SVEUČILIŠTE U SPLITU

Prirodoslovno-matematički fakultet u Splitu

ELABORAT O STUDIJSKOM PROGRAMU

SVEUČILIŠNI DIPLOMSKI STUDIJ
INFORMATIKA; SMJER: NASTAVNIČKI

Split, ožujak 2026

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	Informatika; smjer: nastavnički
Nositelj studijskoga programa	Sveučilište u Splitu
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, 0114
Trajanje studija (godina)	2
Broj ECTS bodova koji se stječu završetkom studija	120
Akademski/stručni naziv koji se stječe po završetku studija	sveučilišni magistar edukacije informatike/sveučilišna magistra edukacije informatike
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)	26

1. UVOD

1.1. Analiza usklađenosti studija sa strateškim ciljevima visokog učilišta

Sveučilišni diplomski studij Informatika; smjer: nastavnički 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 Informatika vodilo računa o usklađivanju nastavnih programa i kolegija s drugim uglednim inozemnim učilištima. Sustav obrazovanja nastavnika informatike u svijetu i Europi je raznolik. To se odnosi na gotovo sve sastavnice obrazovanja: vrstu i organizaciju studija, trajanje studija, stručno zvanje i diplome koje se stječu. Na nekim europskim sveučilištima nastavnički studiji za pojedini predmet su organizirani na preddiplomskoj razini jer je ta razina dovoljna za rad u osnovnim i srednjim školama u tim državama. Nadalje, kod dvopredmetnih studija može se pronaći studij informatike kao glavni predmet („major“) u kombinaciji s drugim predmetom („minor“). Ipak, prilikom izrade nastavnog programa diplomskog studija Informatika analizirana je usporedivost sa srodnim programima sveučilišnih studija u zemlji i svijetu, pa tako usporedivi programi postoje na sljedećim institucijama:

Sveučilište u Zagrebu, Fakultet organizacije i informatike u Varaždinu, Hrvatska
http://www.foi.unizg.hr/hr/studiji/ds/inf#io

Sveučilište u Zagrebu, Filozofski fakultet, Hrvatska
http://theta.ffzg.hr/ECTS/Studij/Index/1172

Sveučilište Juraja Dobrile u Puli, Hrvatska
http://www.unipu.hr/index.php?id=1899

Sveučilište u Rijeci, Odjel za informatiku, Hrvatska
http://www.inf.uniri.hr/files/studiji/diplomski/nastavnicki/program/Program_dipl_jp_nm_od_2014_2015.pdf

Sveučilište u Mariboru, Fakulteta za naravoslovje in matematiko, Fakulteta za elektrotehniko, računalništvo in informatiko, Slovenija.
https://feri.um.si/studij/programi/druga-stopnja/mag/ir/

Za sve analizirane programe karakteristično je da studenti moraju imati temeljna informatička znanja stečena na nižoj razini obrazovanja, dok na diplomskom studiju nadograđuju prethodno stečena strukovna informatička znanja s dodatnim sadržajima. Naglasak studija je na sadržajima kojima studenti dobivaju pedagoško-didaktičko-metodičke kompetencije nužne za uspješno realiziranje svih obrazovnih programa iz informatike u osnovnoj i srednjoj školi s naglaskom na metodiku nastave informatike.

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.
Fakultet je potpisnik ERASMUS sporazuma za mobilnost nastavnika i studenata sa sljedećim institucijama: University of the Aegean i Alexander Technological Educational Institute of Thessaloniki, Grčka; Universita degli studi di Perugia, Italija; Universite Claude Bernard LYON01, Francuska; Vytautas Magnus University, Litva; SS. Cyril and Methodius university in Skopje, Makedonija; University of Bielsko-Biala Akademia Techniczno-Humanistyczna w Bielsku-Bialej, Poljska; University of Ljubljana, Slovenija, University of Maribor, Slovenija; Vienna University of Technology, Austrija. Dosadašnja mobilnost je većinski bila prema PMF-u. Time se potvrđuje kvaliteta, atraktivnost, ali i kompatibilnost programa ovog studija sa sličnim studijima u Europi.

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

Sveučilišni diplomski studij Informatika; smjer: nastavnički 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 Informatike, nastavnički smjer, osposobljava magistre edukacije za izvođenje nastave informatike u osnovnim i srednjim školama te za stručni rad u informatici/računarstvu, a ujedno je temelj za upis na poslijediplomski/doktorski studij informatike.
Magistri su kroz diplomski studij nadogradili znanja stečena na prethodno završenom prijediplomskom studiju. Studenti su stekli kompetencije s kojima mogu modelirati, postaviti i održavati sustave programske podrške, upravljati znanjem u razvoju programske podrške, analizirati i oblikovati raspodijeljene i klasične sustave prema objektnom načelu te voditi projekte za razvoj programske podrške. Pored toga studenti su

proširili svoja znanja iz drugih područja informatike odabirom izbornih kolegija, s posebnim naglaskom na metodiku nastave informatike.

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	PMS105	Didaktika	Anna Alajbeg	30	15	0	3
	PMID40	Paralelno programiranje	Tonći Dadić	30	0	30	5
	PMS007	Psihologija odgoja i obrazovanja I	Nikola Marangunić	30	15	0	3
	PMIK10	Sustavi E - učenja	Ani Grubišić	30	15	0	5
	Ukupno obvezni			120	45	30	16
Izborni	Upisuje se najmanje 14 ECTS bodova izbornih predmeta od čega barem jedan izborni kolegij iz informatičke grupe predmeta						
	PMM850	Matematičke osnove kriptografije	Marija Bliznac Trebješanin, Borka Jadrijević	30	0	30	5
	PMIH40	Metodologija dizajna interakcija	Andrina Granić	30	15	0	5
	PMID54	Modeliranje sustava programske podrške	Branko Žitko	30	30	0	5
	PMIG20	Osnove teorije strategijskih igara	Aljoša Šubašić	45	0	0	5
	PMII50	Računalna grafika	Hrvoje Kalinić	30	0	30	5
	PMIH21	Strojno učenje	Saša Mladenović	30	0	30	5
	PMII40	Uvod u obradu prirodnog jezika	Branko Žitko	30	0	30	5
	PMIH25	Uvod u podatkovnu znanost	Divna Krpan	30	0	30	5
	PMID15	Znanstveno programiranje	Dino Nejašmić	30	0	30	5
	DHZ						
	PMS135	Kineziološka aktivnost, fitness i zdravlje	Mladen Hraste	15	0	15	2
*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	PMIK50	Metodika nastave informatike I	Monika Mladenović	30	30	30	6
	PMS170	Pedagogija	Anna Alajbeg	30	15	0	3
	PMS116	Psihologija odgoja i obrazovanja II	Nikola Marangunić	30	15	0	3
	PMIC50	Raspodijeljeni sustavi	Marko Rosić	30	0	30	5
	PMS006	Stručno-pedagoška praksa	Anna Alajbeg	0	15	0	1
	Ukupno obvezni			120	75	60	18
Izborni	Upisuje se izborne predmeta od čega barem jedan izborni kolegij iz informatičke grupe predmeta do minimalno 60 ECTS bodova na 1. godini						
	PMID60	Jezični procesori	Tonći Dadić, Marko Rosić	30	0	30	5
	PMIH50	Multimodalna interakcija i sučelja	Andrina Granić	30	0	30	5
	PMIK30	Projektiranje sustava za e-učenje	Ani Grubišić	30	0	30	5
	PMII60	Računalni vid	Barbara Džaja	30	0	30	5
	PMT112	Računalom podržani dizajn proizvoda (CAD)	Ivan Peko	30	0	30	5
	PMID56	Računarstvo u zajednici	Jelena Nakić	15	30	0	5
	PMIH12	Raspodijeljene i nerelacijske baze podataka	Monika Mladenović	30	0	30	5
	PMIH20	Rudarenje podataka	Hrvoje Kalinić	30	0	30	5
	PMIC40	Sigurnost računalnih učionica	Goran Zaharija	15	30	0	5
	PMID38	Vizualni programski jezici i okružja	Divna Krpan	15	30	0	5
	DHZ						
	PMS174	Kognitivna psihologija	Nikola Marangunić	15	15	0	2
	PMS176	Nasilje među djecom	Anna Alajbeg	15	15	0	2
	PMS140	Poučavanje učenika s posebnim potrebama	Antonija Bašić Radelja	15	15	0	2
	PMS150	Pozitivna psihologija	Nikola Marangunić	15	15	0	2
*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	PMIK51	Metodički informatički seminar s nastavnom praksom I	Monika Mladenović	0	15	30	3
	PMIK60	Metodika nastave informatike II	Monika Mladenović	30	30	30	6
	PMS114	Metodologija istraživanja u obrazovanju	Anna Alajbeg	30	15	0	3
	PMS108	Sociologija odgoja i obrazovanja	Antonija Bašić Radelja	15	15	0	2
	Ukupno obvezni			75	75	60	14
Izborni	Upisuje se izborne predmeta od čega barem jedan izborni kolegij iz informatičke grupe predmeta do minimalno 60 ECTS bodova na 1. godini						
	PMII15	Arhitekture neuronskih mreža	Goran Zaharija	30	0	30	5
	PMIK80	Informatička praksa		0	0	176	5
	PMII30	Inteligentni agenti	Lada Maleš	30	15	0	5
	PMII45	Obrada prirodnog jezika	Branko Žitko	30	0	30	5
	PMIH28	Poslovna analitika	Marko Rosić	30	0	30	5
	PMID35	Programiranje mobilnih aplikacija	Goran Zaharija	30	0	30	5
	PMIH22	Strojno učenje u bioinformatici i medicini	Dino Nejašmić	30	0	30	5
	PMIK20	Tehnologije sustava E-učenja	Marko Rosić	30	0	30	5
	PMIH15	Uvod u geoinformacijske sustave	Vlado Dadić	30	0	30	5
	PMII40	Uvod u obradu prirodnog jezika	Branko Žitko	30	0	30	5
	PMII65	Vizualizacija podataka	Goran Zaharija	30	0	30	5
	Izborni pedagoški predmet iz grupe I-D3. Student upisuje barem tri predmeta iz informatičke i barem jedan pedagoške grupe izbornih predmeta.						
	PMS201	Napredni modeli nastave	Antonija Bašić Radelja	15	15	0	2
	PMS175	Pedagogija adolescencije	Anna Alajbeg	15	15	0	2
	PMS172	Pedagogija slobodnog vremena	Antonija Bašić Radelja	15	15	0	2
	PMS160	Upravljanje razredom	Antonija Bašić Radelja	15	15	0	2
*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	PMIZ50	Diplomski informatički rad		0	6	0	11
	PMIZ40	Diplomski informatički seminar		0	0	0	4
	PMIK61	Metodički informatički seminar s nastavnom praksom II	Monika Mladenović	0	15	30	3
	Ukupno obvezni			0	21	30	18
Izborni	Upisuje se izborne predmeta od čega barem jedan izborni kolegij iz informatičke grupe predmeta do minimalno 120 ECTS bodova na studiju						
	PMIE20	Algoritmi u bioinformatici	Damir Vukičević	30	0	30	5
	PMIK25	Analitika učenja u računalom potpomognutom procesu učenja i poučavanja	Ani Grubišić	30	0	30	5
	PMIK70	Informatički menadžment	Marko Rosić	30	15	0	5
	PMIK65	Istraživački rad u informatičkom obrazovanju	Monika Mladenović	15	30	0	5
	PMID60	Jezični procesori	Tonći Dadić	30	0	30	5
	PMII20	Kognitivni sustavi	Branko Žitko	30	0	30	5
	PMIH71	Podaci i etika	Marko Rosić	15	15	0	2.5
	PMID45	Programske paradigme	Saša Mladenović, Zoran Sambol	30	0	30	5
	PMT112	Računalom podržani dizajn proizvoda (CAD)	Ivan Peko	30	0	30	5
	PMIH12	Raspodijeljene i nerelacijske baze podataka	Monika Mladenović	30	0	30	5
	PMT279	Robotika u nastavi	Barbara Džaja	15	0	15	2.5
	PMIH20	Rudarenje podataka	Hrvoje Kalinić	30	0	30	5
	PMIC40	Sigurnost računalnih učionica	Goran Zaharija	15	30	0	5
	PMID38	Vizualni programski jezici i okružja	Divna Krpan	15	30	0	5
	Izborni društveno-humanistički predmeti iz grupe I-D4. Student upisuje izbornih predmeta iz bilo koje grupe do minimalno 120 ECTS bodova na studiju.						
	PMS173	Izvannastavne i izvanškolske aktivnosti	Antonija Bašić Radelja	15	15	0	2
	PMS176	Nasilje među djecom	Anna Alajbeg	15	15	0	2
	PMS140	Poučavanje učenika s posebnim potrebama	Antonija Bašić Radelja	15	15	0	2
	PMS150	Pozitivna psihologija	Nikola Marangunić	15	15	0	2

*P=Predavanja, S=Seminari, V=Vježbe

2.2. Opis kolegija

Naziv kolegija	Didaktika					
Kod	PMS105	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Anna Alajbeg	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija Didaktika je osposobiti studente za razumijevanje i primjenu temeljnih didaktičkih teorija i principa u planiranju, izvođenju i evaluaciji nastave. Studenti će razviti vještine potrebne za učinkovito poučavanje, upravljanje razredom i profesionalni razvoj u skladu sa suvremenim obrazovnim trendovima.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	Studenti će moći definirati ključne didaktičke pojmove (ishodi učenja, nastavne metode, kurikulum i sl.) i objasniti različite didaktičke teorije. Studenti će biti osposobljeni za samostalno planiranje nastavnih sati, odabir prikladnih metoda i oblika rada, te za evaluaciju učinkovitosti nastavnog procesa. Studenti će usvojiti tehnike uspješne komunikacije s učenicima i roditeljima, te razviti strategije za upravljanje razredom i rješavanje potencijalnih konflikata. Studenti će razumjeti strukturu i sadržaj nacionalnih i školskih kurikulumskih dokumenata, te će ih znati primijeniti u planiranju i provedbi nastave. Studenti će biti osposobljeni za samokritičku analizu vlastite nastavne prakse, te će razumjeti važnost kontinuiranog profesionalnog usavršavanja u području didaktike.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod u didaktiku.Povijesni razvoj didaktičke misli u svijetu i u Hrvatskoj 2. Didaktičke teorije. Didaktika i druge znanosti 3. Temeljni didaktički pojmovi 4.Teorija kurikuluma 5. Nastavni plan. Nacionalni okvirni kurikul. Školski kurikul. Godišnji plan i program. Predmetni kurikul. 6. Planiranje nastave 7. Ishodi učenja 8. Nastavne metode 9. Organizacijski oblici nastave 10. Komunikacija u nastavi 11. Strategije (sustavi) poučavanja i učenja 12. Alternativni pristupi u poučavanju; 13. Uspješno upravljanje razredom i suradnja s roditeljima 14. Evaluacija odgojno - obrazovnih rezultata; evaluacija vlastitog rada 15. Kolokvij
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, izrada i prezentacija seminarskog rada, položeni kolokviji ili 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	0.5			
Kolokviji		Usmeni ispit	0.5			

	Pismeni ispit	0.5	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, rezultati kolokvija, rezultati ispita.

Ocjenjivanje		
Bodovi (%)	Kriterij	Ocjena
Jelavić, F. (2008). Didaktika (5. dopunjeno izd). Naklada Slap. Jastrebarsko.		
Cindrić, M., Miljković, D., & Strugar, V. (2016). Didaktika i kurikulum, drugo izdanje.		

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

Dopunska literatura	Carol C. Kuhlthau-Leslie K. Maniotes-Ann K. Caspari, Vođeno istraživačko učenje. Učenje u 21. stoljeću, 2018. Maja Ćukušić-Mario Jadrić, E-učenje. Koncepti i primjena, Zagreb, 2012. Milan Matijević -Tomislav Topolovčan, Multimedijska didaktika, Zagreb, 2017.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika.
Ostalo (prema mišljenju predlagatelja)	Sadržaji nastave navedeni su za blok-satove (15 termina x 2 sata). Sadržaji seminarskih radova odrađuju se u seminarskim grupama (15 x 1 po grupi).

<table>
<tr><td>Naziv kolegija</td><td colspan="4">Paralelno programiranje</td></tr>
<tr><td>Kod</td><td>PMID40</td><td>Godina studija</td><td colspan="2">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>dr. sc. Tonći Dadić, pred.</td><td>Bodovna vrijednost (ECTS)</td><td colspan="2">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 S V T</td></tr>
<tr><td>30 0 30 0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="2">0%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">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="4">Objektno orijentirano programiranje.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">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="4">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

Natjecanje za pristup zajedničkim podacima (konkurentno čitanje / pisanje te pisanje / pisanje)

Izostanak napredovanja programa: potpuni zastoj i izgladnjivanje niti

Tjedan 3:

Paralelne arhitekture računala</td></tr>
</table>

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)	

Naziv kolegija	Psihologija odgoja i obrazovanja I					
Kod	PMS007	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Nikola Marangunić	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	30%			

Opis kolegija	
Ciljevi kolegija	Poznavanje elementarnih pojmova i spoznaja iz opće i razvojne psihologije; bolje razumijevanje vlastitog i tuđeg ponašanja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	Nakon odslušanog i položenog predmeta studenti će moći: 1.Interpretirati metode i istraživačke tehnike u području istraživanja odgoja i obrazovanja. 2.Objasniti sastavne elemente ljudskog ponašanja: ličnost, inteligencija, motivacija i emocije. 3.Navesti temelje razvijanja stavova i životnih vrijednosti. 4.Usporediti razlike u psihičkom razvoju s obzirom na životna razdoblja: djetinjstvo, mladost, zrelost, starost
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Uvod u predmet; 2.Uvod u psihologiju odgoja i obrazovanja; 3.Metodologija u istraživanju odgoja i obrazovanja; 4.Ličnost - teorije i modeli; 5.Ličnost - determinante i mjerenje; 6.Inteligencija - određenje i determinante; 7.Inteligencija - mjerenje; 8.Motivacija; 9.Emocije - podjela; 10.Emocije - razvoj; 11.Stavovi - formiranje i utjecaj stavova; 12.Stavovi - stereotipi i predrasude; 13.Stavovi - vrijednosti i razvoj moralne svijesti; 14.Psihički razvoj - djetinjstvo i adolescencija; 15.Psihički razvoj - zrelost i starost.

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

Obveze studenata	Pohađanje nastave, aktivno sudjelovanje, izrada seminarskog rada, kolokviji (prema izboru).					
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	0.5		
	Kolokviji	1	Usmeni ispit	1		
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, rezultati kolokvija (ukoliko mu student pristupi), rezultati ispita.

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

	V. Andrilović, M. Čudina: Osnove opće i razvojne psihologije, Školska knjiga, Zgb,1985. 2		
	N. Pastuović: Osnove psihologije obrazovanja i odgoja, Znamen, Zgb.,1997		
Dopunska literatura	A. Fulgosi: Psihologija ličnosti - teorije i istraživanja, Školska knjiga, Zgb, 1981. 1. D. Goleman: Emocionalna inteligencija, Mozaik knjiga, Zgb., 1997. 2. D. Miljković, M.Rijavec: Razgovori sa zrcalom: psihologija samopouzdanja, Zgb., 1996. 3. M. Rijavec: Čuda se ipak događaju: psihologija pozitivnog mišljenja, IEP,Zgb., 1997. 4. Psihologijski rječnik, Prosvjeta, Zgb., 1992.		
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)	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika.		

<table>
<tr><td>Naziv kolegija</td><td colspan="4">Sustavi E - učenja</td></tr>
<tr><td>Kod</td><td>PMIK10</td><td>Godina studija</td><td colspan="2">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Ani Grubišić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="2">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 S V T</td></tr>
<tr><td>30 15 0 0</td></tr>
<tr><td>Status kolegija</td><td>Obvezni</td><td>Postotak primjene e-učenja</td><td colspan="2">75%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">Cilj je steći znanja o sustavima za e-učenje i njihovoj primjeni u obrazovanju, nastavi i učenju i poučavanju. Zadani cilj se dostiže učenjem i poučavanjem: definicije, funkcijski model i konfiguracija sustava za e-učenje, objekti učenja; norme za oblikovanje sustava za e-učenje; pedagogijske paradigme sustava za e□učenje, inteligentni tutorski sustavi, primjeri sustava za e-učenje.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="4">Uvjeti za upis: nema ih.
Ulazne kompetencije: poznavanje osnova rada na računalu</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">Student će moći:
1. klasificirati sustave e-učenja
2. klasificirati objekte učenja
3. klasificirati norme za oblikovanje arhitekture sustava e-učenja
4. usporediti osnovne konfiguracije sustava e-učenja
5. oblikovati nastavne sadržaje u sustavu e-učenja primjenom ADDIE modela
6. vrednovati učinkovitost sustava e-učenja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="4">Tjedan1:
Upoznavanje s kolegijem
Tjedan2:
Informacijska i komunikacijska tehnologija i područja primjene računala u nastavi
Tjedan3:
Definicija e-učenja i sustav za e-učenje, Funkcijski model sustava za e-učenje
Tjedan4:
Konfiguracija sustava za e-učenje (aktualne klase konfiguracija sustava za e-učenje)
Tjedan5:
Objekti učenja (definicija, karakteristike, modeli), Norme za oblikovanje arhitekture sustava za e-učenje
Tjedan6:
Pedagogijska paradigma sustava za e-učenje (dva sigma problem, tradicionalno učenje, učenje s provjeravanjem, tutorsko učenje)
Tjedan7:
Kolokvij
Tjedan8:
E-procjena znanja
Tjedan9:
Inteligentni tutorski sustavi
Tjedan10:
ADDIE model za oblikovanje nastave
Tjedan11:
Primjena ADDIE modela u oblikovanju lekcija u Moodleu
Tjedan12:
Primjena ADDIE modela u oblikovanju lekcija u Moodleu
Tjedan13:
Metodologija za vrednovanje sustava e-učenja
Tjedan14:
Metodologija za vrednovanje sustava e-učenja
Tjedan15:
Kolokvij</td></tr>
<tr><td>Vrste izvođenja nastave</td><td>☑ Predavanja
☑ Seminari</td><td>☐ Terenska nastava
☑ Samostalni zadaci</td><td colspan="2">☑ Domaće zadaće</td></tr>
</table>

	☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje		☐ Multimedija ☐ Laboratorij ☐ Mentorski rad		☐ ☐ ☐	
Obveze studenata	Pohađanje nastave, aktivno sudjelovanje u nastavnom procesu, domaće zadaće, kolokvij, pismeni 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	0.5
	Eksperimentalni rad		Referat		Domaće zadaće	0.5
	Esej		Seminarski rad	1		
	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 vježbama, rješavanje zadataka, opća aktivnost na nastavi) (20 %). Praktični rad (60%) Pismeni dio ispita (10%) Usmeni dio ispita (10%) Završna ocjena izvodi se na temelju svih navedenih ocjena					
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija			
	-					
Dopunska literatura	Larkin, Jill H., and Ruth W. Chabay. Computer-Assisted Instruction and Intelligent Tutoring Systems: Shared Goals and Complementary Approaches. Technology in Education Series. Lawrence Erlbaum Associates, Inc., 1992. Gauthier, Gilles, Frasson, Claude, VanLehn, Kurt (Eds.) Intelligent Tutoring Systems, 5th International Conference, ITS 2000, Montreal, Canada, June 19-23, 2000 Proceedings Joseph Psotka; L. Dan Massey; Sharon A. Mutter; John Seely Brown, Intelligent Tutoring Systems: Lessons Learned, LAWRENCE ERLBAUM ASSOCIATES PUBLISHERS 1988 Hillsdale, New Jersey Hove and London Hugh Burns, James W. Parlett, Carol Luckhardt Redfield, Intelligent Tutoring Systems: Evolutions in Design, LAWRENCE ERLBAUM ASSOCIATES, PUBLISHERS 1991 Hillsdale, New Jersey Hove and London					
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)						

