni broj procesora Tjedan 8: Komunikacija i koordinacija Izmjena podataka u čvrsto povezanom paralelnom sustavu Izmjena podataka u labavo povezanom sustavu Tjedan 9: Standard: MPI (engl. Message Passing Interface) Pojedinačna i kolektivna razmjena poruka Blokirajuća i neblokirajuća razmjena poruka Uloga reda pri slanju i primanju poruka Atomarnost Tjedan 10: Komunikacija i koordinacija (nastavak) Specifikacija i testiranje atomarnosti te sigurnosnih zahtjeva Zrnatost atomarnog pristupa podacima i transakcije Međusobno isključivanje niti uz pomoć zaključavanja, semfora i monitora Nužni uvjeti nastanka potpunog zastoja i njegova prevencija Transakcije: optimistični i pesimistični pristup Tjedan 11: Paralelna dekompozicija Interferencija niti i pojam kritičnog odsječka Potreba za komunikacijom i koordinacijom te sinkronizacijom niti Sinkronizacija pomoću semafora te aktivnim čekanjem Podjela zadataka particioniranjem zajedničkih podataka Tjedan 12: Paralelna dekompozicija (nastavak) Interferencija niti i pojam kritičnog odsječka Potreba za komunikacijom i koordinacijom te sinkronizacijom niti

	Sinkronizacija pomoću semafora te aktivnim čekanjem Podjela zadataka particioniranjem zajedničkih podataka Tjedan 13: Paralelna dekompozicija (nastavak) Osnovni pojmovi paralelne dekompozicije Dekompozicija utemeljena na zadacima Implementacija paralelizma pomoću niti (engl. Threads) Strategija SIMD Tjedan 14: Vrednovanje paralelnog programa Mjerenje vremenskih svojstava programa Uravnoteženje opterećenja Tjedan 15: Vrednovanje paralelnog programa (nastavak) Utvrđivanje vremena komunikacije između niti/procesa Paralelni upiti baze podataka Učinak keširanja na vrijeme izvršavanja programa

Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☑ Domaće zadaće ☐ ☐ ☐
Obveze studenata	pohađanje 70% predavanja i 70% vježbi te dva domaća rada.		

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
	Pohađanje nastave	0.5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Domaće zadaće	0.5
	Esej		Seminarski rad			
	Kolokviji	2	Usmeni ispit	2		
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pohađanje nastave 10%, domaći radovi 10%, praktični/pismeni ispit ili kolokvij 40% te usmeni ispit 40%.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija

	Domagoj Jakobović: „Predavanja iz kolegija Paralelno programiranje“, FER, Zagreb, 30.3.2015.		
	http://www.fer.unizg.hr/_download/repository/Paralelno_programiranje_predavanja%5B8%5D.pdf (dostupno 6.10.2015)		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Vizualizacija podataka</td></tr>
<tr><td>Kod</td><td>PMII65</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Goran Zaharija</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="3">25%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj kolegija je upoznati se sa osnovnim metodama i alatima za vizualizaciju podataka. Studenti će se kroz kolegij upoznati sa načinima osmišljavanja i stvaranja različitih vizualizacija ovisno o dostupnim podacima i zadanim ciljevima. Također će naučiti kako evaluirati učinkovitost različitih tipova vizualizacije i kritički se osvrnuti na način prikaza podataka (boje, skaliranje, kodiranje). Studenti će kroz kolegij izraditi vlastite vizualizacije korištenjem aktualnih alata.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Osnove programiranja(u bilo kojem jeziku). Prethodno iskustvo sa Python i/ili JavaScriptom je poželjno ali nije obavezno.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Osmisliti i izraditi osnovne vizualizacije podataka korištenjem prikladnih alata.

Vrednovati kredibilitet, etičnost i estetičnost vizualizacija podataka.

Provesti istraživačku analizu podataka korištenjem vizualizacije.

Spoznati način na koji interakcija, dizajn i znanost vizualizacije poboljšavaju osnovne aspekte vizualizacije.

Spoznati kako zaobići najčešće pogreške u vizualizaciji podataka.

Uočiti mogućnosti primjene vizualizacije podataka u stvarnim situacijama, te u različitim domenama.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Uvod u vizualizaciju podataka i web tehnologije.

Skupovi podataka, učitavanje i obrada.

Kodiranje i prikaz podataka

Uobičajeni vizualizacijski idiomi

Prostorna, mrežna i stablasta vizualizacija.

Korištenje boja i veličina (skaliranja) u vizualizaciji.

Interaktivna vizualizacija podataka

Povezani pogledi (vizualizacije)

Redukcija podataka</td></tr>
</table>

	Fokus podataka i kontekst.
Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☐ Mentorski rad ☐ ☐ ☐ ☐
Obveze studenata	Prisustvo na predavanjima i vježbama, aktivno sudjelovanje na nastavnim aktivnostima, izrada domaćih radova, ispit.

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)

Pohađanje nastave	2	Istraživanje		Praktični rad	2
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji	1	Usmeni ispit	0.5		
Pismeni ispit	0.5	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (10%) Praktični rad (30%) Pismeni/usmeni ispit (60%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)

Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
Visualization Analysis & Design, Tamara Munzner (2014). (ISBN 9781466508910)		
Alberto Cairo, The Truthful Art: Data, Charts, and Maps for Communication (Berkeley, California: New Riders, 2016).		
Stephanie D. H. Evergreen, Effective Data Visualization: The Right Chart for the Right Data (Thousand Oaks, CA: Sage, 2017).		

Dopunska literatura	Nastavni materijali dostupni na Internetu, uključujući rješenja odabranih zadataka te dodatna znanstvena literatura
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata na kolegiju, samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Obrada prirodnog jezika</td></tr>
<tr><td>Kod</td><td>PMII45</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Branko Žitko</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="3">0%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">➢ Upoznavanje arhitekture i modela podataka sustava e-učenja, te njihovog
utjecaja na komunikaciju između korisnika i sustava.
➢ Komparativna analiza sustava e-učenja zasnovanih na obradi prirodnog
jezika.
➢ Upoznavanje faza obrade prirodnog jezika: od generiranja do prepoznavanja jezika.
➢ Povezivanje područnog znanja i komunikacijskog sučelja.
➢ Modeliranje inteligentnog tutorskog sustava zasnovanog na obradi
kontroliranog jezika</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Ulazne kompetencije: linearna algebra i vjerojatnost</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. opisati metode obrade prirodnog jezika
2. oblikovati proces razumijevanja i generiranja prirodnog jezika
3. usporediti sustave e-učenja u odnosu na obradu prirodnog jezika
4. evaluirati obradu prirodnog jezika u sustavima e-učenja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Predavanje1:
Uvod u obradu prirodnog jezika. Vrste obrade prirodnog jezika. Označavanje
gramatičkih kategorija. Imenovani entiteti. Rješavanje višesmislenosti riječi.
Ekstrakcija informacija. Vraćanje informacija. Evaluacija obrade prirodnog jezika
Predavanje2:
Razumijevanje prirodnog jezika. Ekstrakcija znanja iz prirodnog jezika. Prikazi
znanja. Evaluacija razumijevanja prirodnog jezika.
Predavanje3:
Generiranje prirodnog jezika. Veza između znanja i jezika. Generiranje riječi, fraza i
rečenica. Generiranje pitanja. Sličnost kao alat za usporedbu jezičnih struktura.
Evaluacija generiranja prirodnog jezika.
Predavanje 4.
Sustavi e-učenja koji koriste tehnike obrade prirodnog jezika. Obrada prirodnog
jezika kod inteligentnih tutorskih sustava. Tutorski dijalog.
Predavanje 5. Komparativna analiza sustava e-učenja koji koriste obradu prirodnog
jezika u komunikaciji s učenikom</td></tr>
</table>