Naziv kolegija	Kineziološka aktivnost, fitness i zdravlje					
Kod	PMS135	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Mladen Hraste	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	0	15	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Prvi je cilj kolegija da se studentima pomogne u razumijevanju i provođenju zdravog načina život. Drugi je cilj kolegija da se preko kineziloških operatora očuva i unaprijedi njihovo zdravlje te podigne kvaliteta njihovog života i studiranja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema uvjeta za upis predmeta. Nema ulaznih kompetencija.
Ishodi učenja	Student će nakon odslušanog predmeta moći: 1.provoditi samostalno participiranje u fitness programima, 2.provoditi tjelesno aktivan način života, 3.primijeniti naučena znanja i vještine potrebne za daljnje samostalno učenje i stjecanje novih motoričkih kompetencija, 4.promicati vrijednosti aktivnoga i zdravoga načina života 5.promicati vrijednosti boljeg mentalnog i fizičkog zdravlja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.(2 sata predavanja): pojam i definicija kineziologije; razvoj i struktura kineziologije 2.(2 sata predavanja): jednadžba specifikacije u sportu 3.(2 sata predavanja): kineziološka aktivnost i zdravlje 4.(2 sata predavanja): pregled znanstvenih istraživanja o učincima kineziološke aktivnosti na ljudsko zdravlje 5.(2 sata predavanja): program suvremene aerobike 6.(2 sata predavanja): cardio fitness program 7.(3 sata predavanja): weight fitness program 8.(2 sata vježbi): program suvremene aerobike (pilates) 9.(2 sata vježbi): program suvremene aerobike (aerobic) 10.(2 sata vježbi): cardio fitness program (manual i fat burn program) 11.(2 sata vježbi): cardio fitness program (high intensity interval training) 12.(2 sata vježbi): weight fitness program za donje ekstremitete 13.(2 sata vježbi): weight fitness program za ruke i rameni pojas 14.(3 sata vježbi): weight fitness program za trup
Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐			
Obveze studenata	Studenti su obvezni prisustvovati minimalno 24 od ukupno 30 predviđenih sati (80%)					

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
	Pohađanje nastave	0.75	Istraživanje		Praktični rad	0.75
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit			
	Pismeni ispit	0.5	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	predmet se ocjenjuje kao aritmetička sredina ocjene iz praktičnog i teoretskog dijela ispita. Student će dobiti ocjenu odličan (5) iz praktičnog dijela ispita ako motoričko gibanje izvodi bez greške, lako i skladno. Student će dobiti ocjenu vrlo dobar (4) iz praktičnog dijela ispita ako motoričko gibanje izvodi bez greške, lako i skladno, ali malo “tvrđe”. Student će dobiti ocjenu dobar (3) iz praktičnog dijela ispita ako motoričko gibanje izvodi s manjim greškama i uz manje poteškoće . Student će dobiti ocjenu dovoljan (2) iz praktičnog dijela

<table>
<tr><td></td><td colspan="3">ispita ako motoričko gibanje izvodi s velikim greškama i uz velike poteškoće. Student će dobiti ocjenu nedovoljan (1) iz praktičnog dijela ispita ako ne može izvesti motorički zadatak ni u elementarnom obliku. Teoretski dio se polaže pismenim testom.</td></tr>
<tr><td rowspan="2">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td>http://www.pmfst.hr/~mhraste/ Priručnik iz kolegija Kineziološka aktivnost, fitness i zdravlje</td><td></td><td>dostupno</td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">Delavier F. (2009). Anatomski vodič za vježbe snage. Medicinska naklada, Zagreb.
Milanović i sur. (1996). Fitness. Fakultet za fizičku kulturu Sveučilišta u Zagrebu, Zagrebački velesajam, Zagrebački športski savez, Fakultet za fizičku kulturu. Mišigoj-Duraković M. i sur. (1999). Tjelesno vježbanje i zdravlje. Fakultet za fizičku kulturu Sveučilišta u Zagrebu.
Mraković M. (1993). Osnove sistematske kineziologije. Priručnik za sportske trenere (ur. Milanović D., Kolman M.). Fakultet za fizičku kulturu, Hrvatski olimpijski odbor, Zagrebački sportski savez.
Sharkey, B. J. ; Gaskill, S. E. (2008). Fitness and health. Vežbanje i zdravlje. Beograd: Subcom.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Vanjska i unutarnja ekspertna evaluacija. Studentska evaluacija.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

Naziv kolegija	Matematičke osnove kriptografije					
Kod	PMM850	Godina studija	1.			
Nositelj/i kolegija	izv. prof. dr. sc. Marija Bliznac Trebješanin prof. dr. sc. Borka Jadrijević	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	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)			

<table>
<tr><td>Naziv kolegija</td><td colspan="3">Metodologija dizajna interakcija</td></tr>
<tr><td>Kod</td><td>PMIH40</td><td>Godina studija</td><td>1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Andrina Granić</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: 30 S: 15 V: 0 T: 0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td>25%</td></tr>
<tr><td colspan="4">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="3">Stjecanje temeljnih znanja o multidisciplinarnom području dizajna interakcija koje se bavi dizajniranjem interaktivnih proizvoda u cilju podržavanja i olakšavanja ljudske komunikacije i interakcije u svakodnevnom životu i radu. Usvajanje teorijskog znanja i praktičnog iskustva o HCI metodama dizajniranja za razvoj korisniku usmjerenog interaktivnog sustava, a sve u cilju kreiranja kvalitetnog korisničkog iskustva. Predmet u fokus procesa dizajniranja stavlja ljude a ne tehnologiju.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="3">Ne postoje formalni preduvjeti, ali bi bilo poželjno da su studenti odslušali kolegij Interakcija čovjeka i računala I: osnove i principi.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="3">Prepoznati, imenovati i objasniti osnovne koncepte i terminologiju koja se koristi u području dizajna interakcija.

Odabrati, argumentirati odabir i primijeniti prikladne metode dizajniranja za razvoj korisniku usmjerenog interaktivnog sustava u različitim fazama dizajniranja: prikupljanje informacija, planiranje, izrada prototipa i vrednovanje.

Kritički analizirati prednosti i nedostatke korištenja metoda dizajna iz HCI područja kod razvoja interaktivnih sustava.

Usporediti i procijeniti pristupe vrednovanju sustava.

Prosuditi o ulozi koju HCI metode imaju u razvoju sustava.

Studija slučaja: preispitati i kritički prosuditi razloge za razvoj interaktivnog sustava/proizvoda; promatrati i identificirati kontekst korištenja te prikupiti relevantne informacije s obzirom na postavljene ciljeve; izraditi „persone“ i scenarije te prototipove niske vjerodostojnosti; primijeniti prikladne metode dizajniranja za razvoj korisniku usmjerenog interaktivnog sustava/proizvoda; razviti interaktivne prototipove visokog stupnja vjerodostojnosti; odabrati i koristiti prikladan pristup vrednovanju.</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="3">Predavanja:

Dizajn interakcija: definicija područja i osnovnih pojmova (2)

Povijesni pregled razvoja dizajna interakcija (2)

Koncepti upotrebljivosti, korisničkog iskustva i kvalitete korištenja (2)

Dizajniranje za korisničko iskustvo (2)

Istraživačke metode: vizualizacija informacija, sučelja i interakcija (2)

Pozvano predavanje (2)

Proces dizajna interakcija: korisniku-usmjeren dizajn, izrada prototipa, vrednovanje, razvoj/izvedba (4)

Metode „persona“ i scenarija (2)</td></tr>
</table>

	Metode izrade skica i prototipova niske i visoke vjerodostojnosti (2) Dizajniranje sudjelovanjem (2) Metode vrednovanja interakcije (4) Budućnost dizajna interakcija (4) Vježbe: Uvod u vježbe iz kolegija - općenito o strukturi vježbi; znanju i vještinama koja će se steći; temama koje će se obraditi; načinu rada; individualnim i grupnim zadacima; ocjenjivanju. (2) Uvod u dizajn interakcija - dizajn digitalnih artefakata; nove tehnologije; nova sučelja; 1. individualni zadatak za studente (analiza 3 primjera dizajniranih interakcija). (2) Prezentacije 1. individualnog zadatka studenata - analiza i rasprava. (2) Pristupačnost (eng. accessibility) - dizajn za sve i univerzalna pristupačnost; pristupačnost i upotrebljivost; kategorije poteškoća i primjeri pristupačnog dizajna interakcija; 2. individualni zadatak za studente (analiza interaktivnih sučelja dizajniranih po kategorijama poteškoća). (2) Prezentacije 2. individualnog zadatka studenata - analiza i rasprava. (2) Razumijevanje korisnika - emocionalni aspekti; emocionalna sučelja; persuazivne tehnologije; antropomorfizam; virtualni likovi i agenti; virtualni suradnici pri učenju. (2) Dizajniranje za iskustvo korisnika - 5 nivoa dizajna; potrebe korisnika; izrada „persona“. (2) Uvod u grupni projekt - dizajniranje, vrednovanje i implementacija sučelja interaktivnog predmeta; analiza trenutnog stanja. (2) Odabir koncepta interaktivnog predmeta - rad u grupama. (2) Izrada prototipa sučelja interaktivnog predmeta - rad u grupama. (2) Provedba vrednovanja sučelja interaktivnih predmeta - rad u grupama. (2) Prezentacije provedenih vrednovanja po grupama - analiza i rasprava. (2) Definiranje potrebnih promjena na sučeljima interaktivnih predmeta - rad u grupama. (2) Implementacija potrebnih promjena na sučeljima interaktivnih predmeta - rad u grupama. (2) Grupni projekti - završne prezentacije projekata studenata po grupama. (2)
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☑ Mentorski rad ☐ ☐ ☐ ☐
Obveze studenata	Redovito pohađanje i aktivno sudjelovanje u svim oblicima nastave. Samostalno rješavanje individualnih zadataka i studija slučaja.

	Izrada projektnog zadatka i polaganje usmenog ispita.					
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	2
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit	1		
	Pismeni ispit	1	Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Kvaliteta izvedbe dodijeljenih zadataka (50%). Usmeni ispit (50%).					

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	J. Preece, Y. Rogers, H. Sharp: Interaction Design: Beyond Human-Computer Interaction, John Wiley & Sons, 4th Edition, 2015.	2	prethodna izdanja on-line
	D. Saffer: Designing for Interaction, Second Edition: Creating Innovative Applications and Devices, New Riders, 2010.		on-line

Dopunska literatura	1. D. Norman: Emotional Design: Why We Love (or Hate) Everyday Things, Basic Books, 2005. 2. B. Shneiderman: Human Needs and the New Computing Technologies, MIT Press, 2003. Svi nastavni materijali dostupni on-line, uključujući i dodatnu znanstvenu literaturu
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata na kolegiju, samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Modeliranje sustava programske podrške					
Kod	PMID54	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Branko Žitko	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	30	0	0
Status kolegija	Izborni	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)			

Naziv kolegija	Osnove teorije strategijskih igara					
Kod	PMIG20	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Aljoša Šubašić	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			45	0	0	0
Status kolegija	Izborni	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)			

Naziv kolegija	Računalna grafika					
Kod	PMII50	Godina studija	1.			
Nositelj/i kolegija	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	0%			

Opis kolegija	
Ciljevi kolegija	Upoznati osnove rada računalnog grafičkog sustava, formiranje slike i grafičkih objekata.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	-
Ishodi učenja	1. Digitalna reprezentacija informacije u računalu s posebnim naglaskom na sliku: upoznati pojmove otipkavanja, gubitka informacije i aliasinga. 2. Ograničenje ljudske percepcije i kako to utječe na zapis informacije u računalu, odnodno metode kompresije (kompresija s gubitkom informacije i bez gubitka informacije, naglaska na učestalim formatima kompresije poput: JPG, PNG, MP3) 3. Upoznati različite modele reprezentacije boje u računalu i način prikaza boje 4. Upoznati razliku između spremanja informacije i spremanja dovoljno podataka da se informacija prenese, razlikovati rastersku od vektorske grafike te njihove prednosti i mane. 5. Upoznati način stvaranja privida kontinuiranog kretanja iz niza statičnih slika 6. Osoposobiti studente za pisanje računalnog programa za prikazivanje jednostavnog 3D objekta 7. Korištenje linearnih perspektivnih transformacija slike i affinih tranfromacija objekta, proširenje 2D matričnih transformacija u 3D prostor
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Primjene i osnovni koncepti računalne grafike (2) 2. Ljudska percepcija, doživljaj slike i pohrana informacije u računalu (4) 3. Grafičko sklopovlje i uređaji, grafički cjevovod (2) 4. Elementi slike i algoritmi, ispunjavanje i odrezivanje (2) 5. Matematički temelji računalne grafike, aliasing (2) 6. Kolokvij 7. Osnove animacije, alati za izradu animacije i izrada animacije izrada animacije (6) 8. Geometrijske transformacije i projekcije. (4) 9. Rasterski i vektorski grafički sustavi. (2) 10. Dubina i osvjetljenje (2) 11. Prikazivanje crta, krivulja, površina i tijela (2) 12. Kolokvij 1. Upoznavanje s Pythonom i OpenGLom (2) 2. Upoznavanje s OpenGL-om (2) 3. Crtanje točaka u 2D prostoru (2) 4. OpenGL primitivi za crtanje složenijih objekata (2) 5. Bojanje objekta i simetrija u računalnoj grafici (2) 6. Crtanje 3D objekta (2) 7. Projekcije i afine transformacije (2) 8. Animacija (2) 9. Interakcija s objektom (4) 10. Klase i objekti (objektno orijentirano programiranje uz OpenGL) (4) 11. Predloženi vlastiti projekt (6)
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*	Pohađanje nastave	1	Istraživanje		Praktični rad	1
	Eksperimentalni rad		Referat			

aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)	Esej		Seminarski rad			
	Kolokviji	1	Usmeni ispit	0.5		
	Pismeni ispit	0.5	Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (25%) Projekt (20%) Pismeni/usmeni ispit (55%)		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Bilješke s predavanja: Računalna grafika, Hrvoje Kalinić		
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">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>Izborni</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.

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.</td></tr>
</table>

	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)	

Naziv kolegija	Uvod u obradu prirodnog jezika					
Kod	PMII40	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Branko Žitko	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	0%			

Opis kolegija	
Ciljevi kolegija	Upoznavanje područja obrade prirodnog jezika. Obrada na morfološkom, sintaktičkom, semantičkom i pragmatičkom nivou s lingvističke i računalne perspektive. Usvajanje temeljnih modela i algoritama za obradu prirodnog jezika.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Ulazne kompetencije: linearna algebra i vjerojatnost, objektno orijentirano programiranje u Pythonu.
Ishodi učenja	opisati metode obrade prirodnog jezika pripremiti podatke za obradu prirodnog jezika implementirati algoritme za obradu prirodnog jezika u Pythonu ocijeniti i usporediti rezultate obrade prirodnog jezika
Sadržaj kolegija detaljno razrađen prema satnici nastave	Tjedan1: Predavanja: Uvodno predavanje: nastavnici, obaveze studenata, elementi tekućeg praćenja, ispit, ocjena, predstavljanje ciljeva kolegija, literatura Problemi obrade prirodnog jezika, težinska kategorizacija Vježbe: Rad s tekstualnim datotekama i Web sadržajem u programskom jeziku Python Tjedan2: Predavanja: Osnove obrade jezika, regularni izrazi, tokenizacija riječi, normalizacija riječi i izvlačenje korijena, segmentacija rečenice i stabla odluke Vježbe: Regularni izrazi u Pythonu, segmentacija riječi i rečenica pomoću regularnih izraza, izvlačenje teksta iz Web stranice Tjedan3: Predavanja: Minimalna udaljenost dva niza znakova, izračun minimalne udaljenosti, povratno praćenje kod izračuna poravnanja, težinska minimalna udaljenost, minimalna udaljenost u računalnoj biologiji Vježbe: Implementacija algoritam minimalne udaljenosti u Pythonu, Implementacija povratnog praćenja kod izračuna minimalne udaljenosti Tjedan4: Predavanja: Modeliranje jezika, n-gram, procjena vjerojatnosti n-grama, evaluacija i perpleksija, generalizacija i problem nula, Laplaceovo izglađivanje, interpolacija i odustajanje, good-turing izglađivanje Vježbe: Modeliranje n-grama u Pythonu, generiranje jezika temeljem n-grama.

Tjedan5:

Predavanja: Ispravljanje pravopisnih grešaka, kanal sa šumom, greške stvarnih riječi

Vježbe: Implementacija algoritma za ispravljanje pravopisnih grešaka temeljem rječnika i minimalne udaljenosti

Tjedan6:

Predavanja: Klasifikacija teksta, naivni Bayes klasifikator, formalizacija naivnog Bayesovog klasifikatora, učenje klasifikatora, odnos s modelom jezika, multinominalni naivni Bayesov klasifikator, preciznost i opoziv, F-mjera, evaluacija klasifikatora

Vježbe: Implementacija naivnog Bayesovog klasifikatora u Pythonu

Tjedan7:

Predavanja: Sentimentalna analiza i osnovni algoritmi, leksikon sentimenata, učenje leksikona sentimenata

Vježbe: Implementacija sentimentalnog analizatora u Pythonu zasnovanog na leksikonu

Tjedan8:

Predavanja: usporedba diskriminativnog i generativnog klasifikatora, osobine diskriminativnog klasifikatora, linearni klasifikator temeljem na osobinama teksta, model maksimalne entropije, optimizacija vjerojatnosti

Vježbe:

Tjedan9:

Predavanja:Prepoznavanje imenovanih entiteta (NER), ekstrakcija informacija, evaluacija NER, slijedni model za NER, maksimalna entropija slijednog modela

Vježbe: Implementacija Markovljevog modela maksimalne entropije za identifikaciju naziva osoba

Tjedan10:

Predavanja: Ekstrakcija relacija (RE), korištenje uzoraka kod RE, nadzirana RE, polunadzirana i nenadzirana RE

Vježbe: Treniranje Markovljevog modela maksimalne entropije

Tjedan11:

Predavanja: Parsiranje teksta, sintaktičke strukture, empirijski pristup parsiranju, eksponencijalni problem parsiranja

Vježbe: Modeliranje CFG

Tjedan12:

Predavanja: Probabilističko parsiranje, kontekstno neovisne gramatike (CFG) i probabilističke kontekstno neovisne gramatike (PCFG), transformacija gramatike, CKY parsiranje

Vježbe: Implementacija CKY parsera za PCFG

	Tjedan13: Predavanja: Vraćanje informacija IR, term-dokument matrice, invertirani indeksi, obrada upita temeljem invertiranih indeksa, frazni upiti i pozicijski indeksi, rankirani IR, bodovanje, TF-IDF težine, model vektorskog prostora Vježbe: Implementacija IR sustava temeljenog na TF-IDF Tjedan14: Predavanja: Sustavi za odgovaranje na pitanja QA, tipovi odgovora i formuliranje upita, ekstrakcija odgovora, korištenje znanja u QA Vježbe: Implementacija QA sustava korištenjem Wiki resursa Tjedan15: Predavanja: Uvod u sumarizaciju, generiranje isječaka i ekstrakcija odgovora, evaluacija sumarizacije, sumarizacija skupa dokumenata Vježbe: Implementacija sumarizacije temeljena na ekstrakciji informacija

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 aktivno sudjelovanje u nastavnom procesu pismeni 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	1
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit			
	Pismeni ispit	2	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu
Aktivnost studenata na predavanjima i vježbama (prisutnost na vježbama, rješavanje zadataka) (50 %). Pismeni dio ispita (50 %), Završna ocjena izvodi se na temelju svih navedenih ocjena.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	D. Jurafsky, J. H. Martin, (2000) Speech and Language Processing, PrenticeHall	1	

Dopunska literatura
S. Bird, E. Klain, E. Looper, (2009) Natural Language Processing with Python, O'Reilly Media

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)

Naziv kolegija	Uvod u podatkovnu znanost					
Kod	PMIH25	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Divna Krpan	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	20%			

Opis kolegija	
Ciljevi kolegija	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.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	
Ishodi učenja	- 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
Sadržaj kolegija detaljno razrađen prema satnici nastave	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)
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 Izrada seminarskih radova Samostalni zadaci

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj*						
	Pohađanje nastave	0.5	Istraživanje		Praktični rad	0.5
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	0.5		

ECTS bodova odgovara bodovnoj vrijednosti kolegija)	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)	

Naziv kolegija	Znanstveno programiranje					
Kod	PMID15	Godina studija	1.			
Nositelj/i kolegija	Dino Nejašmić, pred.	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	20%			

Opis kolegija	
Ciljevi kolegija	Stjecanje znanja i vještina znanstvenog programiranja potrebnih za kolegije iz područja podatkovne znanosti i inženjerstva.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Osnove programiranja, poželjno Python.
Ishodi učenja	- Primjena odgovarajućih stuktura podataka i algoritama za zadani problem - Primjena paradigmi svojstvenih paralelnom/funkcijskom programiranju - Sposobnost vizualiziranja rezultata i izvještavanje rezultata kodom - Primjena numeričkih biblioteka za rješavanja algebariskih i statističkih problema - Analizirati složenosti algoritma - Organizirati program u funkcije i module - Razumjeti internu strukturu operacijskog sustava i njegovu jezgre - Napisati skriptu za izvršavanje u jezgri operacijskog sustava
Sadržaj kolegija detaljno razrađen prema satnici nastave	- Uvod u računarstvo, operacijske sustave i jezgru operacijskog sustava - Datotečni sustav, privilegije i uloge, Unix ljuska, redirekcija - Napredne naredbe za rad u ljusci: bash, grep, awk... - Python: varijable, vrste vrijednost, strukture i iteracije - Python: funkcije, imenovanja, dosezi i moduli - Objektno orjentirano programiranje u Python-u - Python: labda račun, liste, funkcijsko programiranje - Python za linearnu algebru i numeričko računanje: numpy, scipy... - Strukture podataka, dohvat i pohrana podataka - Python za analizu podataka: pandas, sklearn... - Python u primijeni: sklearn, pandas... - Plotting za izvještavanje: matplotlib i jupyter - Upravljanje verzijama koda, integracija i optimizacija koda - Osnove paralelizacije koda u Unix ljusci i Pythonu; skalabilnost - Priprema za ispit

<table>
<tr><td>Vrste izvođenja nastave</td><td colspan="5">☑ Predavanja
☐ Seminari
☑ Vježbe
☐ On line u cijelosti
☑ Mješovito e-učenje</td><td colspan="3">☐ Terenska nastava
☐ Samostalni zadaci
☐ Multimedija
☐ Laboratorij
☑ Mentorski rad</td><td>☐
☐
☐
☐</td></tr>
<tr><td>Obveze studenata</td><td colspan="9">Prisustvo i zalaganje studenata na nastavi, izrada zadataka na satu, izrada zadataka kod kuće</td></tr>
<tr><td rowspan="6">Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td colspan="2">Pohađanje nastave</td><td>1</td><td colspan="2">Istraživanje</td><td></td><td colspan="2">Praktični rad</td><td></td></tr>
<tr><td colspan="2">Eksperimentalni rad</td><td></td><td colspan="2">Referat</td><td></td><td colspan="2">Domaće zadaće</td><td>1</td></tr>
<tr><td colspan="2">Esej</td><td></td><td colspan="2">Seminarski rad</td><td></td><td colspan="2"></td><td></td></tr>
<tr><td colspan="2">Kolokviji</td><td>1</td><td colspan="2">Usmeni ispit</td><td>1</td><td colspan="2"></td><td></td></tr>
<tr><td colspan="2">Pismeni ispit</td><td>1</td><td colspan="2">Projekt</td><td></td><td colspan="2"></td><td></td></tr>
<tr><td colspan="2"></td><td colspan="6"></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="9">Prisustvo i zalaganje studenata na nastavi, izrada zadataka na satu, izrada zadataka kod kuće</td></tr>
<tr><td rowspan="5">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="6">Naslov</td><td>Broj primjeraka u knjižnici</td><td colspan="2">Dostupnost putem ostalih medija</td></tr>
<tr><td colspan="6">C. Hill: Learning Scientific programming with Python</td><td>1</td><td colspan="2"></td></tr>
<tr><td colspan="6">C. Fuehrer, J.E. Solem, O. Verdier: Scientific Computing with Python 3</td><td>1</td><td colspan="2"></td></tr>
<tr><td colspan="6">M. Kerrisk: The Linux Programming Interface</td><td>1</td><td colspan="2"></td></tr>
<tr><td colspan="6">H. P. Langtangen: A Primer on Scientific Programming with Python</td><td></td><td colspan="2">da</td></tr>
<tr><td>Dopunska literatura</td><td colspan="9">H. P. Langtangen: A Primer on Scientific Programming with Python</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="9">Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata na kolegiju, samoanaliza.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="9"></td></tr>
</table>

Naziv kolegija	Jezični procesori					
Kod	PMID60	Godina studija	1.			
Nositelj/i kolegija	dr. sc. Tonći Dadić, pred. prof. dr. sc. Marko Rosić	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	0%			

Opis kolegija	
Ciljevi kolegija	Uvesti glavne pojmove povezane s implementacijom jezičnih procesora programskih jezika: leksička analiza, sintaksna analiza, semantička analiza, potpora izvršavanju programa i generiranje koda programa u ciljnom jeziku.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Objektno programiranje.
Ishodi učenja	Studenti će moći: 1. Objasniti postupke analize i sinteze programa 2. Razumjeti leksička, sintaksna i semantička svojstva programskog jezika 3. Formalno definirati jednostavan proceduralni programski jezik 4. Odabrati postupak sintaksne analize primjeren gramatici jezika 5. Razviti jezični procesor jednostavnog proceduralnog programskog jezika 6. Razviti virtualni stroj definiran programskim jezikom.
Sadržaj kolegija detaljno razrađen prema satnici nastave	Tjedan1: Uvod u predmet. Definicija jezičnog procesora. Komponente jezičnog procesora. Automat. Potisni automat. Turingov stroj. Vježbe. Oblikovanje i implementacija automata. Tjedan2: Regularni izrazi. Leksička jedinka. Klasifikacija leksičkih jedinki. Konflikt leksičke analize. Oblikovanje leksičkog analizatora. Leksičke greške i oporavak. Vježbe: Regularni izrazi. Korištenje klase Regex. Tjedan3: Definicija gramatike. Formalni prikaz gramatike u BNF notaciji. Klasifikacija jezika po Chomskom. Vježbe: Implementacija leksičkog analizatora utemeljenog na klasi Regex. Tjedan4: LL(1) i LR(1) gramatika. Lijevo i desno generativno sintaksno stablo. Apstraktno sintaksno stablo. Vježbe: Oblikovanje i implementacija: objektni modeli gramatike i apstraktnog sintaksnog stabla. Tjedan5: Uvođenje jednostavnog programskog jezika: ulaz, izlaz i pridjeljivanje varijabli vrijednosti algebarsko-logičkog izraza sa zagradama. LL(1) gramatika jezika. Sintaksna analiza rekurzivnim spustom. Vježbe: Oblikovanje i implementacija parsera rekurzivnim spustom. Tjedan6: Izgradnja sintaksnog analizatora od vrha prema dnu uz pomoć potisnog automata. Skupovi započinje, slijedi i primjeni. Tablica sintaksne analize. Vježbe: Implementacija postupka izgradnje tablice sintaksne analize. Tjedan7: Parsiranje programa od vrha prema dnu pomoću potisnog automata. Sintaksne pogreške i oporavak. Vježbe: Priprema za prvi kolokvij. Tjedan8: LR(0) sintaksni analizator. Izgradnja tablica IDI NA / AKCIJA. LR sintaksnog analizatora. Vježbe: Prvi kolokvij Tjedan9: Slabosti LR(0) gramatike. LR(1) sintaksni analizator. Izgradnja tablica IDI NA / AKCIJA LR(1) sintaksnog analizatora. Vježbe: Implementacija sintaksnog analizatora od vrha prema dnu utemeljenog na potisnom automatu. Tjedan10: Proširenje gramatike jednostavnog jezika instrukcijama odluke i ponavljanja. Tablica identifikatora. Semantička analiza programa. Vježbe: Oblikovanje i implementacija LR sintaksnog analizatora. Tjedan11: Virtualni stogovno orijentirani stroj. Uvođenje instrukcija međukoda. Vježbe: Oblikovanje i implementacija LR sintaksnog analizatora (nastavak). Tjedan12: Podrška izvršavanju programa. Pozivi procedura i funkcija. Podrška rekurziji. Vježbe: Oblikovanje i implementacija tablice identifikatora te semantičke analize programa. Tjedan13: Generiranje međukoda kao linearnog programa virtualnog stroja. Vježbe: Oblikovanje i implementacija stogovno orijentiranog virtualnog stroja. Tjedan14: Osnovne značajke prevođenja objektno orijentiranih programskih jezika. Vježbe: Priprema za drugi kolokvij.

	Tjedan15: Studija primjera virtualnog stroja: Microsoft IL jezik. Vježbe: Drugi kolokvij.

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, aktivno sudjelovanje u nastavnom procesu, domaće zadaće, kolokvij ili praktični/pismeni ispit, 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	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%), dvije domaće zadaće (10%), praktični/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
	Srbljić, S: Prevođenje programskih jezika, Element, Zagreb, 2007.	10	
Dopunska literatura	Grune, D., Bal, H., E., Jacobs, C., J., H., Langendoen, K., G.: Modern Compiler Design, Wiley, 2000.		
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)			

Naziv kolegija	Multimodalna interakcija i sučelja					
Kod	PMIH50	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Andrina Granić	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	25%			

Opis kolegija	
Ciljevi kolegija	U svojoj međusobnoj komunikaciji ljudi intenzivno upotrebljavaju multimodalnost bilo simultano u svojoj neposrednoj komunikaciji ili alternativno govorom, pisanjem, pokretima, dodirima. S druge strane komunikacija s računalima tradicionalno upošljava nekoliko modaliteta: korisnik osigurava ulaz putem tipkovnice ili pokazne naprave, dok računalo odgovara vizualno, u formi teksa ili ikona. Predmet osigurava usvajanje teorijskog znanja i uvodnog praktičnog iskustva iz multimodalne komunikacije i različitih vrsta sučelja u području Interakcije čovjeka i računala (engl. Human-Computer Interaction, HCI). Predmet daje uvod u nova sučelja koja mogu poboljšati korisničko iskustvo ili djelotovornost interakcije s računalima kao što su kontrola glasa, interakcija zvukom, raspoznavanje pokreta, proširena stvarnost, haptička povratna informacija.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Poželjno odslušan kolegij Interakcija čovjeka i računala: osnove i principi.
Ishodi učenja	Nakon što polože predment studenti bi trebali: - imenovati i objasniti funkcionalnost suvremenih multimodalnih ili alternativnih sučelja u HCI području, - kritički analizirati prednosti i nedostatke multimodalnih sučelja, - primijeniti/ implementirati HCI sučelja upošljavajući nove tehnike interakcije za neke zadatke (ograničene), - predložiti učinkoviti dizajn novih sučelja primjenom razlčitih modaliteta. U skladu s navedenim, studenti će biti u mogućnosti: - proširiti znanje o nekim specifičnim modalitetima interakcije u drugim predmetima, - primijeniti multimodalnost kako u individulanim zadacima tako i u kontekstu grupnog projekta, - odabrati prikladno sučelje za odabrani zadatak (kako iz HCI tako i iz tehničke perspektive).
Sadržaj kolegija detaljno razrađen prema satnici nastave	Predmet se fokusira na grupni projekt namijenjen kreiranju, analiziranju i/ili vrednovanju multimodalnog ili inovativnog sučelja za konkretni dodijeljeni zadatak. U cilju pripreme za projekt, teorijska predavanja i laboratorijske vježbe osiguravaju uvid u različite tehnologije sučelja, dok se individulani (domaći) zadaci rješavaju u svrhu osgiravanja prikladne „podloge“ i planiranja. Osnovni fokus stavlja se na tehnike vezane za (i) korisnički ulaz kao što je prepoznavanje govora, zasloni na dodoir ili praćenje pogleda oka ili pokreta, te (ii) računalni izlaz kao što se nekonvencionalni zasloni, sinteza govora, zvučni objekti i haptički uređaji. Specifično se također adresiraju efekti kombiniranja različitih modaliteta. Predavanja: 1. Uvod u multimodalna sučelja 2. Mješovita stvarnost 3. Tabletops, taktilnost i praćenje 4. Sučelja temeljena na pokretima 5. Zvuk u interakciji 6. Govorna sučelja 7. Multimodalna konverzacijska sučelja 8. Haptička sučelja 9. Individualni zadaci – analiza i rasprava 10. Seminari

	Vježbe: 1. Sučelja za praćenje pogleda (Tobii) 2. Sučelja temeljena na pokretima (Kinect, Leap) 3. Haptička sučelja (Falcon) 4. Zvukovna/govorna sučelja 5. Taktilna sučelja (Smart Phone with tactile feedback) 6. Grupni projekti 7. Kolokviji /ispit

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

Obveze studenata	Redovito pohađanje i aktivno sudjelovanje u svim oblicima nastave. Samostalna priprema seminara i rješavanje individualnih zadataka. Izrada grupnog projektnog zadatka i polaganje ispita.

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	1	Referat			
	Esej		Seminarski rad	1		
	Kolokviji		Usmeni ispit			
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	
	Seminari (10%) Individualni zadaci (10%) Grupni projekti (30%) Kolokviji /ispit (50%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Dumas, B., Lalanne, D., Oviatt, S. (2009). Multimodal Interfaces: A Survey of Principles, Models and Frameworks. In Denis Lalanne, Jürg Kohlas eds. Human Machine Interaction, LNCS 5440, Springer-Verlag, Berlin/Heidelberg, pp. 3-26. Oviatt S. (1999). Ten myths of multimodal interaction. Communications of the ACM, 42(11), pp. 74 - 81. Reeves et al. (2004). Guidelines for multimodal user interface design. Communications of the ACM, 47 (1), pp. 57-59. Olwal, A. (2009). An Introduction to Augmented Reality. Schöning et al. (2008). Multi-Touch Surfaces: A Technical Guide. Technical Report TUMI0833. Jacob, R. and Kam, K. (2003). Eye Tracking in Human-Computer Interaction and Usability Research: Ready to Deliver the Promises. In Hyona et al. (Eds.), The Mind's eye: Cognitive and Applied Aspects of Eye Movement Research (pp. 573-603). Mitra, S. and Acharya, T. (2007). Gesture recognition: A Survey. IEEE Transactions On Systems, Man and Cybernetics - Part C, 37(3), 311-324. Rocchesso, D., & Bresin, R. (2007). Emerging sounds for disappearing computers. In Streitz, N., Kameas, A., & Mavrommati, I. (Eds.), The Disappearing Computer (pp. 233-254). Berlin Heidelberg: Springer. Mohamed Yacine Tsalamlal, Nizar Ouarti, Mehdi Ammi. (2013). Non-intrusive Haptic Interfaces: State-of-the Art Survey. In Haptic and Audio Interaction Design. LNCS Volume 7989, 2013, pp 1-9.		da

	Oviatt S. (1999). Ten myths of multimodal interaction. Communications of the ACM, 42(11), pp. 74 - 81.		da
	Reeves et al. (2004). Guidelines for multimodal user interface design. Communications of the ACM, 47 (1), pp. 57-59.		da
	Olwal, A. (2009). An Introduction to Augmented Reality.		da
	Schöning et al. (2008). Multi-Touch Surfaces: A Technical Guide. Technical Report TUMI0833.		da
	Jacob, R. and Kam, K. (2003). Eye Tracking in Human-Computer Interaction and Usability Research: Ready to Deliver the Promises. In Hyona et al. (Eds.), The Mind's eye: Cognitive and Applied Aspects of Eye Movement Research (pp. 573-603).		da
	Mitra, S. and Acharya, T. (2007). Gesture recognition: A Survey. IEEE Transactions On Systems, Man and Cybernetics - Part C, 37(3), 311-324.		da
	Rocchesso, D., & Bresin, R. (2007). Emerging sounds for disappearing computers. In Streitz, N., Kameas, A., & Mavrommati, I. (Eds.), The Disappearing Computer (pp. 233-254). Berlin Heidelberg: Springer.		da
	Mohamed Yacine Tsalamlal, Nizar Ouarti, Mehdi Ammi. (2013). Non-intrusive Haptic Interfaces: State-of-the Art Survey. In Haptic and Audio Interaction Design. LNCS Volume 7989, 2013, pp 1-9		da
	Svi nastavni materijali dostupni on-line, uključujući i dodatnu znanstvenu literaturu		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="4">Projektiranje sustava za e-učenje</td></tr>
<tr><td>Kod</td><td>PMIK30</td><td>Godina studija</td><td colspan="2">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Ani Grubišić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="2">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 S V T</td></tr>
<tr><td>30 0 30 0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="2">40%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">Cilj je ovladati metodologijom projektiranja sustava za e-učenje. Zadaci za realizaciju ovog cilja postižu se učenjem i poučavanjem: iteracijskog procesa za modeliranje sustava za e-učenjem identificiranjem sudionika i funkcionalnosti sustava za e-učenje; cjelovitosti vremenske i statičke komponente iteracijskog procesa za izgradnju sustava za e-učenje.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="4">Uvjeti za upis: nema ih.

Ulazne kompetencije: poznavanje osnova sustava e-učenja.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">Student će moći:

1. oblikovati model podataka sustava e-učenja

2. oblikovati model funkcionalnosti sustava e-učenja

3. usporediti različite modele sustava e-učenja

4. razviti funkcionalnost sustava e-učenja u proizvoljnom programskom jeziku

5. vrednovati razvijene funkcionalnosti sustava e-učenja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="4">Tjedan1:

Upoznavanje s kolegijem

Tjedan2:

Iteracijski proces za modeliranje programskog sustava

Tjedan3:

Sudionici sustava za e-učenje

Tjedan4:

Funkcionalnosti sustava za e-učenje

Tjedan5:

Vremenska komponenta iteracijskog procesa za projektiranje sustava za e-učenje (početak, pomna obrada, izgradnja, prijelaz u okruženje naručioca).

Tjedan6:

Statička komponenta procesa za projektiranje sustava za e-učenje (poslovno modeliranje, zahtjevi naručioca, analiza, oblikovanje, implementacija, testiranje, isporuka, vođenje procesa, vođenje promjena).

Tjedan7:

Kolokvij</td></tr>
</table>

	Tjedan8: Instalacija Moodlea Tjedan9: Kreiranje upita nad bazom Moodlea Tjedan10: Uvod u programiranje u PHPu Tjedan11: Oblikovanje web aplikacije/plugina nad bazom Moodlea. Tjedan12: Implementacija web aplikacije/plugina nad bazom Moodlea. Tjedan13: Postavljenje web aplikacije/plugina nad bazom Moodlea. Tjedan14: Testiranje web aplikacije/plugina nad bazom Moodlea. Tjedan15: Kolokvij

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, aktivno sudjelovanje u nastavnom procesu, domaće zadaće, kolokvij, pismeni ispit

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		Domaće zadaće	1
	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 vježbama, rješavanje zadataka, opća aktivnost na nastavi) (20 %). Praktični rad (60%) Pismeni dio ispita (10%) Usmeni dio ispita (10%) Završna ocjena izvodi se na temelju svih navedenih ocjena.

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

	Stankov, S.: E-učenje, Prirodoslovno-matematički fakultet, Sveučilište u Splitu, skripta, 2009.		da
	S. Stankov: Inteligentni tutorski sustavi: teorija i primjena, Prirodoslovno-matematički fakultet, Sveučilište u Splitu, skripta, 2010.		da
	Martha C. Polson; J. Jeffrey Richardson; Elliot Soloway, Foundations of Intelligent Tutoring Systems, LAWRENCE ERLBAUM ASSOCIATES PUBLISHERS 1988 Hillsdale, New Jersey Hove and London		
	Bryn Holmes and John Gardner, E-learning: concepts and practice, London: Sage, 2006 ISBN 1-412911-11-7		
	William Horton, e-Learning by Design, 2nd Edition, 2011, Published by: John Wiley & Sons		
Dopunska literatura	Larkin, Jill H., and Ruth W. Chabay. Computer-Assisted Instruction and Intelligent Tutoring Systems: Shared Goals and Complementary Approaches. Technology in Education Series. Lawrence Erlbaum Associates, Inc., 1992. Gauthier, Gilles, Frasson, Claude, VanLehn, Kurt (Eds.) Intelligent Tutoring Systems, 5th International Conference, ITS 2000, Montreal, Canada, June 19-23, 2000 Proceedings Joseph Psotka; L. Dan Massey; Sharon A. Mutter; John Seely Brown, Intelligent Tutoring Systems: Lessons Learned, LAWRENCE ERLBAUM ASSOCIATES PUBLISHERS 1988 Hillsdale, New Jersey Hove and London Hugh Burns, James W. Parlett, Carol Luckhardt Redfield, Intelligent Tutoring Systems: Evolutions in Design, LAWRENCE ERLBAUM ASSOCIATES, PUBLISHERS 1991 Hillsdale, New Jersey Hove and London		
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="4">Računalni vid</td></tr>
<tr><td>Kod</td><td>PMII60</td><td>Godina studija</td><td colspan="2">1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Barbara Džaja, prof. struč. stud.</td><td>Bodovna vrijednost (ECTS)</td><td colspan="2">5.0</td></tr>
<tr><td>Suradnici</td><td></td><td rowspan="2">Način izvođenja nastave (broj sati u semestru)</td><td colspan="2">P S V T
30 0 30 0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="2">30%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">Usvojiti znanja o osnovnim elementima sustava te algoritama i metoda koje se koriste u aplikacijama računalnog vida.
Samostalna sposobnost studenta da prilagodi i primjeni algoritme računalnog vida za konkretan problem.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="4">Uvjeti za upis: nema ih.
Ulazne kompetencije: poznavanje osnova rada na računalu i poznavanje osnova programiranja.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">Nakon uspješnog savladavanja kolegija, studenti bi trebali biti u mogućnosti:
1. Analizirati i prepoznati zadani problem iz područja računalnog vida
2. Klasificirati algoritme računalnog vida
3. Identificirati tipove slika
4. Napisati algoritam za obradu slike
5. Identificirati metodu obrade za zadani problem
6. Samostalno primjeniti algoritam na vlastitom problemu</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="4">1. Uvod u računalni vid
Predavanje: Upoznavanje s pravilima predmeta, evaluacijom i ciljevima učenja.
Vježba 1: Instalacija alata i biblioteka. Pregled sučelja i osnovnih funkcija.
2. Obrada slike - osnove
Predavanje: Uvod u digitalnu sliku i osnovne koncepte obrade.
Vježba 2: Osnovne operacije obrade slika (rezanje, rotacija, skaliranje).
3. Napredne tehnike obrade slike
Predavanje: Tehnike poboljšanja slike i restauracije.
Vježba 3: Primjena linearnih i nelinearnih filtara na stvarne slike.
4. Filtriranje slike
Predavanje: Detalji o filtriranju u prostornom i frekvencijskom domenu.
Vježba 4: Filtriranje slika korištenjem Fourierove transformacije.
5. Morfološke operacije
Predavanje: Osnove binarne i sive morfologije.
Vježba 5: Primjena morfoloških operacija (erozija, dilatacija).
6. Segmentacija i analiza slike
Predavanje: Metode segmentacije i njihova primjena.
Vježba 6: Segmentacija slike korištenjem različitih pristupa.
7. Analiza teksture i boje
Predavanje: Uloga boje i teksture u analizi slika.
Vježba 7: Analiza i klasifikacija tekstura.
8. 1. Kolokvij
Vježba 8: Priprema za kolokvij kroz rješavanje primjera zadataka.
9. Detekcija i prepoznavanje objekata
Predavanje: Metode detekcije objekata i duboko učenje.
Vježba 9: Upotreba prethodno treniranih modela za detekciju objekata.
10. Praćenje objekata
Predavanje: Tehnike praćenja objekata u pokretu.
Vježba 10: Implementacija algoritama za praćenje.
11. Sigurnosni sustavi temeljeni na računalnom vidu
Predavanje: Primjena računalnog vida u sigurnosnim sustavima, uključujući nadzorne kamere i prepoznavanje lica.
Vježba 11: Implementacija osnovnog sustava za prepoznavanje lica.
12. Računalni vid u robotici</td></tr>
</table>

	Predavanje: Primjena računalnog vida u robotici i automatizaciji. Vježba 12: Integracija računalnog vida s robotskim sustavima. 13. Računalni vid i umjetna inteligencija za zdravstvo Predavanje: Pregled primjene računalnog vida u medicinskim aplikacijama, uključujući dijagnostiku i robotske operacije. Vježba 13: Analiza medicinskih slika korištenjem tehnika računalnog vida. 14. Napredne teme u računalnom vidu Predavanje: Najnoviji trendovi i tehnologije u računalnom vidu. Vježba 14: Rad s najnovijim alatima i bibliotekama u računalnom vidu. 15. 2. Kolokvij Vježba 15: Priprema za kolokvij kroz rješavanje primjera zadataka.

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 Prisustvo na vježbama i izrada vježbi. Aktivno sudjelovanje u nastavnom procesu Samostalna izrada projekta. 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		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	1			
Kolokviji		Usmeni ispit	2			
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu
Ukupno bodovanje (100%): Ispit ili 2 kolokvija - 80 %, seminar 10% i laboratorijske vježbe 10%: 1. Kolokvij 1 : 40 % (ili ispit) 2. Kolokvij 2 : 40 % (ili ispit) 3. Seminar : 10 % (obavezan) 4. Lab vježbe 10 % (obavezno) Ocjena po postocima: 50% do 62% - dovoljan (2) 63% do 75% - dobar (3) 76% do 88% - vrlo dobar (4) 89% do 100% - izvrstan (5)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Obrada slika i računalni vid, interna skripta.		
	Ramesh Jain, Rangachar Kasturi, Brian G.Schunck, Machine Vision, McGraw-Hill, 1995.		
	Prezentacije s predavanja		

Dopunska literatura
1. Linda G. Shapiro, George C. Stockman, Computer Vision, Prentice Hall, 2001. 2. Wesley E.Snyder, Hairong Qi, Machine Vision, Cambridge University Press, 2004. 3. D.A. Forsyth, J. Ponce, Computer Vision A Modern Approach, Prentice Hall, 2003 4. Foley, Computer Graphics: Principles and Practice (second edition in C), Addison-Wesley Publishing Company, 1996.

Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja
Razgovor sa studentima, Mišljenja studenata o kvaliteti nastave putem anonimnih anketa. Nastavnici koji podučavaju srodne predmete surađuju i zajednički vode brigu o kvaliteti nastave. Uspješnost studenata na kolegiju, Samoanaliza

Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Računalom podržani dizajn proizvoda (CAD)					
Kod	PMT112	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Ivan Peko	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	0%			

Opis kolegija	
Ciljevi kolegija	- Upoznati studente s računalom podržanim dizajnom proizvoda (CAD) s posebnim naglaskom na 3D modeliranje - Razviti vještine za računalom podržani 3D dizajn različitih modela i sklopova u skladu s unaprijed definiranim specifikacijama - Razviti vještine za računalom podržane simulacije temeljem dizajniranih modela i sklopova - Razviti sposobnost primjene računalom podržanog 3D dizajna u stvaranju inovativnih proizvoda u različitim industrijama.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	- Nema
Ishodi učenja	- Pretražiti i analizirati literaturu iz računalom podržanog dizajna (CAD) modela i sklopova - Analizirati funkciju i primjenu računalom podržanog 3D dizajna u suvremenoj industriji, razvoju i optimizaciji proizvoda - Primijeniti CAD u izradi računalnih 3D modela, sklopova i simulacija - Primijeniti CAD u parametarskom 3D modeliranju - Analizirati i validirati geometrijske 3D modele i sklopove - Vrednovati alate i postupke u računalom podržanom dizajnu proizvoda - Povezati 3D računalom podržani dizajn s ostalim naprednim digitalnim tehnologijama: 3D printanje, 3D skeniranje, umjetna inteligencija, strojno učenje...
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvodno o računalom podržanom dizajnu 2. Povijesni razvoj tehnologije 3. Pregled softvera koji se koriste za 3D računalom podržani dizajn proizvoda 4. Faze procesa računalom podržanog 3D dizajna proizvoda 5. Parametarsko 3D modeliranje 6. Izrada 3D sklopova 7. Računalom podržane 3D simulacije 8. 3D modeliranje plohama 9. Optimizacija 3D modela (eng. Generative shape design) 10. Aditivne tehnologije (Tehnologije 3D printanja) 11. Povezivanje 3D dizajna s ostalim naprednim digitalnim tehnologijama: 3D skeniranje, 3D printanje, umjetna inteligencija (AI), Internet Stvari (IoT)... 12. Primjena CAD 3D dizajna proizvoda u automobilskoj industriji, zrakoplovnoj/svemirskoj industriji, industriji strojeva i uređaja, brodogradnji, medicinskoj industriji itd.