<table>
<tr><td>Vrste izvođenja nastave</td><td colspan="3">☑ Predavanja
☑ Seminari
☐ Vježbe
☐ On line u cijelosti
☐ Mješovito e-učenje
☐ Terenska nastava
☑ Samostalni zadaci
☐ Multimedija
☐ Laboratorij
☐ Mentorski rad
☐
☐
☐
☐</td></tr>
<tr><td>Obveze studenata</td><td colspan="3">Pohađajte predavanja i vježbi, rješavanje domaće zadaće i drugih zadataka</td></tr>
<tr><td>Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td colspan="3"><table>
<tr><td>Pohađanje nastave</td><td>2</td><td>Istraživanje</td><td></td><td>Praktični rad</td><td></td></tr>
<tr><td>Eksperimentalni rad</td><td></td><td>Referat</td><td></td><td></td><td></td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td>3</td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td></td><td>Usmeni ispit</td><td></td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td></td><td>Projekt</td><td></td><td></td><td></td></tr>
</table></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="3">Studenti moraju imati prolaznu ocjenu iz sva tri gore navedena aspekta ocjenjivanja</td></tr>
<tr><td>Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3"><table>
<tr><th>Naslov</th><th>Broj primjeraka u knjižnici</th><th>Dostupnost putem ostalih medija</th></tr>
<tr><td>D. Jurafsky, J. H. Martin, (2000) Speech and Language Processing, Prentice Hall</td><td>1</td><td></td></tr>
<tr><td>Roger Nkambou, R. Mizoguchi J. Bourdeau (Eds.) (2010) Advances in Intelligent Tutoring Systems, Springer</td><td>1</td><td></td></tr>
</table></td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">Roger Nkambou, R. Mizoguchi J. Bourdeau (Eds.) (2010) Advances in Intelligent Tutoring Systems, Springer</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Razgovor sa studentima, samoprocjena</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Poslovna analitika</td></tr>
<tr><td>Kod</td><td>PMIH28</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Marko Rosić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="3">30%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Stjecanje temeljnih pojmova i znanja o poslovnoj analitici i njenoj primjeni. Osposobiti studente za prepoznavanje situacija u kojima je moguće uspješno primijeniti tehnike i metode poslovne analitike .</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">-</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">1. Definirati osnovne pojmove i podjelu poslovne analitike, te njene prednosti i primjenu
2. Razumjeti Big Data koncept
3. Identificirati poslovni problem i utvrditi da li je pogodan za primjenu alata poslovne analitike
4. Razumjeti i opisati važnost svakog koraka u procesu poslovne analitike
5. Opisati nekoliko metoda kojima se koristi poslovna analitika</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Tjedan 1: Uvod u poslovnu analitiku. Osnovni pojmovi. Podjela.
Tjedan 2: Trendovi razvoja poslovne analitike.
Tjedan 3: Big Data koncept.
Tjedan 4: Poslovna analitika i poslovna inteligencija.(Definicije. Sličnosti i razlike. Primjene)
Tjedan 5: Primjena poslovne analitike na konkretnim primjerima iz prakse.
Tjedan 6: Proces poslovne analitike. (Definiranje problema. Razumijevanje podataka. Priprema podataka. Modeliranje. Evaluacija. Razvoj.)
Tjedan 7: Problem nedostajućih podataka i moguća rješenja. (Analiza i mehanizmi nedostajanja. metode za rješavanje problema nedostajućih vrijednosti)
Tjedan 8: Vizualizacija podataka.
Tjedan 9: Umjetna inteligencija i strojno učenje. (Pojam i povijest. Pristupi u rješavanju problema sa umjetnom inteligencijom. Usporedba umjetne inteligencije i tradicionalnog računarstva. Razne primjene. Inteligentne metode kao dio sustava za potporu odlučivanju.)
Tjedan 10: Ekspertni sustavi.(Pojam i povijest. Specifične primjene)
Tjedan 11: Rudarenje podataka. (Metode rudarenja podataka u poslovnim sustavima. Trendovi razvoja poslovnih sustava.
Tjedan 12: Neuronske mreže. (Definicija i način funkcioniranja. Povijesni razvoj. Dizajniranje arhitekture. Alati za razvoj. Primjena)
Tjedan 13: Stabla odlučivanja. (Definicija i način funkcioniranja. Povijesni razvoj. Klasifikacijska i regresijska stabla odlučivanja. Primjena)</td></tr>
</table>

	Tjedan 14: Asocijacijska pravila. (Definicija i način funkcioniranja. Analiza potrošačke košarice. Primjena) Tjedan 15: Uvođenje poslovne inteligencije u sustav.(Poslovna inteligencija kao dio poslovnog sustava. Upravljanje projektom. Analiza sustava poslovne inteligencije)

Vrste izvođenja nastave			
	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐

Obveze studenata	

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave	0.5	Istraživanje		Praktični rad	2
Eksperimentalni rad		Referat			
Esej		Seminarski rad			
Kolokviji		Usmeni ispit	1		
Pismeni ispit	1.5	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu
Prisustvovanje na nastavi. Pismeni/usmeni ispit. Rješavanje zadataka.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)			
	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	-		

Dopunska literatura

Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja
Statistika ispitnih rezultata i studentska evaluacija putem anonimne ankete na kraju izvedbe predmeta. Anketa se provodi prema pravilniku Sveučilišta u Splitu.