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, aktivno sudjelovanje u nastavnom procesu

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	1	Usmeni ispit				
Pismeni ispit		Projekt	2			

<table>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="3">2 kolokvija / ispit
Ocjena = (K1 + K2)/2
(K1: rezultat 1. kolokvija, K2: rezultat 2. kolokvija)
Ocjena po postocima: 50 - 62%: dovoljan (2), 63 - 75%: dobar (3), 76 - 87%: vrlo dobar (4), 88 - 100%: izvrstan (5)</td></tr>
<tr><td rowspan="2">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td>Materijali s predavanja i vježbi</td><td></td><td></td></tr>
<tr><td>Dopunska literatura</td><td colspan="3">1. K. Lee, "Principles of CAD/CAM/CAE Systems", Addison-Wesley, USA 1999.
2. C. McMahon, J. Browne, “CADCAM: principles, practice and manufacturing management”, PrenticeHall, Harlow 1998.
3. S. Dogra, ''Autodesk Fusion 360 – A Power Guide for Beginners and Intermediate Users'', CADArtifex, 2020.
4. R. Shih, ''Parametric Modeling with Autodesk Fusion 360 (Spring 2020 Edition)'', SDC Publications, USA 2020.
5. S. Dogra, ''Autodesk Fusion 360: Introduction to Surface and T-Spline Modeling'', CADArtifex, 2021.
6. A. Gebhardt, JS. Hötter, ''Additive Manufacturing - 3D Printing for Prototyping and Manufacturing'', Hanser Publications, Cincinnati, 2016.
7. B. Redwood, F. Schöffer, B. Garret, ''The 3D Printing Handbook -Technologies, design and applications'', 3D Hubs, Amsterdam, 2017.
8. P. Kyratsis, A. Manavis, J. P. Davim, ''Computational design and digital manufacturing'', Springer, Cham, 2023</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Razgovor sa studentima, studentska evaluacija primjenom anonimne ankete, uspjeh studenata na ispitu, samoprocjena.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

Naziv kolegija	Računarstvo u zajednici					
Kod	PMID56	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Jelena Nakić	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	30	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	25%			

Opis kolegija	
Ciljevi kolegija	Ciljevi kolegija obuhvaćaju upoznavanje studenata s potrebama šire zajednice te primjenu njihovih tehničkih vještina u stvaranju rješenja od značaja za zajednicu i društvo. Kroz projektni rad u suradnji s partnerima iz zajednice, studenti će razviti aplikacije, sustave ili rješenja koja odgovaraju na stvarne potrebe društva.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Studenti trebaju biti spremni analizirati potrebe zajednice i uz pomoć nastavnika pronaći partnera u zajednici (udruge civilnog društva i druge neprofitne organizacije) kojima bi studentska rješenja mogla biti od koristi.
Ishodi učenja	- Razlikovati društveno korisno učenje od volontiranja i studentske prakse - Oblikovati projekt društveno korisnog učenja - Primijeniti svoje znanje u računarstvu za dizajniranje i implementaciju softverskih rješenja koja rješavaju specifične potrebe zajednice - Primijeniti principe etičkog kodiranja i društvene odgovornosti, kao što su privatnost, jednakost i pristup informacijama, uključivanje marginaliziranih skupina, itd. - Unaprijediti vještine timskog rada i suradnje s partnerima iz zajednice razvijajući vještine komunikacije, upravljanja projektima i rješavanja konflikata - Promišljati o utjecaju tehnologije, u kontekstu razvijenih aplikacija, na zajednicu i društvo
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod u društveno korisno učenje (3+0) 2. Etičke smjernice i odgovornosti studenata i zajednice (2+0) 3. Identifikacija potreba zajednice (2+2) 4. Planiranje i dizajn projekata, upravljanje projektima (2+2) 5. Razvoj softverskih rješenja za stvarne probleme (2+18) 6. Testiranje i implementacija rješenja (2+2) 7. Refleksija i evaluacija razvijenog rješenja i njegove održivosti (2+2) 8. Prezentacija rezultata i preporuka za buduće projekte (0+4)
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 - aktivno sudjelovanje u nastavnom procesu - 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	2	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat		Istraživanje	1	
Esej		Seminarski rad		Aktivnost u nastavi	0.5	
Kolokviji		Usmeni ispit				
Pismeni ispit		Projekt	1.5			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	- planiranje i dizajn projekta (20%) - projekt (60%) - završno izvješće i obrana projekta (20%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Mikelić Preradović, Nives. Učenjem do društva znanja: Teorija i praksa društveno korisnog učenja. Zagreb: Zavod za informacijske studije Odsjeka za informacijske i	0	

	komunikacijske znanosti Filozofskog fakulteta Sveučilišta u Zagrebu, 2009		
	Nastavni materijali na web stranici kolegija	0	online
Dopunska literatura	1. Nejmeh, B.A (Ed): Service-Learning in the Computer and Information Sciences: Practical Applications in Engineering Education. Hoboken NJ: Wiley-IEEE Press, 2012. 2. Clanton Harpine, E. (2024). Service Learning in Higher Education: From pedagogy to practice. Springer. 3. Publikacije u znanstvenim časopisima i konferencijama: Service Learning in Computer Science		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	- razgovor sa studentima - studentska evaluacija primjenom anonimne ankete - uspjeh studenata - samoprocjena		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Raspodijeljene i nerelacijske baze podataka					
Kod	PMIH12	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	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	35%			

Opis kolegija	
Ciljevi kolegija	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.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	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.
Ishodi učenja	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.
Sadržaj kolegija detaljno razrađen prema satnici nastave	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 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*						
	Pohađanje nastave	1	Istraživanje		Praktični rad	1
	Eksperimentalni rad		Referat			

ECTS bodova odgovara bodovnoj vrijednosti kolegija)	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)			

Naziv kolegija	Rudarenje podataka					
Kod	PMIH20	Godina studija	1.			
Nositelj/i kolegija	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	0%			

Opis kolegija	
Ciljevi kolegija	Razumijevanje osnovnih koncepata i algoritama za rudarenje podataka. Stjecanje znanja i vještina u procesima rudarenja podataka na (velikim) skupovima podataka.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Primijenjena statistika (poželjno)
Ishodi učenja	1. Upoznavanje metoda za predprocesiranje, pretraživanje i vizualizaciju podataka 2. Upoznavanje algoritamam za klasifikaciju, asocijaciju i grupiranje podataka 3. Razumijevanje osnovnih paradignmi učenja: učenje bez nadzora, učenje potporom i učenje pod nadzorom 4. Razumijevanje problema pretreniranja i prokletstva dimenzionalnosti
Sadržaj kolegija detaljno razrađen prema satnici nastave	Ciljevi i zadatci rudarenja podataka (2) Pripremna obrada podataka (2) Pretraživanje i vizualizacija podataka (2) Utvrđivanje sličnosti među podatcima: korelacija i entropijske mjere (4) Klasifikacija podataka: stabla odluke (2) Alternativne metode klasifikacije podataka: metoda najbližeg susjedstva, Bayesov pristup klasifikaciji, neuronske mreže... (4) Kolokvi (2) Asocijacija podataka (2) Grupiranje podataka: K-najbližih susjedstava, samoorganizirajuće mreže... (4) Različite paradigme i pristupi učenju (2) Tehnike za smanjenje dimenzionalnosti prostora (2)
Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☑ Laboratorij ☐ Mentorski rad
Obveze studenata	Aktivno sudjelovanje u nastavnim aktivnostima. Izrada zadataka kod kuće. 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	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	1			
Kolokviji	1	Usmeni ispit	1			
Pismeni ispit	1	Projekt	1			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (20%) Projekt (40%) Pismeni/usmeni ispit (40%)		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Wu, X. et al.:Top 10 algorithms in data mining. Knowl. Inf. Syst., Vol. 14, No. 1. (2007), pp. 1-37.		
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)			

Naziv kolegija	Sigurnost računalnih učionica					
Kod	PMIC40	Godina studija	1.			
Nositelj/i kolegija	izv. prof. dr. sc. Goran Zaharija	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	30	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija je upoznati studente sa problematikom vezanom uz postavljanje i održavanje računalnih učionica. Studenti bi se trebali kroz niz praktičnih vježbi upoznati sa aktualnim tehnikama i alatima za održavanje i nadzor računalnih učionica.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Uvod u računarstvo
Ishodi učenja	Nakon završetka kolegija studenti bi trebali biti u mogućnosti: 1. Razumjeti probleme sigurnosti računalnih učionice u kontekstu sigurne uporabe računala od strane učenika. 2. Opisati glavne teme, primjenu i područja istraživanja vezana uz sigurnost računalnih učionica, uključujući načine upravljanja korisnicima i pripadajućim pravima, planiranje iprovođenje izrade sigurnostnih kopija, virtualizacije, antivirusnu zaštitu i zaštitu od neovlaštenog pristupa, zaštitu osobnih podataka, probleme sigurnosti pri dijeljenju resursa, zaštitu od neprimjerenih internetskih sadržaja. 3. Primijeniti osnovne za povećanje razine sigurnosti u računalnim učionicama. 4. Raspravljati o ulozi sigurnosti u svakodnevnom životu i društvu koje se oslanja na informacijsko komunikacijsku tehnologiju. 5. Prepoznati granice sposobnosti zaštite trenutnih metoda tehnika i alata s naglaskom na odgovorno korištenje istih.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod u probleme sigurnosti računalnih učionica 2. Virtualizacija i instalacija više operacijskih sustava 3. Profili korisnika i upravljanje korisničkim pravima 4. Postavljanje ograničenja na uporabu pojedinih programa i usluga 5. RAID, princip rada i odabir razine 6. Izrada plana i upravljanje sigurnosnim kopijama 7. Oporavak učionice nakon nepredviđenog događaja 8. Automatizacija procesa pomoću specijaliziranih skripti 9. Antivirusna zaštita 10. Zaštita od neovlaštenog pristupa 11. Nadzor rada korisnika učionice 12. Konfiguriranje i aktualizacija programske podrške računalne učionice 13. Dijeljenje resursa i problem sigurnosti 14. Zaštita osobnih podataka 15. Primjerenost sadržaja na internetu Vježbe prate predavanja u istoj satnici i raspodjeli tema.
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, izrada završnog projekta, ispit.

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	0.5	Praktični rad	1
Eksperimentalni rad		Referat			
Esej		Seminarski rad	3		
Kolokviji		Usmeni ispit			

	Pismeni ispit		Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (10%) Završni ispit (90%)					
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov			Broj primjeraka u knjižnici	Dostupnost putem ostalih medija	
	Security in Computing, 6th Edition by Charles Pfleeger, Shari Lawrence Pfleeger, Lizzie Coles-Kemp Released August 2023 Publisher(s): Addison-Wesley Professional ISBN: 9780137891375					
	Computer Security Fundamentals, 5th Edition by William Chuck Easttom Released February 2023 Publisher(s): Pearson IT Certification ISBN: 9780137984756					
Dopunska literatura	Nastavni materijali dostupni na Internetu, uključujući rješenja odabranih zadataka tedodatna znanstvena literatura.					
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata nakolegiju, samoanaliza.					
Ostalo (prema mišljenju predlagatelja)						

Naziv kolegija	Vizualni programski jezici i okružja					
Kod	PMID38	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Divna Krpan	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	30	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	20%			

Opis kolegija	
Ciljevi kolegija	Upoznati studente s različitim vizualnim programskim okruženjima i njihovom primjenom u podučavanju te istražiti literaturu za odabrano područje. Istražiti metodologije temeljene na istraživanju za prijelaz s vizualnog na tekstualno programiranje. Analizirati ulogu vizualnog programiranja u podučavanju računalnog razmišljanja, simulacija i razvoja aplikacija s primjenom u obrazovanju.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	
Ishodi učenja	- opisati i usporediti različite vizualne programske jezike i okružja - usporediti i vrednovati vizualne programske jezike - izraditi obrazovne aktivnosti koristeći vizualne programske jezike i okružja - izraditi plan primjene vizualnog programskog jezika u nastavi - planirati strategije prijelaza s vizualnog na tekstualno programiranje - pripremiti istraživanje s primjenom vizualnih programskih jezika
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod i usporedba vizualnih programskih okruženja (2+0) 2. Napredni koncepti u vizualnom programiranju (2+0) 3. Posredovani prijenos iz vizualnih jezika u tekstualne i obrnuto (2+0) 4. Primjena vizualnog programiranja u poučavanju i miskoncepcije (2+0) 5. Paradigme programiranja u vizualnim okruženjima (2+0) 6. Simulacije i proširenja okruženja (2+0) 7. Primjeri i analiza postojećih istraživanja u primjenih vizualnih programskih jezika i okružja u obrazovanju (3+0) 8. Izlaganja studentskih seminara (0+15)
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	Dolasci na predavanja. Izrada seminarskog 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	1.5	Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	3			
Kolokviji		Usmeni ispit				
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Praktičan rad i aktivnosti za vrijeme nastave (20%), seminarski rad i izlaganje (70%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	The MagPi Team, Learn to Code with Scratch		
	B. Harvey i J. Monig, SNAP! Reference Manual		online
Dopunska literatura	Marji, Majed. Learn to Program with Scratch: A Visual Introduction to Programming with Games, Art, Science, and Math. No Starch Press, 2014. The Official ScratchJr Book: Help Your Kids Learn to Code Marina Umaschi Bers, Mitchel		

	Resnick Publikacije u časopisima: Journal of Visual Languages and Computing, Computers & Education, ACM Transactions on Computing Education The Computer Science Education Journal Publikacije s konferencija: SIGCSE (Special Interest Group on Computer Science Education) ITiCSE (Innovation and Technology in Computer Science) ISSEP (Informatics in Secondary Schools: Evolution and Perspective) Online materijali i upute.
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)	

Naziv kolegija	Kognitivna psihologija					
Kod	PMS174	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Nikola Marangunić	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija			
Ciljevi kolegija	Razumijevanje temeljnih pojmova psihologije učenja, pamćenja, percepcije i inteligencije. Upoznavanje teorijske i praktične osnove zakonitosti stjecanja znanja i rješavanja problema.		
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.		
Ishodi učenja	Nakon odslušanog i položenog predmeta studenti će moći: 1. Opisati temeljne postavke kognitivne psihologije. 2. Definirati kognitivnu neuroznanost kao osnovu znanstvenog proučavanja ljudske spoznaje. 3. Opisati temeljne spoznajne procese poput pažnje, percepcije, pamćenja i učenja. 4. Navesti različite reprezentacije znanja. 5. Interpretirati načine rješavanja problema kod kreativnih i nadarenih učenika. 6. Opisati faze kognitivnog razvoja. 7. Interpretirati razlike ljudske i umjetne inteligencije.		
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod u kolegij; 2. Uvod u područje kognitivne psihologije; 3. Kognitivna neuroznanost; 4. Pažnja i svijest; 5. Percepcija; 6. Procesi pamćenja; 7. Reprezentacija znanja: predodžbe i propozicije; 8. Reprezentacija i organizacija znanja; 9. Jezik: priroda i usvajanje; 10. Rješavanje problema; 11. Kreativnost; 12. Nadarenost; 13. Odlučivanje i rezoniranje; 14. Kognitivni razvoj; 15. Ljudska i umjetna inteligencija.		
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	Nazočnost na nastavi, aktivnost na nastavi, izrada samostalnih zadataka, rad na projektu, završni projekt.		

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	-		
Dopunska literatura	1. Zarevski, P. (2007). Psihologija pamćenja i učenja. Naklada Slap, Jastrebarsko. 2. Howe, M. J. A. (2002). Psihologija učenja. Naklada Slap, Jastrebarsko. 3. Rathus, S. A. (2001). Temelji psihologije. Naklada Slap, Jastrebarsko		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika.		
Ostalo (prema mišljenju predlagatelja)			

<table>
<tr><td>Naziv kolegija</td><td colspan="3">Nasilje među djecom</td></tr>
<tr><td>Kod</td><td>PMS176</td><td>Godina studija</td><td>1.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Anna Alajbeg</td><td>Bodovna vrijednost (ECTS)</td><td>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><table><tr><td>P</td><td>S</td><td>V</td><td>T</td></tr><tr><td>15</td><td>15</td><td>0</td><td>0</td></tr></table></td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td>0%</td></tr>
<tr><td colspan="4">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="3">Upoznati studente s fenomenom klasičnog i elektroničkog vršnjačkog nasilja. Razumijevanje osnovnih
utjecaja različitih vrsta nasilja na psihosocijalni razvoj djece i posljedice u kasnijoj dobi. Razviti sposobnost odabira adekvatnih metoda u prevenciji i intervenciji u činu vršnjačkog nasilja</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">• Interpretirati i klasificirati znanstveno utvrđene oblike nasilja među djecom
• Osposobljenost za identifikaciju različitih oblika klasičnog i elektroničkog vršnjačkog nasilja
• Prepoznati i objasniti rizične čimbenike na individualnoj i društvenoj razini za pojavu fenomena nasilja među djecom
• Kritički procjenjivati i određivati primjerene metode postupanja na razini primarne prevencije;
• Planirati profesionalno utemeljene postupke u skladu sa zakonskom regulativom.
• Sposobnost ranog uočavanja problema vršnjačkog nasilja
• Razvoj kompetencija za pomaganje djeci koja su sudjelovala u nasilju
• Pripremljenost za suradnju s drugim stručnjacima i obiteljima te službeno postupanje (prijava) u slučajevima nasilja i zlostavljanja</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="3">Nastavni sat predavanja
1. Uvodni sat – upoznavanje s kolegijem
2. Nasilje među djecom - povijesni pregled
3. Sukobi, nasilje i zlostavljanje – terminološko određenje
4. Oblici i obilježja klasičnog vršnjačkog nasilja
5. Oblici i obilježja elektroničkog vršnjačkog nasilja
6. Individualni čimbenici rizika i zaštite u vršnjačkom nasilju
7. Obiteljski čimbenici rizika i zaštite u vršnjačkom nasilju
8. Školski čimbenici rizika i zaštite u vršnjačkom nasilju
9. Uloge djece u klasičnom nasilju među djecom
10. Uloge djece u elektroničkom nasilju među djecom
11. Posljedice klasičnog i elektroničkog vršnjačkog nasilja
12.-13. Zaštita, postupanje i prevencija vršnjačkog nasilja
14. Priprema za kolokvij
15. Kolokvij

Nastavni sat seminara
1. Podjela seminarskih radnji. Upute za pisanje seminarskih radnji
2. Zakonska regulativa i pravna zaštita djece u Republici Hrvatskoj
3. Teorijski modeli nasilnih roditeljskih ponašanja prema djeci
4. Nasilje u mladenačkim vezama
5. Rizični i zaštitni čimbenici za zlostavljanje djece
6. Tjelesno kažnjavanje djece
7. Emocionalno zlostavljanje
8. Seksualno zlostavljanje, posljedice i tretman
9. Razvod roditelja i manipulacija djecom pri razvodu roditelja
10. Mediji i nasilje među djecom</td></tr>
</table>

	11. Karakteristike počinitelja s obzirom na vrstu nasilja 12. UNICEF-ov preventivni program „Stop nasilju među djecom“ 13. UNICEF-ov preventivni program „Stop nasilju među djecom“ – prevencija elektroničkog zlostavljanja 14. Olweusov preventivni program 15. KiVa preventivni program

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

Obveze studenata	Redovito pohađanje i aktivno sudjelovanje u nastavi, seminari (pozitivno ocijenjen napisani seminarski rad i prezentacija), polaganje kolokvija ili 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	0.5		
	Kolokviji	0.5	Usmeni ispit	0.5		
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Završna ocjena iz kolegija Nasilje među djecom određuje se temeljem uspjeha postignutom na kolokviju tijekom predavanja i seminara. Studenti moraju napisati jedan seminarski rad u kojem će obraditi zadanu temu s popisa tema seminarskih radova. Seminar se ocjenjuje ocjenom od 1 do 5. Ocjena iz teorijskog dijela određuje se temeljem uspjeha postignutog na usmenom teorijskom kolokvijiu koji se održava u petnaestom tjednu nastave. Usmeni odgovori studenata ocjenjuje se ocjenom od 1 do 5. Konačna ocjena iz kolegija Nasilje među djecom izračunava se na sljedeći način:(ocjena teorija) + (ocjena seminar) + (redovitost i zalaganje na nastavi).

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Bilić, V. (2018). Nove perspektive, izazovi i pristupi nasilju među vršnjacima. Obrazovni izazovi i Učiteljski fakultet u Zagrebu. Zagreb		
	Bilić, V., Buljan Flander, G., Hrpka, H. (2012). Nasilje nad djecom i među djecom. Jastrebarsko: Naklada Slap		
	Olweus, D. (1993). Nasilje među djecom u školi. Zagreb: Školska knjiga		

Dopunska literatura	Bilić, V. i Zloković, J. (2004). Fenomen maltretiranja djece, Naklada Ljevak, Zagreb. Pregrad, J. i sur. (2007). Priručnik Stop nasilju među djecom, UNICEF Zagreb.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Prisustvovanje nastavi, praktični kolokviji, teorijski kolokvij, studentska evaluacija nastave i nastavnika
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Poučavanje učenika s posebnim potrebama					
Kod	PMS140	Godina studija	1.			
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Osposobljenost za razvoj inkluzivnog kurikula u osnovnoj i srednjoj školi, osposobljenost za pisanje IOOP-a, praćenje, razumijevanje i vrednovanje učenika s posebnim potrebama.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Jezična, računalna i informacijska pismenost.
Ishodi učenja	1.Osposobljenost za timski rad pri pedagoškom dijagnosticiranju posebnih potreba učenika u inkluzivnom okruženju. 2.Osposobljenost za uključenost u izradu i primjenu redovitih programa s primjenom individualiziranih pristupa i prilagodbe sadržaja za nastavne predmete za koje se studenti osposobljavaju. 3.Upoznavanje s tehnikama, metodama i načinima provedbe osobnih kurikuluma. 4.Upoznavanje s vještinama praćenja, vođenja, facilitiranja i medijaciji u interaktivnim metodama rada uz pomoć asistivne tehnologije.. 5.Stjecanje osnovnih informacija o organiziranju i vođenju radionica na nivou razreda i škole u svrhu inkluzije. Razvijanje kritičkog mišljenja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Upoznavanje sa sadržajem predmeta. 2.Terminologija djeca s posebnim potrebama. 3.Učenici s teškoćama u razvoju prema Pravilniku o osnovnoškolskom i srednjoškolskom odgoju i obrazovanju učenika s teškoćama u razvoju. 4.Primjereni programi za učenike s teškoćama u razvoju. 5.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s teškoćama vida i sluha. 6.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s govorno jezičnim poteškoćama. 7.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s poteškoćama čitanja, pisanja i računanja. 8.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s poremećajima u ponašanju. 9.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s motoričkim poteškoćama 10.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s intelektualnim teškoćama 11.Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s poremećajima iz autističnog spektra. 12. Redoviti program uz individualizirani pristup i prilagodbu sadržaja za učenike s ADHD-om 13.Okvir za poticanje i prilagodbu iskustava učenja te vrednovanje postignuća učenika s teškoćama. 14.Prilagodba sadržaja za darovite učenike 15. Okvir za poticanje iskustava učenja i vrednovanje postignuća darovite učenike.
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐			
Obveze studenata	• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi • samostalna priprema i izlaganje seminara					

<table>
<tr><td rowspan="5">Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td>Pohađanje nastave</td><td>0.5</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>0.5</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>1</td><td>Projekt</td><td></td><td></td><td></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="6">Pohađanje nastave – 25 %
Seminar – 25 %
Pismeni ispit –50%</td></tr>
<tr><td rowspan="6">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3">Naslov</td><td>Broj primjeraka u knjižnici</td><td colspan="2">Dostupnost putem ostalih medija</td></tr>
<tr><td colspan="3">Pravilnik o osnovnoškolskom i srednjoškolskom odgoju i obrazovanju učenika s teškoćama u razvoju travanj, 2015. NN.</td><td></td><td colspan="2">web</td></tr>
<tr><td colspan="3">Jensen, E. : Različita djeca različiti učenici, Educa, Zagreb,2004</td><td></td><td colspan="2"></td></tr>
<tr><td colspan="3">Bouillet, D.(2010). Izazovi integriranog odgoja i obrazovanja. Zagreb: Školska knjiga.</td><td></td><td colspan="2"></td></tr>
<tr><td colspan="3">Nacionalni okvirni kurikulum za predškolski odgoj i opće obvezno obrazovanje u osnovnoj i srednjoj školi. R. Hrvatska, Ministarstvo znanosti, studeni 2008</td><td></td><td colspan="2">web</td></tr>
<tr><td colspan="3">Zrilić, S. (2011). Djeca s posebnim potrebama u vrtiću i nižim razredima osnovne škole. Zadar: Sveučilište u Zadru.</td><td></td><td colspan="2"></td></tr>
<tr><td>Dopunska literatura</td><td colspan="6">Remscmidt, K, Autizam, Slap, 2008. (odabrana poglavlja)</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="6">Evaluacijske liste, ispitna postignuća.
Evidencija o nazočnosti na predavanjima i seminarima.
Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika.
Rezultati na kolokvijima i pismenom ispitu.
Zajednička rasprava o načinima unapređenja rada .</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="6"></td></tr>
</table>

Naziv kolegija	Pozitivna psihologija					
Kod	PMS150	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Nikola Marangunić	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	30%			

Opis kolegija	
Ciljevi kolegija	Poznavanje pojmova i spoznaja vezanih za sreću, zadovoljstvo, smisao života te poticanje osobne snage u ostvarivanju toga.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih
Ishodi učenja	Nakon odslušanog i položenog predmeta studenti će moći: 1.Interpretirati položaj pozitivne psihologije kao znanstvene discipline unutar psihologijske znanosti. 2.Opisati temeljne pojmove iz područja poput sreće, dobrobiti, pozitivne motivacije i emocija. 3.Opisati nove psihologijske modele koji stoje u temelju istraživanja ljudske dobrobiti i smisla života. 4.Definirati teorijske pravce istraživanja pozitivnih emocija. 5.Navesti motivacijski ciklus poticanja osobnih snaga u ostvarivanju pozitivnijeg životnog stava. 6.Interpretirati kako odgajati djecu koja će kao odrasli ljudi biti kreativni, hrabri, tolerantni i ljubazni.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Uvod u predmet; 2.Uvod u područje pozitivne psihologije; 3.Što je sreća?; 4.Pozitivna stanja: pozitivne emocije; 5.Pozitivna stanja: subjektivna dobrobit; 6.Sretni i nesretni ljudi/djeca: mišljenje, osobine, motivacija; 7.Pozitivni odnosi 1. dio; 8.Pozitivni odnosi 2. dio; 9.Pozitivna zajednica 1. dio; 10.Pozitivna zajednica 2. dio; 11.Pozitivna zajednica 3. dio; 12.Pozitivna psihologija u praksi: predškolski odgoj; 13.Pozitivna psihologija u praksi: optimistično dijete; 14.Pozitivna psihologija u praksi: pozitivna adolescencija; 15.Budućnost pozitivne psihologije.
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, aktivno sudjelovanje, seminarski rad.					

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	1			
Kolokviji		Usmeni ispit				
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, izrada seminarskih radova.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Brdar, I., Rijavec, M. i Miljković, D. (2008): Pozitivna psihologija, IEP, Zagreb.		
	Seligman, M.E.P. (2005):Optimistično dijete: provjereni program za prevenciju i trajnu zaštitu djece od depresije, IEP, Zagreb.		
Dopunska literatura	Miljković, D. i Rijavec, M. (2004): Tri puta do otoka sreće, IEP, Zagreb		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika.		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Metodika nastave informatike I					
Kod	PMIK50	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	Bodovna vrijednost (ECTS)	6.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	30	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	5%			

Opis kolegija	
Ciljevi kolegija	Teorijski i praktično osposobiti studente za kvalitetnu pripremu, realizaciju i analizu nastavnog procesa
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Obvezno temeljito poznavanje ključnih informatičkih područja (programiranje, strukture podataka i algoritmi, baze podataka, računalne mreže, arhitektura računala..) Poželjno je poznavanje didaktike i psihologije učenja.
Ishodi učenja	Studenti će moći: 1. Razlikovati informatiku kao jedne od temeljnih prirodnih znanosti od drugih srodnih znanstvenih disciplina 2. Shvatiti ulogu nastavnika informatike u skladu s teorijama škole 3. Analizirati kurikulum informatike, planirati nastavu, organizirati znanje za poduku. 4. Realizirati nastavu koristeći najprikladnije modele poučavanja prilagođene sadržaju, vrsti škole, uzrastu i individualnim karakteristikama učenika, te preporuke koje proizlaze iz teorija učenja 5. Motivirati učenike služeći se teorijskim rezultatima, posebno kognitivnih teorija motivacije i teorijom postizanja cilja 6. Prepoznati faktore koji ometaju objektivno ocjenjivanje i ublažiti njihovo djelovanje, sastaviti mjerne instrumente koji ispunjavaju zahtjeve valjanosti, pouzdanosti, objektivnosti
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Osnovni pojmovi: informatika, računarstvo, računarska znanost, informacijska znanost, računalno inženjerstvo, informacijsko-komunikacijske tehnologije, programsko inženjerstvo, informacijski sustavi. (2+0+0) 2. Kurikulum(i) informatike, HNOS, K-12, CS2020. Pismenost, okretnost, potrebna znanja i vještine: koncepti, sposobnost rješavanja problema, vještine primjene IT. Alternativni pristupi izradi kurikuluma. (4+0+0) 3. Biheviorističke i kognitivne teorije učenja. Teorije obrade informacija. (4+0+0) 4. Konstruktivizam u nastavi informatike (2+0+0) 5. Taksonomije učenja u nastavi informatike (2+0+0) 6. Testovi znanja u nastavi informatike. Zadatci objektivnog tipa. Državna matura iz informatike. (2+0+0) 7. Vrednovanje u nastavi informatike. Mjerni instrumenti i karakteristike. Valjanost, pouzdanost, objektivnost, diskriminativna vrijednost zadatka. Konstrukcija testa iz informatike korištenjem Bloomove taksonomije. Vrste pitanja u CSE. (4+0+0) 8. Modeli poučavanja u nastavi informatike: problemska nastava, projektna, šegrtovanje, učenje putem otkrivanja, suradnička, ERR okvir za poučavanje, situacijsko učenje, generička, sinektika. Berginovi obrasci. Poučavanje u računalnom laboratoriju. Stjecanje iskustva u poučavanju informatike. (4+0+0) 9. Računalno razmišljanje: status u kurikulumu, korištenje Logo programskog jezika za računalno razmišljanje, CS Unplugged. Rješavanje problemskih zadataka u Logu (2+20+0) 10. Računalno razmišljanje: vizualno-blokovski programski jezici (2+10+0) 11. Planiranje nastave. Analiza i izrada scenarija učenja (pripreme za sat), sudjelovanje u nastavi u osnovnoj školi (2+0+30)

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. Tri pisane pripreme nastavnih sati s teorijskom analizom. 10 sati sudjelovanja u nastavu u osnovnoj školi, izrada tri pisane pripreme nastavnih sati s teorijskom analizom, te održano ispitno predavanje.		

<table>
<tr><td rowspan="5">Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><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>Nastavna praksa</td><td>1</td></tr>
<tr><td>Esej</td><td></td><td>Seminarski rad</td><td></td><td></td><td></td></tr>
<tr><td>Kolokviji</td><td></td><td>Usmeni ispit</td><td>3</td><td></td><td></td></tr>
<tr><td>Pismeni ispit</td><td></td><td>Projekt</td><td></td><td></td><td></td></tr>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="6">Usmeni ispit (75%) Nastavna praksa (25%)</td></tr>
<tr><td rowspan="3">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3">Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td colspan="3">Mladenović, M., Metodika nastave matematike I - predavanja, 2025.</td><td></td><td>da</td></tr>
<tr><td colspan="3">Hazzan, O., Lapidot, T., Ragonis, N., Guide to teaching computer science: an activity-based approach, Springer, 2011.</td><td>1</td><td>da</td></tr>
<tr><td>Dopunska literatura</td><td colspan="6">Petrina, S., Advanced teaching methods for technology classroom, Information Science Publishing, 2007.
Schubert, S., Schwill, A., Didaktik der informatik, 2011.
Hubvieser, P., Didaktik der Informatik: Grundlagen, Konzepte, Beispiele, 2007.
Instructional strategies online, http://olc.spsd.sk.ca/DE/pd/instr/index.html, 2014.</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="6">1. Studentske ankete.
2.Povratne informacije mentora iz osnovne i srednje škole.
3. Povratne informacije sa stručnih ispita.
4.Samoprocjena</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="6">Seminar - refleksija studenata o održanoj nastavi u osnovnoj školi.</td></tr>
</table>

Naziv kolegija	Pedagogija					
Kod	PMS170	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Anna Alajbeg	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Ovladavanje osnovnim znanjima i vještinama iz područja pedagoške teorije i prakse potrebnih za uspješnu organizaciju pedagoških aktivnosti i vođenje pedagoških procesa.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	Nakon odslušanog i položenog predmeta studenti će moći: 1.razlikovati temeljne pedagoške procese 2.uočiti mogućnosti pedagoškog djelovanja 3.ovladati sadržajima pedagoškog djelovanja i osvještavanje njegovih razina 4.razvijati kompetencije za uspješno planiranje, organiziranje i evaluiranje pedagoških procesa
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Pedagogija kao znanstvena disciplina 2. Pedagogija i ličnost 3.-5. Temeljni pedagoški procesi 6. Vrste i oblici socijalnog učenja 7.-9. Pedagoški razvoj ličnosnti i pedagoško djelovanje 10.-12. Područja pedagoškog djelovanja i njihove kvalitativne razine 13. Metodika pedagoškog djelovanja 14./15. Opće karakteristike obrazovnih sustava i obrazovni sustav RH

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

Obveze studenata	Pohađanje nastave, izrada i prezentacija seminarskog rada, položeni kolokviji ili 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	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	1			
Kolokviji	1	Usmeni ispit				
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, rezultati kolokvija, rezultati ispita (ukoliko mu student pristupi).

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Gudjons, H. (1994.): Pedagogija – temeljna znanja. Educa, Zagreb.		
	Lenzen, D. (2002.): Vodič za studij znanosti o odgoju. Educa, Zagreb.		
	Milat, J. (2005.): Pedagogija – teorija osposobljavanja. Školska knjiga, Zagreb.		

Dopunska literatura	Zaninović, M. (1988.): Opća povijest pedagogije. Školska knjiga, Zagreb. Fulgosi, A. (1987.): Psihologija ličnosti. Školska knjiga, Zagreb. Giesecke, H. (1993.): Uvod u pedagogiju. Educa, Zagreb.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika.

ishoda učenja	
Ostalo (prema mišljenju predlagatelja)	* Sadržaji nastave navedeni su za blok-satove (15termina x 2 sata) ** Sadržaji seminarskih radova odrađuju se u seminarskim grupama (15x1 po grupi

Naziv kolegija	Psihologija odgoja i obrazovanja II					
Kod	PMS116	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Nikola Marangunić	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	30%			

Opis kolegija	
Ciljevi kolegija	Usvojenost temeljnih zakonitosti pamćenja i učenja; prepoznavanje učenika s poteškoćama; prepoznavanje elemenata zlouporabe droga.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Položena Psihologija odgoja i obrazovanja I
Ishodi učenja	Nakon odslušanog i položenog predmeta polaznici će moći: 1.Opisati temeljne zakonitosti ljudske sposobnosti pamćenja 2.Interpretirati teorijske postavke mehanizama učenja 3.Usporediti metode procjenjivanja i ocjenjivanja znanja učenika 4.Prepoznati i interpretirati poteškoće djece u školama 5.Prepoznati različite oblike ovisnosti i njene prevencije
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Uvod u kolegij; 2.Pamćenje: vrste i procesi; 3.Pamćenje: faze i mnemotehnika; 4.Pamćenje: Zaboravljanje: proaktivna i retroaktivna inhibicija; 5.Učenje: oblici; 6.Učenje: činitelji uspješnog učenja; 7.Učenje: uspješnije učenje i pamćenje; 8.Dokimologija: teorija i praksa procjenjivanja znanja; 9.Dokimologija: uloga nastavnika; 10.Dokimologija: vrste ocjenjivanja i strah od ispitivanja; 11.Djeca s poteškoćama u redovitim školama; 12.Kriteriji i vrste poteškoća; 13.Zlouporaba droga: Vrste ovisnosti; 14.Zlouporaba droga: ovisničko ponašanje; 15.Načini prevencije ovisnosti.
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, aktivno sudjelovanje, izrada seminarskog rada, kolokviji (prema izboru).					

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	0.5			
Kolokviji	1	Usmeni ispit	1			
Pismeni ispit	1	Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, rezultati kolokvija (ukoliko mu student pristupi), rezultati ispita.		
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Woolfolk, A. (2016): Edukacijska psihologija, Naklada "Slap", Jastrebarsko.		

	Grgin, T. (2004): Školsko ocjenjivanje znanja, Naklada "Slap", Jastrebarsko.		
Dopunska literatura	Brdar, I., Rijavec, M. (1998): Što učiniti kad dijete dobije lošu ocjenu, IEP, Zagreb. Čudina – Obradović, M. (1990): Nadrenost - razumijevanje, prepoznavanje i razvijanje, Školska knjiga, Zagreb. Gossen, D. C. (1994): Restitucija - preobrazba školske discipline, Alinea, Zagreb. Janković, J. (1996): Zločesti Đaci genijalci, Alinea, Zagreb. Lalić, D., Nazor, M. (1997): Narkomani: smrtopisi, Alinea, Zagreb. Zarevski, P. (2007): Psihologija pamćenja i učenja, Naklada "Slap", Jastrebarsko. Vizek Vidović, V., Rijavec, M., Vlahović - Štetić, V., Miljković, D. (2003): Psihologija obrazovanja, IEP - Vern, Zagreb. Wood, D. (1995): Kako djeca misle i uče, Educa, Zagreb. Howe, M. J. A. (2002): Psihologija učenja. Naklada Slap, Jastrebarsko. Psihologijski rječnik (2005), Prosvjeta, Zagreb.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Raspodijeljeni sustavi					
Kod	PMIC50	Godina studija	1.			
Nositelj/i kolegija	prof. dr. sc. Marko Rosić	Bodovna vrijednost (ECTS)	5.0			
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	Stjecanje temeljnih znanja o raspodijeljenom računarstvu i odgovarajućim sustavima. Vladanje temeljnim načelima primjene, vrednovanja te modeliranja raspodijeljenih sustava.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	1. Nabrojati karakteristike, prednosti i nedostatke raspodijeljenih sustava 2. Razumjeti specifičnosti programske podrške raspodijeljenih sustava 3. Razumjeti algoritme komunikacije u raspodijeljenim sustavima 4. Razumjeti logičke, vektorske i matrične satove 5. Nabrojati i razumjeti načine zajedničkog korištenja dijeljenih resursa i algoritme međusobnog isključivanja u raspodijeljenim sustavima. 6. Opisati model partnerskog umrežavanja
Sadržaj kolegija detaljno razrađen prema satnici nastave	Predavanja: Uvod u raspodijeljene sustave (2h) , definicija raspodijeljenih sustava, prednosti i nedostatci raspodijeljenih sustava (2h), karakteristike raspodijeljenih sustava (2h), dijeljenje resursa (2h), sklopovske postavke raspodijeljenih sustava (3h), operacijski sustavi raspodijeljenih sustava (3h), posrednički vezni programi (middleware) (2h), komunikacije u rapodijeljenim sustavima (4h), logički, vektorski i matrični satovi (4h), međusobna isključivanja (2h), klijent poslužitelj model (2h), mreže partnerskog umrežavanja (2h). Vježbe prate područje predavanja u istoj satnici.

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

Obveze studenata	Pohađanje predavanja i vježbi prema pravilniku o studiranju. Izrada zadanih seminarskih radova.

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	2		
	Kolokviji		Usmeni ispit			
	Pismeni ispit	2	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvovanje na nastavi i rješavanje zadataka (20%), Seminarski rad (40%), Ispit (40%).

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	M. Van Steen, A. Tannebaum, Distributed Systems: Principles and Paradigms, Prentice Hall		

Dopunska literatura	R. Orfali, D. Harkley, J. Edwards: The Essential Distributed Object Survival Guide, John Wiley
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Stručno-pedagoška praksa					
Kod	PMS006	Godina studija	1.			
Nositelj/i kolegija	doc. dr. sc. Anna Alajbeg	Bodovna vrijednost (ECTS)	1.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Ovladavanje osnovnim znanjima i vještinama iz područja pedagoške teorije i prakse potrebnih za uspješnu organizaciju pedagoških aktivnosti i vođenje pedagoških procesa.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušana i položena Didaktika.
Ishodi učenja	Student se upoznaje sa školom kao živim organizmom te uočava njenu strukturu, organizaciju i dinamiku. Nadalje, student se upoznaje i s drugim djelatnostima škole kao društvene ustanove te s poslovima i zadacima različitih profila i profesija zaposlenika škole koji omogućavaju neometan rad škole, a za koje u okviru studijskog programa nije bio u mogućnosti steći saznanja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Škola kao odgojno-obrazovna ustanova 2. ustrojstvo škole, način rada i upravlja-nja (organi i tijela) 3. izvedbeni programi (škole, stručnih službi ...) 4. zaposlenici (vrste, broj i zaduženja) i stručne službe i aktivi (djelokrug djelovanja i način rada) 5. pedagoška, razredna i učenička dokumentacija 6. organizacija, prostori i oprema 7. vanjska suradnja 8. ostalo (specifičnosti) 9. raspored sati 10.priprave s hospitacija po struci.

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

Obveze studenata	Hospitirati dva radna dana u školi te se upoznati sa svim aspektima škole kao odgojno-obrazovne ustanove; odslušati dvije hospitacije iz predmeta studiranja; podnijeti pismeni izvještaj o hospitiranju.

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Kvaliteta obrasca izvještaja i primjedaba na uočeno stanje u školi.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Obrazac izvještaja dostupan na Moodleu.		

Dopunska literatura	
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika

Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="4">Arhitekture neuronskih mreža</td></tr>
<tr><td>Kod</td><td>PMII15</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>izv. prof. 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>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="3">0%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">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="4">-</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">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="4">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)

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)</td></tr>
</table>

	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)	

Naziv kolegija	Informatička praksa					
Kod	PMIK80	Godina studija	2.			
Nositelj/i kolegija		Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	0	176	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Priprema studenata za tržište rada. Usmjeravanje razvoja studenata u skladu sa potrebama tržišta. Unapređenje vještine primjene stečenog znanja pri rješavanju konkretnih zadataka. Razvijanje samostalnosti i kreativnog traganja za rješenjem postavljenih zadataka.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Sukladno članku 4. stavku 6. Pravilnika o stručnoj praksi na Sveučilištu u Splitu, ako je broj raspoloživih mjesta za obavljanje stručne prakse koji je Fakultet ugovorio s prihvatnim organizacijama, odnosno nastavnim bazama, provodi se selekcijski postupak određen člankom 5. Pravilnika.
Ishodi učenja	Studenti će moći: upotrijebiti znanje koje posjeduje pri rješavanju konkretnih zadataka procijeniti resurse potrebne za izvršenje zadatka približno procijeniti vrijeme potrebno za izvršenje zadatka samostalno „uz pomoć alata za pretraživanje“ riješiti zadatak surađivati sa zaposlenicima prihvatne organizacije
Sadržaj kolegija detaljno razrađen prema satnici nastave	Stručna informatička praksa obavlja se u prihvatnoj organizaciji odnosno nastavnoj bazi u trajanju od 22 radna dana po 8 sati dnevno po rasporedu koji se dogovara s mentorom iz prihvatne organizacije. Može započeti najranije 1. veljače, a završiti najkasnije do kraja akademske godine. Predviđa se upoznavanje studenta s djelatnošću prihvatne organizacije kao i situacija na tržištu na kojem organizacija djeluje. Izbor zadatka li više njih, kao i detaljan plan studentove aktivnosti određuje se u suradnji s mentorom iz prihvatne organizacije.
Vrste izvođenja nastave	☐ Predavanja ☐ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☑ Mentorski rad
Obveze studenata	Obavljanje informatičke stručne prakse prema rasporedu utvrđenom s mentorom iz prihvatne organizacije. Izrada Izvještaja o obavljenoj praksi te njegova odbrana pred mentorom kojeg je imenovao Fakultet.

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija*)						
Pohađanje nastave		Istraživanje		Praktični rad	4.9	
Eksperimentalni rad		Referat	0.5			
Esej		Seminarski rad				
Kolokviji		Usmeni ispit	0.5			
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Mentor iz prihvatne organizacije ocjenjuje studenta opisnom ocjenom: Student je uspješno obavio stručnu praksu Student nije uspješno obavio stručnu praksu. Potonja se opisna ocjena dodatno obrazlaže u pisanom obliku. Kada je mentor iz prihvatne organizacije studentovo obavljanje stručne prakse ocijenio uspješnim, mentor kojeg je imenovao Fakultet analizira Izvještaj o obavljenoj stručnoj praksi, raspravlja o radnim zadatcima sa studentom i temeljem toga dodjeljuje studentu jednu od sljedeće dvije opisne ocjene: Student je uspješno izradio i obranio Izvještaj o stručnoj praksi Student nije uspješno izradio i obranio Izvještaj o stručnoj praksi. Ocjenu „Student nije uspješno izradio i obranio Izvještaj o stručnoj praksi“ obrazlaže se u

<table>
<tr><td></td><td colspan="3">pisanoj formi.
Kada su ocjene oba mentora pozitivne u indeks se upisuje ocjena „Položeno“. U slučaju negativne ocjene stručne prakse, student nema pravo ponovo upisati stručnu praksu slijedeće akademske godine.</td></tr>
<tr><td rowspan="2">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td>Naslov</td><td>Broj primjeraka u knjižnici</td><td>Dostupnost putem ostalih medija</td></tr>
<tr><td colspan="3">-</td></tr>
<tr><td>Dopunska literatura</td><td colspan="3"></td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="3">Po obavljenoj praksi studenti ispunjavaju anketu o zadovoljstvu stručnom praksom koja je propisana Pravilnikom o stručnoj praksi na Sveučilištu u Splitu. Anketni upitnik sadrži tri izjave o tome smatra li student da je obavljanjem prakse unaprijedio svoje praktične vještine te jesu li zadaci bili primjerene težine i adekvatno objašnjeni. Student ocjenjuje svoje slaganje s iznijetim tvrdnjama na 5-stupanjskoj Likertovoj ljestvici. Pored toga, student može iznijeti primjedbe i sugestije usmjerene prema unapređenju stručne prakse.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="3"></td></tr>
</table>

Naziv kolegija	Inteligentni agenti					
Kod	PMII30	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Lada Maleš	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija je upoznati studente sa osnovnim konceptima vezanim uz pojam agenta i inteligentnog agenta. Dati će se pregled različitih agentskih arhitektura i njihove primjene. Predstaviti će se nekoliko različitih metodologija razvoja agentski temeljenih sustava. Studenti će u sklopu kolegija kroz izradu projekta sudjelovati u razvoju jednostavne agentski temeljene aplikacije koristeći prikladne porgramske jezike i alate.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Poznavanje osnova programiranja.
Ishodi učenja	Nakon završetka koleija, studenti bi trebali biti u mogućnosti: 1. Definirati pojam inteligentnog agenta i glavne karakteristike. 2. Opisati različite agentske arhitekture. 3. Koristiti agentski temeljene sustave za rješavanje problema. 4. Definirati pojam višeagentskog sustava. 5. Navesti različite vrste interakcija između agenata.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Uvod u inteligentne agente (2h). 2. Agentske arhitekture (2h). 3. Hibridne agentske aritekture (2h) 4. Višeagentski sustavi (2h) 5. Kooperacija i koordinacija agenata (2h) 6. Komunikacija, jezici i protokoli (2h) 7. Odabir teme projekta (2h). 8. Simulacije agentskih sustava (2h). 9. Interakcije u višeagentskim sustavima (2h) 10. Strategije pregovora, aukcija (2h). 11. Upravljanje ograničenim resursima (2h) 12. Formiranje koalicija (2h) 13. Agentske metodologije razvoja (2h) 14. Primjeri primjene agentskih sustava (2h) 15. Projekt - završna verzija (2h). Vježbe prate predavanja u istoj satnici i raspodjeli tema
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, izrada završnog projekta, 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	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	1			
Kolokviji		Usmeni ispit	2			
Pismeni ispit	1	Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (20%) Projekt (40%) Usmeni ispit (40%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Wooldridge, M (2001). An Introduction to Multiagent System. Wiley, NY.		
Dopunska literatura	Nastavni materijali dostupni na Internetu, uključujući rješenja odabranih zadataka te dodatna znanstvena 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)			