Ostalo (prema mišljenju predlagatelja)

<table>
<tr><td>Naziv kolegija</td><td colspan="5">Strojno učenje u bioinformatici i medicini</td></tr>
<tr><td>Kod</td><td>PMIH22</td><td>Godina studija</td><td colspan="4">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>Dino Nejašmić, pred.</td><td>Bodovna vrijednost (ECTS)</td><td colspan="4">5.0</td></tr>
<tr><td rowspan="2">Suradnici</td><td rowspan="2"></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td>P</td><td>S</td><td>V</td><td>T</td></tr>
<tr><td>30</td><td>0</td><td>30</td><td>0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="4">20%</td></tr>
<tr><td colspan="6">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="5">Cilj kolegija je upoznati studente s mogućim primjenama metoda strojnog učenja u
bioinformatici i medicini.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Poznavanje metoda strojnog učenja.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Po završetku kolegija, studenti će moći:
1. Prepoznati mogućnosti upotrebe strojnog učenja u bioinformatici i medicini.
2. Primijeniti metode strojnog učenja na podatke iz područja bioinformatike i
medicine.
3. Procijeniti i opravdati prikladnost različitih metoda strojnog učenja za zadani
zadatak.
4. Usporediti efikasnost različitih algoritama strojnog učenja za zadani zadatak.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">1. Uvod u genetiku i genomiku.
2. Metoda potpornih vektora. Algoritam k-najbližih susjeda. Primjer iz prakse:
Detekcija karcinoma dojke.
3. Linearna regresija. Logistička regresija. Primjer iz prakse: Cjelogenomske
analize povezanosti: identifikacija genetskih varijanti povezanih s razinama
hormona štitnjače.
4. Ansambli modela. Random forest algoritam. Primjer iz prakse: Klasifikacija
dijabetičke retinopatije.
5. Metode odabira značajki i smanjenje dimenzionalnosti. Metoda glavnih
komponenata. Primjer iz prakse: prehrambene navike.
6. Dubinsko strojno učenje. Primjer iz prakse: Analiza izražajnosti gena.
7. Neuronske mreže. Višeslojni perceptron. Konvolucijske neuronske mreže.
Povratne neuronske mreže. Rekurzivne neuronske mreže. Primjeri iz prakse:
Predikcija srčanih bolesti, Probir za autizam. Analiza slike: Otkrivanje stadija
raka pluća.
8. Mogućnosti i prepreke za strojno učenje u bioinformatici i medicini.</td></tr>
</table>

<table>
<tr><td>Vrste izvođenja nastave</td><td>☑ Predavanja
☐ Seminari
☑ Vježbe
☐ On line u cijelosti
☐ Mješovito e-učenje</td><td>☐ Terenska nastava
☐ Samostalni zadaci
☐ Multimedija
☐ Laboratorij
☐ Mentorski rad</td><td>☐
☐
☐
☐</td></tr>
<tr><td>Obveze studenata</td><td colspan="3">Pohađanje nastave, aktivno sudjelovanje u nastavnom procesu, ispiti.</td></tr>
<tr><td>Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td colspan="3"><table>
<tr><td>Pohađanje nastave</td><td>1.5</td><td>Istraživanje</td><td></td><td>Praktični rad</td><td></td></tr>
<tr><td>Eksperimentalni rad</td><td></td><td>Referat</td><td></td><td></td><td></td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td>1.5</td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td></td><td>Usmeni ispit</td><td>2</td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td></td><td>Projekt</td><td></td><td></td><td></td></tr>
</table></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="3">Seminarski rad (50%), Usmeni ispit (50%).</td></tr>
<tr><td>Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3"><table>
<tr><th>Naslov</th><th>Broj primjeraka u knjižnici</th><th>Dostupnost putem ostalih medija</th></tr>
<tr><td>Cleophas T, Zwinderman A. Machine Learning in Medicine – a Complete Overview. Springer International Publishing. 2015</td><td></td><td></td></tr>
<tr><td>https://www.udemy.com/course/applied-machine-learning-for-healthcare/</td><td></td><td></td></tr>
<tr><td>Ching T, Himmelstein DS, Beaulieu-Jones BK, et al. Opportunities and obstacles for deep learning in biology and medicine. J R Soc Interface. 2018;15(141).</td><td></td><td></td></tr>
</table></td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">Leung MKK, Delong A, Alipanahi B, Frey BJ. Machine Learning in Genomic Medicine: A Review of Computational Problems and Data Sets. P Ieee. 2016;104(1):176-197

Min S, Lee B, Yoon S. Deep learning in bioinformatics. Briefings in Bioinformatics. 2017;18(5):851-869.