Naziv kolegija	Obrada prirodnog jezika					
Kod	PMII45	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Branko Žitko	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	0%			

Opis kolegija	
Ciljevi kolegija	➢ 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
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Ulazne kompetencije: linearna algebra i vjerojatnost
Ishodi učenja	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
Sadržaj kolegija detaljno razrađen prema satnici nastave	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
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐
Obveze studenata	Pohađajte predavanja 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	2	Istraživanje		Praktični rad		
Eksperimentalni rad		Referat				
Esej		Seminarski rad	3			
Kolokviji		Usmeni ispit				
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Studenti moraju imati prolaznu ocjenu iz sva tri gore navedena aspekta ocjenjivanja

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	D. Jurafsky, J. H. Martin, (2000) Speech and Language Processing, Prentice Hall	1	
	Roger Nkambou, R. Mizoguchi J. Bourdeau (Eds.) (2010) Advances in Intelligent Tutoring Systems, Springer	1	
Dopunska literatura	Roger Nkambou, R. Mizoguchi J. Bourdeau (Eds.) (2010) Advances in Intelligent Tutoring Systems, Springer		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovor sa studentima, samoprocjena		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Poslovna analitika					
Kod	PMIH28	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Marko Rosić	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	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 .
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	-
Ishodi učenja	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
Sadržaj kolegija detaljno razrađen prema satnici nastave	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) 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)						

Naziv kolegija	Programiranje mobilnih aplikacija					
Kod	PMID35	Godina studija	2.			
Nositelj/i kolegija	izv. prof. dr. sc. Goran Zaharija	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	25%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija je prikazati studentima osnovne koncepte vezane uz dizajniranje i razvoj mobilnih aplikacija. Opisati će se nekoliko različitih okruženja i razvojnih platformi za mobilne aplikacije. Studenti će u sklopu kolegija kroz izradu projekta sudjelovati u razvoju jednostavne mobilne aplikacije koristeći prikladne programske jezike i alate.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Poznavanje osnova programiranja, sa naglaskom na OOP paradigmu. Položen kolegij Objektno orijentirano programiranje. Položen kolegij Programiranje mrežnih aplikacija. Odslušan kolegij Okviri i alati za razvoj web aplikacija.
Ishodi učenja	Objasniti razliku između razvoja klasičnih i mobilnih aplikacija. Opisati osnovnu strukturu mobilne aplikacije. Prepoznati glavne izazove razvoja mobilnih aplikacija – različite veličine ekrana, ograničena memorija i procesorska snaga – te kako ih riješiti. Osmisliti i realizirati vlastitu mobilnu aplikaciju Objasniti kompletni proces razvoja mobilne aplikacije – podešavanje, razvoj, testiranje i distribuciju
Sadržaj kolegija detaljno razrađen prema satnici nastave	Osnove razvoja mobilnih aplikacija. Pregled trenutnih mobilnih platformi (iOS, Android, Mobile 8). Razvoj Cross-platform mobilnih aplikacija. Uvod u razvojno okruženje. Izrada jednostavne mobilne aplikacije. Dizajn korisničkog sučelja. Životni ciklus dijelova aplikacije. Upravljanje podacima u mobilnim aplikacijama. Dohvaćanje resursa i prava pristupa unutar uređaja. Upravljanje događajima (ekran na dodir, geste, okretanje uređaja). Upravljanje događajima (ekran na dodir, geste, okretanje uređaja). Odabir teme projekta. Rad na projektu. Projekt - završna verzija.
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, aktivno sudjelovanje u nastavnom procesu, praktični ispit na računalu, 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	Istraživanje		Praktični rad	1
Eksperimentalni rad		Referat		Domaće zadaće	0.5
Esej		Seminarski rad			
Kolokviji		Usmeni ispit	1		
Pismeni ispit	0.5	Projekt	1		

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (10%) Projekt (45%) Usmeni ispit (45%)

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

	Lee, Schneider, and Schell, Mobile Applications: Architecture, Design, and Development, Prentice Hall, 2004.		
	Brian Fling, Mobile Design and Development, O'Reilly Media, 2009		
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)			

Naziv kolegija	Strojno učenje u bioinformatici i medicini					
Kod	PMIH22	Godina studija	2.			
Nositelj/i kolegija	Dino Nejašmić, pred.	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	20%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija je upoznati studente s mogućim primjenama metoda strojnog učenja u bioinformatici i medicini.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Poznavanje metoda strojnog učenja.
Ishodi učenja	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.
Sadržaj kolegija detaljno razrađen prema satnici nastave	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.
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, aktivno sudjelovanje u nastavnom procesu, ispiti.

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	1.5			
Kolokviji		Usmeni ispit	2			
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Seminarski rad (50%), Usmeni ispit (50%).

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

	Cleophas T, Zwinderman A. Machine Learning in Medicine – a Complete Overview. Springer International Publishing. 2015		
	https://www.udemy.com/course/applied-machine-learning-for-healthcare/		
	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).		
Dopunska literatura	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).		
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)			

Naziv kolegija	Tehnologije sustava E-učenja					
Kod	PMIK20	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Marko Rosić	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	0%			

Opis kolegija	
Ciljevi kolegija	Osigurati temeljna znanja i vještine potrebne za korištenje i vrednovanje tehnologija za e-učenje te razvoj sustava e-učenja
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih
Ishodi učenja	1. Nabrojati tehnologije e-učenja koje su se koristile u ranijim fazama razvoja e-učenja 2. Nabrojati tehnologije e-učenja današnjice 3. Nabrojati trendove razvoja tehnologija e-učenja 4. Vrednovati ponuđene tehnologije kroz parametre zasnivanja sustava e-učenja 5. Izraditi plan zasnivanja sustava e-učenja nad odabranom tehnologijom.
Sadržaj kolegija detaljno razrađen prema satnici nastave	Predavanja: Uvodna razmatranja (2), povijesni prikaz tehnologija e-učenja (2), usluge sustava e-učenja (3), sustavi e-učenja zasnovani na informacijskom prostoru Web-a (4), raspodijeljenim tehnologijama (2), semantičkom Web-u (3), inteligentnim agentima (3), mrežama društvenog umrežavanja (4), mrežama partnerskog umrežavanja (2). Mobilni sustavi (3) te sustavi zasnovani na lokacijskim uslugama (2). Vježbe tematski te po satnici prate predavanja.
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 prema pravilniku o studiranju. Izrada seminarskog rada/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		
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	Pohađanje nastave (10%), Seminarski rad/projekt (40%), Ispit (50%)

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

Dopunska literatura	Predavanja dostupna preko sustava Moodle
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovori sa studentima, anonimna studentska anketa, uspjeh na ispitu, samoevaluacija.

Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="4">Uvod u geoinformacijske sustave</td></tr>
<tr><td>Kod</td><td>PMIH15</td><td>Godina studija</td><td colspan="2">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>prof. dr. sc. Vlado Dadić</td><td>Bodovna vrijednost (ECTS)</td><td colspan="2">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 S V T</td></tr>
<tr><td>30 0 30 0</td></tr>
<tr><td>Status kolegija</td><td>Izborni</td><td>Postotak primjene e-učenja</td><td colspan="2">0%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">Stjecanje osnovnih znanja o geografskim informacijskim sustavima (GIS), njihovoj primjeni u rukovanju geoprostornim podatcima i tematskim slojevima, uključujući prikupljanje, provjeru kvalitete, pohranu, obradu, analizu i prikaz rezultata u izdvojenom i mrežnom okolišu</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="4">Poznavanje HTML-a i rada u mrežnom okolišu i opće poznavanje relacijskih i objektnih baza podataka</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">• Upoznavanje s GIS systems i njihovim posebitostima

• Upoznavanje geoprostornih modela korištenih u GIS-u

• Upoznavanje s geoidom Zemljom i načinima njenog prikaza u dvodimenzionalnom prostoru (X,Y ravnini)

• Upoznavanje s korištenim datumima i projekcijama (lokalni i globalni datumi)

• Upoznavanje s metodama i tehnikama prikupljanja geoprostornih i pripadajućih atributnih podataka (primarni i sekundarni)

• Upoznavanje s metodama generiranja prostornih slojeva iz mjerenja u ograničenom broju geoprostornih točaka

• Osposobljenost rada na nekoliko samostalnih i mrežnih GIS alata

• Izrada GIS projekata s naglaskom na preklapanje tematskih GIS slojeva i upotreba Booleove algebre i drugih metoda u geoprostornoj analizi

• Rješavanje praktičnih zadataka vezanih za analitiku geoprostornih podataka u cilju izrade podloge za donošenje optimalnih odluka u upravljanju prostorom</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="4">Predavanja:

• Osnovni pojmovi u GIS-u. Područja primjene GIS-a. Sastavnice GIS-a. Razvoj GIS-a. GIS i okružje (samostalni, mrežni, bežični) (2).

• Modeli podataka u GIS-u. Točka, linija i površina kao osnovni modeli. . Objektno-relacijski modeli podataka. Preklapanje različitih tematskih slojeva preko Boolovih operanda kao osnova analize geoprostornih podataka (2)

• Digitalizacija i rekonstrukcija stvarnog svijeta i prikaz u GIS-u. Prikupljanje prostornih i atributnih podataka i njihova integracija u GIS-u. Optimizacija troškova prikupljanja podataka korištenjem postojećih s obzirom na kakvoću i konkretne potrebe. (2).

• „Gap“ analiza i minimalni broj prostornih ulaznih podataka za izradu prostornih polja. Generiranje prostornih polja iz podataka mjerenih u statistički slučajno raspoređenim pozicijama – izrada tematskih slojeva.(2)

• Kriging (BLUE) metoda lokalne objektivne analize. Varijanca i kovarijanca u procjeni međuzavisnosti prostorno raspoređenih podataka. Ostale najčešće upotrjebljavanje</td></tr>
</table>

metode objektivne analize u GIS-u (standardne, fuzzy, neuronske mreže).(2)

• GIS sustav u samostalnom okruženju, lokalnom mrežnom okruženju, web okolišu i bežičnom okruženju. Posebitosti računalne i programske opreme u GIS-u. Programski alati za rukovanje prostornim podatcima. (2)

• Metode za prikupljanje i unos podataka u GIS baze. Primarne i sekundarne metode prikupljanja podataka. Posebitost (prednosti i nedostatci) postojećih tematskih slojeva. Procjena njihove upotrebljivosti s obzirom na aktualno stanje. Tehnike izmjera. Geodetska izmjera. Mjerne tehnike i sustavi za daljinsko prikupljanje podataka (2).

• Geoprostorno pozicioniranje. Kartografska podloga. Mjerila. Kategorije mjerila. Mjerilo u GIS-u. Prostorni georeferentni sustavi.(2)

• Zemlja kao geoid. Model Zemlje: Elipsoid. Referentni elipsoid - globalni datum. Lokalni elipsoidi i lokalni datumi. Uzimanje u obzir spljoštenosti Zemlje kod datuma. Poboljšanje datuma u 19. i 20. stoljeću kao rezultat povećanja točnosti mjerenja. (2)

• Vrste projekcija Zemlje u dvodimenzionalni prostor – x,y ravninu. Cilindrične, azimutalne i konusne projekcije. Konformne, ekvivalentne i ekvidistantne projekcije i njihove osobine. Izobličenja kod projekcija. (2)

• Datumi i projekcije u Hrvatskoj kroz povijest. Hrvatska u dvije zone (5. i 6.). Hrvatska kao jedna zona (zakonska obveza korištenje u službene svrhe od 1.1. 2010). Datum GRS80 i projekcija HTR96. Centralni meridijan 16.5 stupnjeva. (2)

• Pretvaranje GIS slojeva izrađenih u prethodnim službenim datumima i projekcijama s novima. Pogrješke kod transformacije. Programski paketi specijalizirani za potrebe GIS-a. Licencirani (ArcInfo/ArcView, ArcGIS, AutoCAD Map, CARIS), slobodni QGIS I GRASS (2)

• Mrežni GIS. Osnovni standardi. Otvoreni GIS (Open GIS). Senzor GML. Marine GML. Pokretni GIS (Mobile GIS). (2)

• Načela izrade GIS projekta. Organizacijske i tehnološke promjene. Očekivana korist. Potrebni računalni i ljudski resursi. Analiza troškova i koristi. Višekriterijalna analiza u vrjednovanju geoprostora. (2)

• INSPIRE - Europska infrastruktura prostornih informacija, arhitektura, standardi, primjena, analiza utjecaja, zaštita podataka. (2)

Vježbe:

• Digitalizacija i rekonstrukcija stvarnog svijeta i prikaz u GIS-u. Prikupljanje prostornih i atributnih podataka i njihova integracija u GIS-u. Optimizacija troškova prikupljanja podataka korištenjem postojećih s obzirom na kakvoću i konkretne potrebe. Problematika pretvaranja mjerenih podataka u prostorne slojeve (2).

• Određivanje potrebnog broja i raspodjele prostornih ulaznih podataka. Generiranje prostornih polja iz podataka mjerenih u statistički slučajno raspoređenim pozicijama – izrada tematskih slojeva.

• Vježbanje s praktičnim primjerima u generiranju i analizi prostornih polja programskim alatom Surfer 8 (2D prostor, prostor vrijeme...; ribarstvo, ekologija) (2)

• Digitalizacija i skeniranje postojećih grafičkih prikaza – karata, grafova, crteža. Primjeri iz katastra. Prednosti i nedostaci. Formati i konverzija podataka. Razmjena geoprostornih podataka i standardi.

• Daljinsko istraživanje. Fotogrametrija. Aero-foto. Pasivni i aktivni daljinski senzori. Multispekrtri i hiperspektri u funkciji prepoznavanja tematskih slojeva. Radarski senzori. Odziv zemaljske podloge na različiti frekventni spektar. (2)

	• Provjera homogenosti i izotropnosti polja. Problematika različitih skala po x i y osi. Praktično rješavanje problema neizotropnosti. Generiranje izlaznih polja. Korišteni formati kod GIS prikaza i njihova kompatibilnost. „shp“ format kao standardni format za razmjenu u GIS-u. (2) • Provjera različitih metoda generiranja prostornih polja iz podataka statistički slučajno raspoređenih u prostoru. Pojava „volovskih očiju“ u prostornom polju i njihovo smanjivanje. (2) • Osnove rada s prijenosnim programskima alatom Q-GIS. Konverzija datuma i projekcija. Dodatni alati za posebne namjene. (4) • Kreiranje slojeva i dodavanje atributnih tablica u ArcView programu. Dodavanje podataka za diskretne mjerne postaje i pretvaranje u „shp“ formate. Izrada linijskih i poligonskih struktura. Ažuriranje postojećih slojeva.(3) • Upotreba Boolove algebre u obradi tematskih slojeva u ArcView programu. Preklapanje slojeva. Utjecaj projekcije na rezultate rukovanja slojevima. (2) • Pretvaranje i ujednačavanje slojeva generiranim u različitim datumima i projekcijama. GRS 80 i WGS 84. Pogrješke kod digitalizacije i njihovo otklanjanje. Generalizacija i „streaming“ u funkciji povećanja učinkovitosti GIS –a.(2) • Izrada mrežnih stranica s GIS sastavnicama. WMS i WFS servisi u mrežnom okolišu i usklađenost slojeva s INSPIRE direktivom. Povezivanje GIS poslužitelja s bazama podataka. Prilagodba GIS mrežnih aplikacija mobilnim uređajima. GIS u oblaku. (3) • Upotreba GIS-a alata u mrežnom okolišu u svrhu učinkovitijeg upravljanja hrvatskim priobalnim područjem. Primjer iz ribarstvenih zakonskih propisa, namjene korištenja prostora, određivanje boniteta područja, prikaz Nature 2000 i pokrov zemljišta u Hrvatskoj. (2)

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

Obveze studenata	Prisustvovanje predavanjima i vježbama, izrada seminarskog rada i polaganje kolokvija i završnog ispita					
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	1		
	Kolokviji		Usmeni ispit	2.5		
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Vrjednovanje rada studenata se obavlja kroz evidentiranje redovitog prisustvovanja i aktivnog sudjelovanja u nastavi, redovitog prisustvovanja i uspješnoj izradi postavljenih zadataka tijekom vježbi na računalu, ocjeni izrađenog seminarskog rada iz područja GIS-a, kroz polaganje do dva kolokvija tijekom semestra, te uspješnost u rješavanju zadatka na pismenom i općeg poznavanja predmetne tematike na usmenom dijelu ispita

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	George B. Korte, 2001. The GIS book, 5th edition. Onword press-Thompson learning, 387 pp.		
	George B. Korte, 2001. The GIS book, 5th edition. Onword press-Thompson learning, 387 pp.		

	David E. Davis, 2003. GIS for everyone with CD room, 33rd edition. ESRI, 164pp.		
	Dawn J. Wright, ed.,2015. Ocean solutions – Earth solutions. ESRI Press, 366pp.		
Dopunska literatura	Deutch C.V. and A.G. Journel, 1998. GSLIB – Geostatistical software; library and user's guide. Oxford University Press. 369 pp. Vasilis D. Valavanis, 2002. Geographic information systems in oceanography and fisheries. Taylor and Francis Press, 209 pp. Clayton V. Deutch and Andre G. Journel,, GISLIB-Geostaatistcal software ,library and users guide. Oxford university press, 369 pp. Gary Amdabl, 2001. GIS for public safety. ESRI Press, 108pp. http://www.esri.com/mapmuseum http://www.qgistutorials.com/en/ http://www.kartografija.hr/old_hkd/ http://www.dgu.hr/ Http://jadran.izor.hr/geo/msfd_mon.htm		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evidencija sudjelovanja i aktivnom sudjelovanju u nastavi, vježbama i seminarima Ocjenjivanje seminarskog rada iz područja GIS-a Ocjenjivanje rješavanja praktičnih problema iz GIS-a preko kolokvija Ocjenjivanje izrađenog pismenog dijela ispita s praktičnim radom u GIS alatu Ocjenjivanje usmenog dijela ispita		
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>izv. prof. 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>Izborni</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

Fokus podataka i kontekst.</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">Prisustvo na predavanjima i vježbama, aktivno sudjelovanje na nastavnim aktivnostima, izrada domaćih radova, ispit.</td></tr>
<tr><td rowspan="5">Praćenje rada studenata (upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj ECTS bodova odgovara bodovnoj vrijednosti kolegija)</td><td>Pohađanje nastave</td><td>2</td><td>Istraživanje</td><td></td><td>Praktični rad</td><td>2</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>1</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>
<tr><td>Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu</td><td colspan="6">Prisustvo/sudjelovanje na nastavi (10%)

Praktični rad (30%)

Pismeni/usmeni ispit (60%)</td></tr>
<tr><td rowspan="4">Obvezna literatura (dostupna u knjižnici i putem ostalih medija)</td><td colspan="3">Naslov</td><td>Broj primjeraka u knjižnici</td><td colspan="2">Dostupnost putem ostalih medija</td></tr>
<tr><td colspan="3">Visualization Analysis & Design, Tamara Munzner (2014). (ISBN 9781466508910)</td><td></td><td colspan="2"></td></tr>
<tr><td colspan="3">Alberto Cairo, The Truthful Art: Data, Charts, and Maps for Communication (Berkeley, California: New Riders, 2016).</td><td></td><td colspan="2"></td></tr>
<tr><td colspan="3">Stephanie D. H. Evergreen, Effective Data Visualization: The Right Chart for the Right Data (Thousand Oaks, CA: Sage, 2017).</td><td></td><td colspan="2"></td></tr>
<tr><td>Dopunska literatura</td><td colspan="6">Nastavni materijali dostupni na Internetu, uključujući rješenja odabranih zadataka te dodatna znanstvena literatura</td></tr>
<tr><td>Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja</td><td colspan="6">Razgovor sa studentima, anonimna studentska anketa, uspješnost studenata na kolegiju, samoanaliza.</td></tr>
<tr><td>Ostalo (prema mišljenju predlagatelja)</td><td colspan="6"></td></tr>
</table>

Naziv kolegija	Metodički informatički seminar s nastavnom praksom I					
Kod	PMIK51	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	15	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Osposobiti studente za kvalitetnu pripremu, izvođenje i analizu svih vrsta nastave informatike, ovladavanje raznovrsnim repertoarom metoda poučavanja, adekvatnu uporabu medija te pripremu učenika za informatička natjecanja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušana Metodika nastave informatike I. Za ispitni sat preduvjet je položen MNI1. Poznavanje didaktičkih teorija, metoda poučavanja i osnova informatike
Ishodi učenja	Studenti će: 1. izraditi godišnji plan na nastavni predmet Informatika te ga razraditi za nastavne cjeline i teme 2.. ovladati raznovrsnim repertoarom modela poučavanja i argumentirano izvršiti izbor najprikladnijeg u datim okolnostima 3. adekvatno koristiti medije 4. napraviti pripremu nastavnog sata temeljenu na vlastitom iskustvu i rezultatima znanstvenih istraživanja vezanih za realizaciju te teme u nastavi, s naglaskom na teškoće učenika i miskoncepcije 5. steći praktične vještine u formativnom i sumativnom vrednovanju (usmeno, pisano, praktično, projekti, portfolio)
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Priprema za nastavu – opći model izveden iz didaktičkih teorija i modela poučavanja te preporuka vodećih teorija učenja. Prema tom modelu izrađuju se pripreme za ključne teme poput proceduralnog programiranja, objektnog programiranja, struktura podataka, baza podataka, operacijskih sustava, programskih paketa za obradu teksta, tablična računanja, izradu web stranica i sl. (0+0+22) 2. Zadaci s informatičkih natjecanja za učenike OŠ (Infokup, HSIN..). Kornjačina grafika (LOGO ili Python), procedure, rekurzivni programi i praćenje njihova izvršavanja. (0+15+8)

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

Obveze studenata
1. ispit - zadaci s informatičkih natjecanja učenika osnovne škole 2. 12 sati sudjelovanja u nastavi OŠ, 3 pisane pripreme, 1 probni i 1 ispitni sat 3. redovito tjedno rješavanje zadataka s informatičkih natjecanja za učenike OŠ. 4. Esej o održanoj nastavnoj praksi u OŠ

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		Domaće zadaće	1.4	
Esej	0.2	Seminarski rad		Ispitna predavanja	0.4	
Kolokviji		Usmeni ispit				
Pismeni ispit		Projekt				

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu
Tjedno rješavanje zadataka s natjecanja i izlaganje i/ili pismeni ispit (60%), ocjena iz nastavne prakse (40%)

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

	Udžbenici informatike za osnovnu školu	5	
	Zadaci s informatičkih natjecanja OŠ (Infokup, HSIN,...)		da
Dopunska literatura	1. hospotacija, ogledni sat, pripreme OŠ - 60% 2. praktični ispit - 40%		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	1. studentske ankete 2.povratne informacije mentora OŠ 3. povratne informacije sa stručnih ispita 4. izvještaji mentora, 5.samoprocjena,		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Metodika nastave informatike II					
Kod	PMIK60	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	Bodovna vrijednost (ECTS)	6.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	30	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Teorijski i praktično osposobiti studente za kvalitetnu pripremu, realizaciju i analizu nastavnog procesa na temelju rezultata znanstvenih istraživanja u području informatičkog obrazovanja
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušana Metodika nastave informatike I. Obvezno temeljito poznavanje ključnih informatičkih tema (programiranje, algoritmi i strukture podataka, baze podataka, arhitektura računala, Poželjno je poznavanje didaktike i psihologije učenja.
Ishodi učenja	1. Procijeniti programske jezike za poučavanje programiranja s obzirom na dob učenika te programske paradigme. 2. Primijeniti metodu posredovanog prijenosa znanja između različitih programskih jezika/paradigmi. 3. Primijeniti tehnike rješavanja problema i uloga varijabli u algoritmima. 4. Prepoznati potencijalne miskoncepcije i sastaviti test za njihovo otkrivanje. 5. Poučavati tehnike efikasnog praćenja izvršavanja koda. 6. Koristiti vizualizaciju algoritama za poučavanje i samostalno učenje temeljeno na teoriji multimedijalnog učenja. 7. Prepoznati teškoće u shvaćanju rekurzije i primijeniti odgovarajuće modele poučavanja. 8. Primijeniti suvremene alate i robote za poučavanje programiranja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Poučavanje programiranja – (alati, vizualizacije, roboti, programske paradigme...i njihova didaktička pozadina). Blokovski, vizualno-tekstualni i tekstualni programski jezici. Taksonomija programskih jezika i okruženja za poučavanje programiranja. Usporedba PJ – kriteriji i rezultati. Učinkovitost robota u poučavanju programiranja – primjeri istraživanja. (4+10+0) 2. Posredovani prijenos - prijelazi između različitih okruženja. Analiza istraživanja, preporuke u nastavi. Tehnike rješavanja problema. Uloga varijabli. (2+0+0) 3. Tipične početničke greške u programiranju – klasifikacije i uzroci. Usporedba s ekspertima. Miskoncepcije o efikasnosti i korektnosti program. Istraživanja miskoncepcija. (4+0+0) 4. Rekurzija – osnovni slučajevi – tipične greške, studentske teškoće i njihovi uzroci. Zašto je teška – primjeri. Mentalni modeli rekurzije. Modeli poučavanja rekurzije- model malih ljudi i ugniježdenih okvira. (2+0+0) 5. Poučavanje objektnog programiranja – koraci implementacije (klase, objekti, nasljeđivanje, enkapsulacija, ponovna upotrebljivost), zašto prije metodologija nego jezik, što se ne preporuča koristiti, koji pristup prije koristiti (objektni ili proceduralni). Fenomenogafska studija – shvaćanje pojma klasa, objekt. (2+0+0) 6. Vizualizacije – apstrakcija, primjena u poučavanju algoritama i struktura podataka.- primjeri (obilasci binarnog stabla po širini i dubini, sortiranja, heap-sort, AVL, Dijkstra-algoritam najkraćeg puta, hashing, Huffmanov kod). Istraživanja stvarnih efekata vizualizacije: meta-analiza. Razine uključenosti studenata. Teorija multimedijalnog učenja - principi. Kognitivno preopterećenje – uzroci, načini redukcije. (6+10+0) 7. Natjecanja iz informatike - provedba i teme s natjecanja, Infokup, HSIN. Analiza zadataka, rješavanje u programskom jeziku JAVA, C++, Python - usporedba (2+10+0) 8. Programiranje GUI aplikacija - u nastavi informatike. Tkinter (2+8+0) 9. Istraživanja u području informatičkog obrazovanja. Pregled relevantne literature, analiza odabranih znanstvenih radova (2+0+0) 10. Planiranje nastave programiranja. Analiza i izrada scenarija učenja (pripreme za sat), sudjelovanje u nastavi u osnovnoj školi, analiza satova (2+0+30) 11. Nastava informatike u srednjim školama, kurikulum gimnazije, strukovne škole. Proračunske tablice i baze podataka u nastavi informatike u srednjim školama (2+2+0).
Vrste izvođenja nastave	☑ Predavanja	☐ Terenska nastava	☐

	☑ Seminari ☑ Vježbe ☐ On line u cijelosti ☑ Mješovito e-učenje		☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad		☐ ☐ ☐	
Obveze studenata	Pohađanje svih oblika nastave, nastavna praksa, 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	2	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat		Nastavna praksa	1
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit	3		
	Pismeni ispit		Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Usmeni ispit (75%), Nastavna praksa (25%).					

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	1. Mladenović, M., Metodika nastave matematike II-predavanja, 2025.		da
	2. Hazzan, O., Lapidot, T., Ragonis, N., Guide to teaching computer science: an activity-based approach, Springer, 2011.	1	
	3. Fincher, S., Petre, M., Computer science education research, Taylor & Francis 2004.	1	

Dopunska literatura	Publikacije u časopisima:: Computers & Education,, ACM Transactions on Computing Education, The Computer Science Education Journal Publikacije s konferencija:: SIGCSE (Special Interest Group on Computer Science Education), ITiCSE (Innovation and Technology in Computer Science), ISSEP (Informatics in Secondary Schools: Evolution and Perspective) Ostali znanstveni radovi iz informatičkog obrazovanja
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	1. Studentske ankete. 2. Povratne informacije mentora iz osnovne i srednje škole. 3. Povratne informacije sa stručnih ispita. Samoprocjena
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Metodologija istraživanja u obrazovanju					
Kod	PMS114	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Anna Alajbeg	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Upoznati i ovladati tehnikama znanstveno-istraživačkog rada.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	nema
Ishodi učenja	1. Osposobljenost za znanstveno promišljanje i istraživanje pedagoških fenomena, 2. provođenje postupaka znanstvenog istraživanja, 3. izradu instrumenata znanstvenog istraživanja u odgojno-obrazovnoj praksi, 4. prezentaciju postignutih rezultata znanstvenoj i stručnoj javnosti te 5. za samostalno praćenje i razumijevanje znanstvene literature, osobito periodike.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Spoznaja i epistemiološke pretpostavke znanosti 2. Struktura, sustav i klasifikacija znanosti 3. Znanost i istraživanje – pristupi, aspekti i vrste istraživanja 4. Tehnologija znanstveno-istraživačkog rad – projekti 5. Metode 6. Eksperiment 7. Postupci, instrumenti i tehnike prikupljanja podataka 8./9.Mjerne karakteristike instrumenata 10. Rad na dokumentaciji 11. Sustavno promatranje i intervjuiranje 12. Anketiranje 13. Procjenjivanje i prosuđivanje 14. Testiranje i ispitivanje zadacima objektivnog tipa 15. Izvještaj o istraživanju*
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, izrada i prezentacija seminarskog rada, položeni kolokviji ili ispit.		

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	0.5		
	Kolokviji	0.5	Usmeni ispit	0.5		
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Nazočnost na nastavi, aktivnost na nastavi, rezultati kolokvija, rezultati ispita.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Mužić, V. (2002.): Uvod u metodologiju istraživanja odgoja i obrazovanja. Educa, Zagreb.		
	Mejovšek, M. (2008). Metode znanstvenog istraživanja u društvenim i humanističkim znanostim.		
	Louis Cohen ; Lawrence Manion ; Keith Morrison ; Prijevod: Gordana Kuterovac Jagodić i Iris Marušić Metode istraživanja u obrazovanju // Jastrebarsko: Naklada Slap, 2007		

Dopunska literatura	1. Halmi, A. (2001.): Metododoligija istraživanja u socijalnom radu. Alinea, Zagreb. 2. Halmi, A. (1996.): Kvalitativna metododoligija u društvenim istraživanjima. AGM, Samobor.

	3. Halmi, A. (2003.): Strategije kvalitativnih istraživanja u primjenenim društvenim znanostima. Naklada Slap, Jastrebarsko. 4. Periodika: Napredak, Odgojne znanosti, Društvena istraživanja...**
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija predmeta i nastavnika
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Sociologija odgoja i obrazovanja		
Kod	PMS108	Godina studija	2.
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0
Suradnici		Način izvođenja nastave (broj sati u semestru)	P: 15, S: 15, V: 0, T: 0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%

Opis kolegija	
Ciljevi kolegija	Upoznati studente/ice s osnovnim ciljevima, pojmovima, razvojem, teorijskim pristupima, društvenim kontekstom, specifičnostima odgojno-obrazovnih institucija te položajem i odnosima sudionika u njima. Razviti kod studenata opće kompetencije poput kritičkog mišljenja te sposobnosti primjene znanja u praksi.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	Studenti/ice će nakon izvršavanja studijskih obveza moći: 1.Opisati i definirati predmet sociologije odgoja (nastanak i razvoj, osnovni pojmovi, mjesto u sustavu znanosti); 2.Objasniti širi društveni kontekst odgoja i obrazovanja (vrijednosti, odnose, funkcije, ne/jednakosti, važnost odgoja-obrazovanja, procese koji utječu na uspjeh učenika, devijacije i sl.); 3.Prepoznati sociološke (teorijske) perspektive koje se odnose na odgoj-obrazovanje (osnovne postavke, prednosti/nedostaci); 4.Identificirati utjecaj društvenih i tehnoloških promjena na razvoj odgoja-obrazovanja (demokratizacija, multikultura, globalizacija, ekologija, tehnologija); 5.Razumijeti važnost uloge odgojitelja/učitelja u društvu (karakteristike profesije); 6.Demonstrirati prezentaciju odgojnih i obrazovnih sadržaja ovog kolegija. 7. Opisati i analizirati uzroke i posljedice nejednakosti u obrazovnim iskustvima i postignućima 8. Moći predložiti promjene koje bi pozitivno utjecale na transformaciju sustava obrazovanja u Hrvatskoj
Sadržaj kolegija detaljno razrađen prema satnici nastave	Sadržaj predmeta obuhvaća: 1.Uvod u predmet obveze,programski zahtjevi, literatura i način rada (dogovor sa studentima (2 sata) 2.Analiza i objašnjenjeosnovnih pojmova: odgoj, obrazovanje, socijalizacija...(2 sata) 3.Osnove povijesnog razvoja sociologije odgoja i obrazovanja – nastanak, razvoj, djelokrug i zadaci; odnos prema drugim znanostima (4 sata) 4.Teorijske perspektive sociologije odgoja i obrazovanja – funkcionalizam, konfliktna teorijska perspektiva, feminističke teorije, interakcionizam (4 sata) 5.Društvene nejednakosti i obrazovne šanse (2 sata) 6. Obrazovanje i reprodukcija društvenih nejednakosti (2 sata) 7.Odgoj i socijalne promjene - društvene vrijednosti; - socijalizacija i devijantne pojave (2 sata) 8.Društveni kontekst odgoja i obrazovanja (4 sata) 9.Sociologija profesije odgojitelj i profesije učitelj (2 sata) 10. Obrazovanje i reprodukcija društvenih nejednakosti (2 sata) 11.Ekologija i odgoj (2 sata) 12.Novi trendovi (2 sata)
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☑ Mentorski rad
Obveze studenata	• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi

	• vođenje refleksivnog dnevnika kroz semestar samostalno • samostalna priprema i izlaganje seminara

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	0	Praktični rad	
	Eksperimentalni rad	0.2	Referat			
	Esej	0	Seminarski rad	0.3		
	Kolokviji		Usmeni ispit			
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pismeni ispit – 50% Seminar, vođenje refleksivnog dnevnika - 25% Prisustvo i aktivnost na nastavi - 25% Pisanje refleksivnog dnevnika studentima će pomoći razvijati vještinu kritičkog mišljenja kroz osobne osvrte o vlastitom iskustvu, usmjeravajući fokus na vlastite poglede, kroz kontempliranje te pronalaženje rješenja za probleme. Refleksivni dnevnik u ovom kolegiju pomaže studentima da osvijeste obrazovne nejednakosti u društvu te da dublje uđu u tematiku kolegija, s obzirom da refleksivni dnevnik sadrži i perspektivu onoga koji ga vodi.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Giddens A. (2007.) Sociologija, Zagreb, Nakladni Zavod Globus XVI. poglavlje Obrazovanje str.488-526		
	Haralambos, M., Holbron, M. (2002).Sociologija: Teme i perspektive. (str. 773-882). Zagreb: Golden marketing.		
	Liessmann, K. P. (2019) Obrazovanje kao izazov Zagreb : Školska knjiga,		
	Prpić K. (ur.) (2005.) Elite znanja u društvu (ne)znanja, Zagreb IDIZ		

Dopunska literatura	Bognar, B. Škola na prijelazu iz industrijskog u postindustrijsko društvo. Metodički ogledi 10(2): str. 9-24 Farnell, T (2009) Jamči li besplatno obrazovanje i jednak pristup obrazovanju. Revija za socijalnu politiku (god.16 br.2) Piršl, Temeljni pojmovi odgoja, http://209.132/search?q=cache:wtj7xGc4SUIJ.www.ffpu.hr/fileadmin/Documenti/Odgoj_02.ppt+odgoj+definicija&cd=3&hl=en&ct=clnk, 29.1.1020. Ross, A. (2009), Educational Policies that Address Social Inequality: Overall Report. Dostupno na: http://www.epasi.eu
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evaluacijske liste, ispitna postignuća. Evidencija o nazočnosti na predavanjima i seminarima. Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika. Rezultati na kolokvijima i pismenom ispitu. Zajednička rasprava o načinima unapređenja rada .
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Napredni modeli nastave					
Kod	PMS201	Godina studija	2.			
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Cilj predmeta je da studenti upoznaju različite teorije, sustave i modele procesa nastave i učenja uz kritički i stvaralački odnos prema edukacijskoj teoriji i praksi; da upoznaju različita teorijsko-metodološka ishodišta edukacijskih procesa; da se upoznaju sa razvojnim kontinuitetom nastave; da se upoznaju sa različitim shvaćanjima (teorijama) razvoja i nastave; da upoznaju razliku između tradicionalnih i suvremenih sustava i modela nastave i učenja; da upoznaju različite sustave i modele nastave i njihove posebnosti; da se osposobe za organizaciju nastave u skladu s različitim sustavima i modelima nastave i učenja; da se osposobe za transfer i interferenciju spoznaja na različite situacije edukacijskih procesa; da se motiviraju za istraživački rad na području sustava i modela nastave i učenja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Položen ispit iz predmeta Didaktika
Ishodi učenja	Očekuje se da studenti razviju sljedeće opće kompetencije: - identificirati i analizirati razloge postojanja više teorija, sustava i modela nastave i učenja - - identificirati složenost odgojno-obrazovnog procesa - objasniti i analizirati razvojni kontinuitet nastave - razlikovati i usporediti različite paradigmatske osnove i znanstveno-teorijske pozicije znanosti o odgoju i obrazovanju - nabrojati tradicionalne i suvremene sustave i modele nastave i učenja - usporediti i analizirati tradicionalne i suvremene sustave i modele nastave i učenja - analizirati temeljne elemente nastavnog procesa u različitim sustavima i modelima nastave i učenja - razlikovati temeljne strukture i funkcije pojedinih sustava - pripremiti, realizirati i vrednovati nastavni sat u skladu s različitim modelima u procesu nastave i učenja - identificirati i opisati utjecaj organizacije nastave na razvoj učenika.
Sadržaj kolegija detaljno razrađen prema satnici nastave	Razlozi postojanja više sustava i modela nastave i učenja. Složenost nastave i učenja. Različitost pristupa problemima nastave i učenja. Različitost paradigmatske osnove i znanstveno-teorijskih pozicija znanosti o odgoju i obrazovanju. Različitost metodoloških polazišta. Temeljna obilježja komunikacije, svrha, ciljevi i zadaci, odnosi sudionika, učionci. Modeli nastave: Transmisijski model nastave Transakcijski model nastave Transformacijski model nastave Post-postmoderna majeutika Post-industrijsko društvo Društva znanja Koncepcije cjeloživotnog učenja Sokratov dijalog Teorije druge modernizacije ili post-postmoderne Teorija mcdonaldizacije Teorija društva rizika Teorija fluidnog društva Teorija umreženog društva Teorija komunikativnog djelovanja Kritička pedagogija Konstruktivizam Teorija iskustvenog učenja Kritičko mišljenje - sapere aude Majeutički model nastave
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi • samostalna priprema i izlaganje seminara

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			0	
Esej		Seminarski rad	0.5		0	
Kolokviji		Usmeni ispit				

	Pismeni ispit	1	Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pismeni ispit – 50% Seminar - 25% Prisustvo i aktivnost na nastavi - 25%					
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov			Broj primjeraka u knjižnici	Dostupnost putem ostalih medija	
	Kovačević, S.,Mušanović, L. (2013), Od transmisije do majeutike – modeli nastave, HFD, Rijeka.					
	Jensen, E. (2003), Super nastava. Zagreb: Educa					
Dopunska literatura	*** (1993), Didaktičke teorije. Zagreb: Educa. Bošnjak, B. (1998), Drugo lice škole. Zagreb: Alinea.					
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evaluacijske liste, ispitna postignuća. Evidencija o nazočnosti na predavanjima i seminarima. Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika. Rezultati na kolokvijima i pismenom ispitu. Zajednička rasprava o načinima unapređenja rada.					
Ostalo (prema mišljenju predlagatelja)						

Naziv kolegija	Pedagogija adolescencije					
Kod	PMS175	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Anna Alajbeg	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Upoznati razvojne osobine i (ne)tipična ponašanja u adolescenciji. Shvatiti i prepoznati razvojno primjerene reakcije i ponašanja adolescenata te mogućnosti i načine pedagoškog odnosno odgojno-socijalnog utjecaja na tijek razvoja adolescenta. Postići osnovne kompetencije pedagoškog rada s adolescentima i roditeljima adolescenata.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema ih.
Ishodi učenja	· Opisati pedagogiju adolescencije kao znanstvenu disciplinu · Definirati i klasificirati temeljne pojmove razdoblja adolescencije · Objasniti pojmovno određenje adolescencije kroz razvojna razdoblja te raščlaniti socijalno-ekološke činitelje i odgojne utjecaje · Objasniti razvojne karakteristike i preispitati oblike i uzroke ponašanja karakterističnih za razdoblje adolescencije · Razlikovati i identificirati razvojno-pedagoške teškoće u adolescenciji · Navesti i procijeniti mogućnosti i načine odgojnog i socijalnog djelovanja na tijek razvoja adolescenta te preporučiti pedagoške intervencije · Steći znanje o različitim oblicima neprilagođenog ponašanja adolescenata · Kritički promišljati i raspravljati o socijalnim i odgojnim činiteljima razvoja u adolescenciji
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Pedagogija adolescencije: predmet, sadržaj, istraživanje i polje praktičnog djelovanja 2. Pojam, srodni pojmovi (pubertet, mladost) i razvojne karakteristike: tjelesne, kognitivne, emocionalne, socijalne 3. Pedagoška povijest djetinjstva i adolescencije 4. Adolescenti u socijalnom kontekstu: pristupi proučavanju adolescencije, generacijske skupine, produženo trajanje adolescencije 5. Adolescenti u teorijskom kontekstu: od bioloških do teorija kulture 6. Kognitivni razvoj: obrada informacija, donošenje odluka i pitanja procjene 7. Formiranje identiteta 8. Razvoj moralnih vrijednosti 9. Socijalni razvoj: promjena u karakteru prijateljskih i romantičnih odnosa 10. Adolescenti i njihove obitelji; odnos roditelja i adolescenata 11. Najčešći poremećaji u ponašanju u adolescenciji 12. Ponašanja i stavovi vezani uz zdravlje 13. Adolescentsko društvo, kultura i subkultura 14. Mogućnosti i oblici pedagoške prevencije i intervencije 15. Kolokvij
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐			
Obveze studenata	Redovito pohađanje i aktivno sudjelovanje u nastavi, seminari (pozitivno ocijenjen napisani seminarski rad i prezentacija), polaganje kolokvija ili 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	0.5			
Kolokviji	0.5	Usmeni ispit	0.5			

	Pismeni ispit		Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Završna ocjena iz kolegija Pedagogija adolescencije određuje se temeljem uspjeha postignutom na kolokviju tijekom predavanja i seminara. Studenti moraju napisati jedan seminarski rad u kojem će obraditi zadanu temu s popisa tema seminarskih radova. Seminar se ocjenjuje ocjenom od 1 do 5. Ocjena iz teorijskog dijela određuje se temeljem uspjeha postignutog na usmenom teorijskom kolokviju koji se održava u petnaestom tjednu nastave. Usmeni odgovori studenata ocjenjuje se ocjenom od 1 do 5. Konačna ocjena iz kolegija Pedagogija adolescencije izračunava se na sljedeći način:(ocjena teorija) + (ocjena seminar) + (redovitost i zalaganje na nastavi).					
Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov			Broj primjeraka u knjižnici	Dostupnost putem ostalih medija	
	Bastašić, Z. (1995, 2002), Pubertet i adolescencija. Školska knjiga, Zagreb					
	Glasser, W. (2002), Nesretni tinejdžeri. Alineja, Zagreb					
	Gudjons, H. (1994), Pedagogija – temeljna znanja. Educa, Zagreb, (peto pogl., str. 93-122)					
	Lacković-Grgin, K. (2006), Psihologija adolescencije. Slap, Jastrebarsko					
Dopunska literatura	Maleš, D. (1995), Između djetinjstva i zrelosti. Temposhop, Đakovo Rice, F. P,, Dolgin, K. G. (ed.) (2008), The adolescent: development, relationships, and culture, 12th edition. Boston: Pearson/Allyn and Bacon. (odabrana poglavlja					
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)						

Naziv kolegija	Pedagogija slobodnog vremena					
Kod	PMS172	Godina studija	2.			
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Cilj kolegija jest unaprijediti kulturu provođenja slobodnog vremena kod studenata kao budućih nastavnika, te upoznavanje s osnovnim teorijskim pedagoškim konceptima i najnovijim globalnim i hrvatskim istraživanjima koja se tiču slobodnog vremena. Osvijestiti važnost osmišljavanja slobodnog vremena djece i mladih i njihovog odgoja i obrazovanja u slobodnom vremenu za slobodno vrijeme. Osvijestiti važnost nekonzumerističkog, aktivnog, strukturiranog, te preventivnog provođenja slobodnog vremena.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Položene Pedagogija (79121)i Didaktika (79107)
Ishodi učenja	1. Uočiti prostor slobodnog vremena kao prostor dobrovoljnih aktivnosti odmora, rekreacije i samoostvarenja. 2. Definirati prostor slobodnog vremena kao prostora primarne prevencije PUP-a. 3. Prepoznati specifičnosti djece i mladih radi artikulacije njihovog slobodnog vremena. 4. Uočiti važnost i raznolikosti ponude aktivnosti u slobodnom i slobode izbora (s obzirom na socio-ekonomsko-demografske aspekte). 5. Usvojiti temeljne teorijske pristupe koji se bave fenomenom slobodnog vremena. 6. Izabrati aktivnost slobodnog vremena te ju pedagoški analizirati uz pomoć obrađenih teorijskih pristupa.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Pedagogija SV u sustavu pedagoških disciplina. 2.-4. Slobodno vrijeme – pojam i shvaćanja. 5./7. Funkcije i vrste slobodnog vremena. 8./9. Karakteristike slobodnog vremena mladih. 10./11. Osobitosti mladih i slobodno vrijeme. 12/13. Aktivnosti mladih u slobodnom vremenu. 14. Društveno poželjne aktivnosti mladih u SV. 15. Područja djelovanja PSV.

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

Obveze studenata
• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi • samostalna priprema i izlaganje seminara • terenska nastava u vidu posjeta umjetničkoj, sportskoj ili obrazovnoj ustanovi koja provodi aktivnosti kojima se bavi pedagogija slobodnog vremena, u pratnji nastavnice (2 puta u semestru) • terenska nastava se izvodi u izvornoj stvarnosti u umjetničkoj ili sportskoj instituciji (oko koje se većina studenata usuglasi, u pratnji nastavnice, 2 puta u semestru)

Praćenje rada studenata (*upisati udio u ECTS bodovima za svaku aktivnost tako da ukupni broj*						
	Pohađanje nastave	0.5	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	0.5		

ECTS bodova odgovara bodovnoj vrijednosti kolegija)	Kolokviji		Usmeni ispit			
	Pismeni ispit	1	Projekt			
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pismeni ispit – 50% Prisustvo, seminar, terenska nastava - 50%					

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Arbunić, A. (2002.): Struktura slobodnog vremena djece (učenika) osnovnoškolske dobi. FF, Zagreb (neobjavljena doktorska disertacija).		
	Livazović, G. (2018), Uvod u pedagogiju slobodnog vremena. Filozofski fakultet ; Hrvatska sveučilišna naklada.		
	Slobodno vrijeme: pedagoška artikulacija i implikacije (2000). Napredak, tematski broj, 141 (4)		
Dopunska literatura	Martinić, T. (1977.): Slobodno vrijeme i suvremeno društvo. Informator, Zagreb. Ilišin, V. (2001.): Djeca i mediji. Državni zavod za zaštitu obitelji, materinstva i mladeži, Zagreb. Slobodno vrijeme (2012). Priručnik br. 7 zbirke priručnika Eduquality: Studenti s invaliditetom. Zagreb: Sveučilište u Zagrebu.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evaluacijske liste, ispitna postignuća. Evidencija o nazočnosti na predavanjima i seminarima. Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika. Rezultati na kolokvijima i pismenom ispitu. Zajednička rasprava o načinima unapređenja rada .		
Ostalo (prema mišljenju predlagatelja)	*Sadržaji seminarskih radova odrađuju se u seminarskim grupama (15x1 po grupi) i predstavljaju prezentaciju 1 znanstvenog rad iz područja slobodnog vremena.		