Lan K, Wang DT, Fong S, Liu LS, Wong KKL, Dey N. A Survey of Data Mining and Deep Learning in Bioinformatics. J Med Syst. 2018;42(8).</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Statistika ispitnih rezultata i studentska evaluacija putem anonimne ankete na kraju izvedbe predmeta. Anketa se provodi prema pravilniku Sveučilišta u Splitu.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

Naziv kolegija	Diplomski rad					
Kod	PMIZ55	Godina studija	2.			
Nositelj/i kolegija		Bodovna vrijednost (ECTS)	30.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	0	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija			
Ciljevi kolegija			
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij			
Ishodi učenja			
Vrste izvođenja nastave	☐ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐
Obveze studenata			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu			

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	-		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Statistika ispitnih rezultata i studentska evaluacija putem anonimne ankete na kraju izvedbe predmeta. Anketa se provodi prema pravilniku Sveučilišta u Splitu.		
Ostalo (prema mišljenju predlagatelja)			

3. PRILOZI

3.1. Ishodi učenja studijskog programa

1. prikupiti, preuzeti, spremiti i transformirati podatke
2. upravljati podacima iz različitih heterogenih izvora
3. analizirati i istražiti podatke
4. izvijestiti o podacima korištenjem metoda deskriptivne statistike i vizualizacija
5. stvoriti prediktivne modele iz podataka korištenjem metoda naprednog strojnog učenja
6. empirijski evaluirati modele strojnog učenja
7. proširiti i kombinirati strojna učenja, posebice dubinske neuronske mreže
8. odgovoriti na izazove iz stvarnog života u strojnom učenju, poput manjkavih podataka
9. identifikacija i pristup osnovnim problemima u bioinformatici i medicinskim podacima
10. analiza podataka i učenje modela kompleksnih mreža
11. primjena obrade prirodnog jezika na šumne, višejezične ili korisnički-generirane tekstove
12. smjestiti postojeće algoritme strojnog učenja unutar šireg konteksta umjetne inteligencije
13. napisati računalni program koji je učinkovit i održiv
14. specificirati računalne arhitekture koje mogu raditi s velikim skupovima podataka
15. izraditi raspodijeljene i paralelne razvojne okvire za podatkovno-intenzivno računarstvo
16. analizirati i kritički sagledati podatkovne sustave
17. pisati sažeta, uvjerljiva i empirijski podržana izvješća
18. uključiti etičko razmatranje u području podataka
19. surađivati sa kolegama s ciljem efikasnog upravljanja zajedničkim radom na projektu
20. pozicionirati rad na primjeni unutar prikladnog teoretskog okvira

3.2. Nastavnici na studijskom programu

Kolegij	Nastavnici i suradnici
Algoritmi u bioinformatici	Damir Vukičević
Analitika učenja	Ani Grubišić
Analiza mreža	Hrvoje Kalinić Nikola Balić
Arhitekture neuronskih mreža	Goran Zaharija
Diplomski rad	
Diplomski rad - priprema	Saša Mladenović
Linearna algebra, optimizacija i statistika	Damir Vukičević
Obrada prirodnog jezika	Branko Žitko
Odabrana poglavlja relacijskih baza podataka	Monika Mladenović
Paralelno programiranje	Tonći Dadić
Podaci i etika	Marko Rosić
Poslovna analitika	Marko Rosić
Projekt - prva godina	Saša Mladenović
Raspodijeljene i nerelacijske baze podataka	Monika Mladenović
Strojno učenje	Saša Mladenović
Strojno učenje - trendovi i teme istraživanja	Saša Mladenović
Strojno učenje u bioinformatici i medicini	Dino Nejašmić
Uvod u podatkovnu znanost	Divna Krpan
Uvod u podatkovnu znanost - primjeri dobre prakse	Divna Krpan
Vizualizacija podataka	Goran Zaharija
Znanstveno programiranje	Dino Nejašmić

Titula, ime i prezime nositelja	doc. dr. sc. Divna Krpan
Kolegij koji predaje na predloženom studijskom programu	Uvod u podatkovnu znanost Uvod u podatkovnu znanost - primjeri dobre prakse
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	dkrpan@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	292414
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	prof. dr. sc. Saša Mladenović
Kolegij koji predaje na predloženom studijskom programu	Diplomski rad - priprema Projekt - prva godina Strojno učenje Strojno učenje - trendovi i teme istraživanja
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	smladen@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	313294
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2	

(dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	prof. dr. sc. Damir Vukičević
Kolegij koji predaje na predloženom studijskom programu	Algoritmi u bioinformatici Linearna algebra, optimizacija i statistika
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	vukicevi@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	256631
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	Dino Nejašmić
Kolegij koji predaje na predloženom studijskom programu	Strojno učenje u bioinformatici i medicini Znanstveno programiranje
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	dnejasmic@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	doc. dr. sc. Monika Mladenović
Kolegij koji predaje na predloženom studijskom programu	Odabrana poglavlja relacijskih baza podataka Raspodijeljene i nerelacijske baze podataka
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	monmla@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	361896
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	prof. dr. sc. Marko Rosić
Kolegij koji predaje na predloženom studijskom programu	Podaci i etika Poslovna analitika
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	marko@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	226885
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	dr. sc. Tonći Dadić
Kolegij koji predaje na predloženom studijskom programu	Paralelno programiranje
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	tdadic@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	226905
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	doc. dr. sc. Goran Zaharija
Kolegij koji predaje na predloženom studijskom programu	Arhitekture neuronskih mreža Vizualizacija podataka
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	gzaharija@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	329950
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	prof. dr. sc. Branko Žitko
Kolegij koji predaje na predloženom studijskom programu	Obrada prirodnog jezika
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	bzitko@pmfst.hr
Osobna web stranica	u naslovnom zvanju docenta
Godina rođenja	
Matični broj iz Upisnika znanstvenika	257351
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	Tehničke znanosti, računarstvo
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	prof. dr. sc. Ani Grubišić
Kolegij koji predaje na predloženom studijskom programu	Analitika učenja
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	ani@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	257340
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	izv. prof. dr. sc. Hrvoje Kalinić
Kolegij koji predaje na predloženom studijskom programu	Analiza mreža
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	hkalinic@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	289865
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	
Datum zaposlenja	
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	
Područje rada	
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	
Ustanova	
Mjesto	
Nadnevak	
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	

Titula, ime i prezime nositelja	Nikola Balić
Kolegij koji predaje na predloženom studijskom programu	Analiza mreža
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Ruđera Boškovića 27
Telefon	098500161
E-mail	nbalic@pmfst.hr
Osobna web stranica	https://www.linkedin.com/in/nikolabalic/
Godina rođenja	21.06.1983.
Matični broj iz Upisnika znanstvenika	
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	
Područje i polje izbora u znanstveno ili umjetničko zvanje	
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	Pulent, obrt za usluge
Datum zaposlenja	01.10.2018.
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	Vlasnik
Područje rada	Razvoj poslovanja
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	mag.ing.comp.
Ustanova	Fakultet elektrotehnike, strojarstva i brodogradnje
Mjesto	Split
Nadnevak	01.01.2009.
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	

Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	
KOMPETENCIJE ZA PREDMET	
Ranije iskustvo u nositeljstvu sličnih kolegija (navesti naziv kolegija, studijskoga programa na kojem se izvodi/izvodio i razinu studijskoga programa)	
Autorstvo sveučilišnih/fakultetskih udžbenika iz područja kolegija	
Stručni, znanstveni i umjetnički radovi objavljeni u posljednjih pet godina iz područja kolegija (najviše 5 referenca)	
Stručni i znanstveni radovi iz metodike i kvalitete nastave objavljeni u posljednjih pet godina (najviše 5 referenca)	
Stručni, znanstveni i umjetnički projekti iz područja kolegija koji su se provodili u posljednjih pet godina (najviše 5 referenca)	
U sklopu kojega programa i u kojem je opsegu nositelj stekao metodičko-psihološko-didaktičko - pedagoške kompetencije?	
PRIZNANJA I NAGRADE	
Priznanja i nagrade za nastavni i znanstveni rad/umjetnički rad	