Naziv kolegija	Upravljanje razredom		
Kod	PMS160	Godina studija	2.
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0
Suradnici		Način izvođenja nastave (broj sati u semestru)	P: 15, S: 15, V: 0, T: 0
Status kolegija	Izborni	Postotak primjene e-učenja	0%

Opis kolegija	
Ciljevi kolegija	Ciljevi predmeta su osposobiti studente za kvalitetno donošenje odluka u nastavnom procesu s posebnim naglaskom na stvaranje kvalitetnog nastavnog ozračja i okružja, stjecanje znanja i vještina kojima mogu prevenirati te rješavati sukobe u različitim nastavnim situacijama te ih osposobiti za kvalitetno upravljanje razredom kao i za vođenje roditeljskih sastanaka i primanja roditelja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušani kolegiji Didaktika i Opća pedagogija
Ishodi učenja	Nakon odslušanog i položenog predmeta studenti će moći: 1.Prepoznavati, razlikovati i vrednovati različite stilove rada nastavnika i stilove odgoja. 2.Poznavati, analizirati i vrednovati odrednice kvalitetne nastavne klime i komunikacije, odnosno nastavnog ozračja. 3.Definirati, procjenjivati i vrednovati osobitosti učinkovitog nastavnog procesa. 4.Poznavati, razlikovati i vrednovati uzroke školske nedisciplinе, te načine motiviranja učenika ovisno o njihovim razvojnim karakteristikama. 5.Poznavati, razlikovati i vrednovati načine postizanja discipline u nastavnom procesu uvažavajući razvojne karakteristike učenika, te usavršavati kompetencije postupanja u različitim nastavnim situacijama. 6.Organizirati kvalitetne roditeljske sastanke i primanja roditelja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.odnos tradicionalne i suvremene škole s obzirom na ulogu sudionika nastavnog procesa, načine stjecanja znanja i vještina; kurikulumski, kompetencijski i sukonstruktivistički pristup izgradnji suvremene škole (2P) 2.značajke učinkovitog nastavnog procesa u suvremenoj školi (1P) 3.upravljanje razredom s obzirom na razvojne karakteristike učenika (dobne, spolne, socijalne, emocionalne, zdravstvene) (2P) 4.stilovi rada nastavnika i stilovi odgoja (1P) 5.motivacija u suvremenom odgojno – obrazovnom procesu (1P) 6.utjecaj ocjenjivanja na kvalitetu nastavnog ozračja (1P) 7.značajke nastavnog ozračja i okružja u suvremenoj nastavi te u važnijim reformskim pedagogijama (2P) 8.učinkovita nastavna komunikacija (1P) 9.uzroci školske discipline i ostvarivanje discipline u nastavnom procesu (2P) 10.organizacija roditeljskog sastanka (1P) 11.primanje roditelja (1P) Seminari se organiziraju kao radionice u kojima studenti pripremaju, kritički promišljaju i diskutiraju o temama, aktualnostima i problemima važnima za upravljanje razredom te planiraju nove strategije prevencije i rješavanja detektiranih problema. U provedbi seminara od studenata se očekuje angažirano sudjelovanje, suradničko učenje i timski rad.
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje ☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi • napisana i predana dva eseja

	• samostalna priprema i izlaganje seminara Kroz seminarsku nastavu odrađivat će se i dio priprema i materijala koji će biti potrebni za izvršavanje obveze pisanja eseja. Tema prvog eseja na početku semestra će se ticati njihovog dosadašnjeg obrazovnog puta i istinskih iskustava koja su obilježila njihovo obrazovanje, nastavnici kroz njihovo školovanje, iskustva s nastavnicima, komunikacijske vještine nastavnika i sl. Tema drugog eseja će biti ista, no imajući u vidu materijale koje su pročitali, razgovore i rasprave koje su se vodile na seminarima - kako studenti reflektiraju argumente te jesu li se njihove perspektive i osjećaji promijenili?

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	0.3	Seminarski rad	0.2		
	Kolokviji		Usmeni ispit	0		
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pismeni ispit – 50% Seminar, eseji - 25% Prisustvo i aktivnost na nastavi - 25%

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Ilić, I.; Ištvanić, I.; Letica, J.; Sirovatka, G.; Vican, D. (2012), Upravljanje razredom. Zagreb: Agencija za strukovno obrazovanje i obrazovanje odraslih u suradnji s British Councilom.		dostupno
	Vizek Vidović, V.; Rijavec, M.; Vlahović -Štetić, V.; Miljković, D: (2014), Psihologija obrazovanja. Zagreb: IEP VERN. (odabrana poglavlja)		
	Kyriacou, C. (2001), Temeljna nastavna umijeća. Zagreb: Educa. (odabrana poglavlja)		

Dopunska literatura	Jensen, E. (2003), Super nastava. Zagreb: Educa. Glasser, W. (1995), Nastavnik u kvalitetnoj školi. Zagreb: Educa. Ajduković, M.; Pečnik, N. (20029, Nenasilno rješavanje sukoba. Zagreb: Alinea. Bičanić, J. (20019, Vježbanje životnih vještina. Priručnik za razrednike. Zagreb: Alinea Matijević, M. (2001), Alternativne škole. Zagreb: Tipex. Matijević, M.; Radovanović, D. (2011), Nastava usmjerena na učenika. Zagreb: Školske novine.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evaluacijske liste, ispitna postignuća. Evidencija o nazočnosti na predavanjima i seminarima. Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika. Rezultati na kolokvijima i pismenom ispitu. Zajednička rasprava o načinima unapređenja rada .
Ostalo (prema mišljenju predlagatelja)	

<table>
<tr><td>Naziv kolegija</td><td colspan="4">Algoritmi u bioinformatici</td></tr>
<tr><td>Kod</td><td>PMIE20</td><td>Godina studija</td><td colspan="3">2.</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="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">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="4">Osnove struktura podatka te osnove programiranja.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">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="4">Uvod u osnove biologije (genomike)

Osnove statistike u bioinformatici

Sekvencioniranje genoma

Dinamičko programiranje

Pohlepni algoritmi

Udaljenost među nizovima znakova (stringovima)

Prepoznavanje motiva

Poravnanje nizova znakova (stringova)

Taksonomska klasifikacija (Clustering)</td></tr>
</table>

	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)	

Naziv kolegija	Analitika učenja u računalom potpomognutom procesu učenja i poučavanja					
Kod	PMIK25	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Ani Grubišić	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	Cilj je steći znanja o primjeni analitike učenja u računalom potpomognutom procesu učenja i poučavanja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Uvjeti za upis: nema ih. Ulazne kompetencije: poznavanje osnova rada na računalu.
Ishodi učenja	Opisati analitiku učenja i usporediti je s rudarenjem podataka u obrazovanju (eng. educational data mining). Analizirati, planirati i postaviti analitiku učenja za malo pilot istraživanje, naglasiti namjeru i navesti alate koji će se koristiti za ostvarivanje ciljeva analize. Razviti matricu istaknutih alata za analitiku učenja s istaknutim strategijama analize. Vrednovati trenutno stanje tehnologija za analitiku učenja te opisati prednosti i nedostatke open source alata i komercijalnih alata. Vrednovati i opisati ulogu analitike učenja u sustavima za e-učenje. Provesti osnovne analitičke aktivnosti (npr. uvoz i vizualizacija podataka) putem open source alata (npr. R). Interpretirati podatke prikupljene u sustavima za e-učenje. Ispitati skupove podataka da bi se dobo uvid o tome kako su studenti uključeni u sustavima e-učenja.
Sadržaj kolegija detaljno razrađen prema satnici nastave	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, prekomjernaspecijalizacija (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, 4hV) 6. Rudarenje odnosa: korelacije, pronalaženje kauzalnosti, otkrivanjeslijednih 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)
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, izrada projekta		

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	0.5	Praktični rad	1
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	Domaće zadaće (25%) Izvještaj o projektu (25%) Pismeni ispit (50%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	The Handbook of Learning Analytics, Editors: Charles Lang, George Siemens, Alyssa Wise, Dragan Gašević, ISBN: 978-0-9952408-0-3, DOI: 10.18608/hla17		Online
	Baker, R.S. (2018) Big Data and Education. 4th Edition. Philadelphia, PA: University of Pennsylvania.		Online
Dopunska literatura	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.		
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)			

Naziv kolegija	Informatički menadžment					
Kod	PMIK70	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Marko Rosić	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			30	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	35%			

Opis kolegija	
Ciljevi kolegija	Kroz kolegij Informatički menadžment studenti će steći opće kompetencije potrebne za razumijevanje načina funkcioniranja poduzeća. Primjenom temeljnih teoretskih, metodoloških i aplikativna znanja iz područja menadžmenta i informatike te vođenja poslovanja student stječe kompetencije upravljanja poslovnim sustavima manjeg i srednjeg stupnja složenosti. Stečene kompetencije informatičkog menadžmenta temelje se na vještnama i znanjima usmjerenim vođenju projekata i rješavanju problema programiranjem. Pored navedenog studenti će biti sposobni za obavljanje poslova upravljačkog i organizacijskog tipa, imat će sposobnost vođenja kako informatičkih projekata tako i drugih projekata, upravljanja i implementiranja informacijskih poslovnih sustava, planiranja, rada u timu, organiziranja, komuniciranja, vođenja i kontrole različitih poslova na različitim razina u poduzećima iz područja informatike, komplementarnih djelatnosti i ostalih djelatnosti.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Nema preduvjeta
Ishodi učenja	1. Razumjeti na koji način funkcioniraju poduzeća, kako se ponašaju potrošači na tržištu 2. Objasniti način funkcioniranja poduzeća, načine upravljanja troškovima, metode izračuna cijene te utvrđivanja pokazatelja uspješnosti poslovanja 3. Razlikovati potrebna sredstava za rad poduzeća, dati primjer izračuna amortizacije osnovnih sredstava 4. Objasniti osnovnu primjenu informatičke tehnologije, uloge računalnih i IT sustava u proizvodnom i životnom okruženju 5. Objasniti važnost planiranja, organiziranja, kadroviranja, vođenja i kontrole u poduzeću te važnost njihove povezanosti za nesmetano funkcioniranje poduzeća 6. Primijeniti temeljne metode za analizu i projektiranja informacijskog sustava te izraditi razvojni plan uvođenja novog informacijskog sustava u organizaciju 7. Izraditi misiju, viziju, ciljeve, SWOT analizu poduzeća te definirati strategiju poduzeća 8. Prepoznati, istražiti i evaluirati poduzetničku priliku te mogućnosti i rizike pretvaranja poduzetničke prilike u poduzetnički poduhvat. 9. Samostalno pripremiti, organizirati i prezentirati poslovnu ideju, projekt ili plan 10. Izraditi prototip koristeći se primjerenim programskim jezikom za rješavanje manjih problema te koristiti osnovne programske konstrukcije odabranog programskog jezika
Sadržaj kolegija detaljno razrađen prema satnici nastave	Predavanja: 1. Uvod, poslovni sustav i i informatička tehnologija (2h) 2. Informacijski sustav i informatičke aktivnosti (2h) 3. Deset glavnih pogrešaka IT menadžmenta (2h) 4. Veza prema programskom inženjerstvu (2h) 5. Modeli razvoja (2h) 6. Sustavi podrške odlučivanju (2h) 7. Optimizacija sustava unutar zadanih ograničenja (2h) 8. Vođenje projekata (4h) 10. Financiranje (2h) 11. Planiranje (2h) 12. Poduzetnik i poduzetništvo (2h) 13. Izrada poslovnog plana (2h)

	14. Analiza uspješnosti projekta (2h) 15. Prezentacija projekta Vježbe prate predavanja u istoj satnici i raspodjeli tema.

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, izrada završnog projekta, 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	Istraživanje		Praktični rad	
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	1		
	Kolokviji		Usmeni ispit	2		
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Prisustvo/sudjelovanje na nastavi (20%) Seminar (40%) Pismeni/usmeni ispit (40%

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Introduction to Management Science Bernard W. Taylor III, Pearson Education, ISBN-10: 0132751917		
	Systems Analysis and Design in a Changing World, John W. Satzinger, Robert B. Jackson, Stephen D. Burd, ISBN-10: 1305117204		

Dopunska literatura	Kako upravljati razvojnim procesom, Steve Maguire, Microsoft press, Znak 1995.
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)	

Naziv kolegija	Istraživački rad u informatičkom obrazovanju					
Kod	PMIK65	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	Bodovna vrijednost (ECTS)	5.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	30	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Istražiti literaturu za odabrano područje istraživanja obrazovanja u informatici (npr. metode podučavanja, vizualizacijski sustavi, obrazovna tehnologija, itd.), napisati pregled literature za odabrano područje te izraditi plan istraživanja. Napraviti nacrt istraživanja, te ga provesti.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušan kolegij Metodika nastave informatike I Upisan kolegij Metodika nastave informatike II
Ishodi učenja	Po usvajanju kolegija, studenti će biti osposobljeni: - raspravljati o područjima istraživanja informatičkog obrazovanja i otvorenim istraživačkim pitanjima - opisati korake u provođenju pregleda literature - prepoznati znanstvene radove koji su relevantni za provedbu vlastitog istraživačkog rada - prepoznati istraživačka pitanja, primijenjenu metodologiju i pronalaske u istraživačkim radovima - izraditi pregled područja - izraditi plan provedbe vlastitog istraživanja - raspravljati o odlukama donesenim u izradi plana istraživanja
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Upoznavanje s područjima istraživanja u informatičkom obrazovanju (2+0) 2. Faze planiranja istraživanja (2+0) 3. Primjeri i analiza postojećih istraživanja u obrazovanju iz odabranih informatičkih područja (7+0) 4. Način pisanja pregleda literature (2+0) 5. Analiza primjera postojećih pregleda literature (2+0) 6. Izrada nacrta istraživanja (0+4) 7. Provedba istraživanja (0 +10) 8. Izrada znanstvenog rada (0+0+4) 9. Ilzlaganja, rasprava i analiza studentskih seminara i rezultata istraživanja (0+2)
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐			
Obveze studenata	Dolasci na predavanja. Izrada seminarskog rada. Osmisliti (i provesti) istraživanje.					

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	1.5	Praktični rad	
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad	3		
	Kolokviji		Usmeni ispit			
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Plan istraživanja (30%), Seminarski rad i izlaganje (70%)

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

	Sally Fincher, Marian Petre: Computer Science Education Research, 2004.	1	
	Orit Hazzan, Tami Lapidot, Noa Ragonis: Guide to Teaching Computer Science: An Activity-Based Approach	1	
	Manion, L., & Morrison, K. (2007). Metode istraživanja u obrazovanju.	5	
Dopunska literatura	Publikacije u časopisima: Computers & Education, ACM Transactions on Computing Education The Computer Science Education Journal Publikacije s konferencija: SIGCSE (Special Interest Group on Computer Science Education) ITiCSE (Innovation and Technology in Computer Science) ISSEP (Informatics in Secondary Schools: Evolution and Perspective) Online materijali i upute.		
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="4">Kognitivni sustavi</td></tr>
<tr><td>Kod</td><td>PMII20</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">50%</td></tr>
<tr><td colspan="5">Opis kolegija</td></tr>
<tr><td>Ciljevi kolegija</td><td colspan="4">Usvojiti jezgrenih metode umjetne inteligencije zasnovane na znanju. Upoznati se s zadacima koje rješava umjetna inteligencija zasnovana na znanju. Upoznati metode koje agenti umjetne inteligencije zasnovane na znanju koriste za rješavanje tih zadataka. Analizirati odnos između umjetne inteligencije zasnovane na znanju i ljudske kognicije.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="4">Uvjeti za upis: Uvod u umjetnu inteligenciju
Ulazne kompetencije: Strukture podataka i algoritmi.</td></tr>
<tr><td>Ishodi učenja</td><td colspan="4">Oblikovati i implementirati agente umjetne inteligencije zasnovane na znanju. Primijeniti agente i strategije radi rješavanje složenih, praktičnih problema Koristiti modele i rezultate agenata prilikom promišljanja o ljudskoj kogniciji</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="4">Tjedan1:
Predavanja: Uvodno predavanje: nastavnici, obaveze studenata, elementi tekućeg praćenja, ispit, ocjena, predstavljanje ciljeva, ishoda i strategija kolegija, literatura Semantičke mreže
Vježbe: Reprezentacija Ravenovih matrica pomoću semantičke mreže
Tjedan2:
Predavanja: Generiranje i testiranje, sukcesivna aproksimacija.
Vježbe: Rješavanje Ravenovih matrica pomoću semantičke mreže i generiranja i testiranja
Tjedan3:
Predavanja: Redukcija problema, Produkcijski sustavi
Vježbe: Rješavanje Ravenovih matrica pomoću semantičke mreže i sukcesivne aproksimacije
Tjedan4:
Predavanja: Okviri
Vježbe: Reprezentacija Ravenovih matrica pomoću okvira
Tjedan5:
Predavanja: Učenje snimanjem slučajeva, Rasuđivanje temeljem slučajeva
Vježbe: Učenje rješavanja problema Ravenovih matrica
Tjedan6:
Predavanja: Inkrementalno učenje koncepata, Klasifikacija
Vježbe: Učenje klasifikacijske sheme za problem Ravenovih matrica
Tjedan7:
Predavanja: Logika
Vježbe: Pravila za objašnjavanje postupka rješavanja problema Ravenovih matrica
Tjedan8:
Predavanja: Planiranje, Razumijevanje
Vježbe: Razumijevanje rješavanja problema Ravenovih matrica
Tjedan9:
Predavanja: Zdravorazumsko rasuđivanje, Skripte
Vježbe: Reprezentacija rješavanja problema Ravenovih matrica pomoću skripte
Tjedan10:
Predavanja: Učenje temeljem objašnjenja, Analogijsko rasuđivanja
Vježbe: Pronalaženje analognog problema za Ravenove matrice
Tjedan11:
Predavanja: Prostori verzija, Propagacija ograničenja
Vježbe: Propagacija propozicijskih ograničenja na vizualno ograničenje problema Ravenovih matrica
Tjedan12:</td></tr>
</table>

	Predavanja: Konfiguracija Vježbe: Rekonfiguracija pravila za rješavanje problema Ravenovih matrica Tjedan13: Predavanja: Dijagnoza Vježbe: Objašnjavanje i dijagnoza problema Ravenovih matrica Tjedan14: Predavanja: Učenje ispravljanjem pogrešaka Vježbe: Traženje i ispravljanje pogrešaka u postupku rješavanja Ravenovih matrica Tjedan15: Predavanja: Meta-rasuđivanje, Napredne teme Vježbe: Izbor metoda za rješavanje problema Ravenovih matrica

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 aktivno sudjelovanje u nastavnom procesu kolokvij pismeni 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	1
	Eksperimentalni rad		Referat			
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit			
	Pismeni ispit	2	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Aktivnost studenata na predavanjima i vježbama (prisutnost na vježbama, rješavanje zadataka) (40 %). Pismeni dio ispita (60 %), Završna ocjena izvodi se na temelju svih navedenih ocjena.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Artificial Intelligence: Structures and Strategies for Complex Problem Solving. George Luger. Sixth Edition. Pearson Education, 2009		
	Introduction to Knowledge Systems. Mark Stefik. Morgan Kauffman 1995.		

Dopunska literatura	Artificial Intelligence. Patrick Winston. Third Edition. MIT Press 1993
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)	

Naziv kolegija	Podaci i etika		
Kod	PMIH71	Godina studija	2.
Nositelj/i kolegija	prof. dr. sc. Marko Rosić	Bodovna vrijednost (ECTS)	2.5
Suradnici		Način izvođenja nastave (broj sati u semestru)	P: 15, S: 15, V: 0, T: 0
Status kolegija	Izborni	Postotak primjene e-učenja	20%

Opis kolegija	
Ciljevi kolegija	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.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	-
Ishodi učenja	• Analizirati problem, odnosno situaciju vezano za etička pitanja u promatranom području • Razlučivati bitno od nebitnog (apstrahirati) unutar promatranog područja • Kritički vrednovati probleme, situacije, procese i rješenja u poslovnom okruženju vezano za korištenje velikih skupova podataka • Vrednovati računalne modele i sa stajališta područja koja se obrađuju unutar ovog kolegija • Definirati potencijalna područja rizika pri razvoju sustava IKT-a (unutar tema obrađenih kolegijem).
Sadržaj kolegija detaljno razrađen prema satnici nastave	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 kvalitet života) (2) 9. Problem vječnih digitalnih zapisa (2) 10. Sigurnost (Tko odlučuje je li nova tehnologija sigurna?) (4) 11. Samomodificirajuće i samoreplicirajuće tehnologije (4)
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☑ Mješovito e-učenje ☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad
Obveze studenata	Pohađanje seminara, izrada seminarskog rada te njegovo izlaganje.
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Sudjelovanje u aktivnostima (40%), Usmeni ispit (60%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Bynum T. 2015 Computer and information ethics. In The Stanford encyclopedia of philosophy (ed. EN Zalta), Winter 2015. See		

	http://plato.stanford.edu/archives/win2015/entries/ethicscomputer/.		
	Floridi L. 2013 The ethics of information. Oxford, UK: Oxford University Press.		
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Razgovori sa studentima, anonimna studentska anketa, uspješnost na ispitu, samoanaliza.		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Programske paradigme					
Kod	PMID45	Godina studija	2.			
Nositelj/i kolegija	prof. dr. sc. Saša Mladenović Zoran Sambol, pred.	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	25%			

Opis kolegija	
Ciljevi kolegija	Stjecanje temeljnih znanja o programskim paradigmama.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Strukture podataka i algoritmi Objektno-orijentirano programiranje
Ishodi učenja	Objasniti prednosti i mane pojedine programske paradigme Razviti jednostavne programe koristeći različite programske paradigme i usporediti njihovu realizaciju Utvrditi prikladnost korištenja određene programske paradigme u različitim kontekstima primjene Argumentirati prednosti i mane primjene funkcionalne i imperativne paradigme u izradi programskog koda s istovremenim izvršavanjem
Sadržaj kolegija detaljno razrađen prema satnici nastave	Pregled programskih paradigmi uz primjere pripadajućih programskih jezika Zajednička svojstva programskih jezika Imperativno programiranje Objektno-orijentirano programiranje – temeljeno na klasama Objektno-orijentirano programiranje – temeljeno na prototipovima Funkcijsko programiranje Istovremeno i imperativno programiranje Istovremeno i funkcijsko programiranje Logičko programiranje Primjeri dobre prakse Usporedba rješenja poznatih problema u različitim paradigmama sa zadacima s prijema za posao
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	Prisustvo na predavanjima i vježbama, aktivno sudjelovanje na nastavnim aktivnostima, izrada domaćih radova, izrada završnog projekta, 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	1
	Eksperimentalni rad		Referat		Domaće zadaće	0.5
	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	Prisustvo/aktivnost na nastavi (20%) Zadaci (40%) Pismeni/usmeni ispit (40%)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Robert W Sebesta, Concepts of Programming Languages, 10th Edition, Addison-Wesley, 2013		

Dopunska literatura	Maurizio Gabbrielli, Simone Martini; Programming Languages: Principles and Paradigms (Undergraduate Topics in Computer Science). 2010th Edition. ISBN-13: 978-1848829138
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">Robotika u nastavi</td></tr>
<tr><td>Kod</td><td>PMT279</td><td>Godina studija</td><td colspan="3">2.</td></tr>
<tr><td>Nositelj/i kolegija</td><td>doc. dr. sc. Barbara Džaja, prof. struč. stud.</td><td>Bodovna vrijednost (ECTS)</td><td colspan="3">2.5</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>0</td><td>15</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">Osposobiti studenta za samostalnu primjenu jednostavnih robotskih sustava u nastavi.</td></tr>
<tr><td>Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij</td><td colspan="5">Nema ih</td></tr>
<tr><td>Ishodi učenja</td><td colspan="5">Nakon ovog predmeta student će biti sposoban:
1. Sastaviti obrazovni robotski sklop
2. Napraviti program pomoću grafičkog programskog alata
3. Pokrenuti Arduino, Raspberry Pi. mBot
4. Napisati program u Pythonu za upravljanje Raspberry PI GPIO
5. Napisati program u Arduino IDE sučelju i pokrenuti ga na Arduino razvojnoj pločici
6. Napraviti program pomoću mBlock alata
7. Konstruirati jednostavni robotski sklop
12. tjedan: FischerTechnik konstrukcije za primijenjenu robotiku. Modeli za rad u nastavi. (1h)
13. tjedan: Micro:bit – razvojna pločica. Opis uređaja. Svjetla, tipke, kompas, akcelerometar, izvodi, tehničke informacije. Povezivanje s računalom, mogućnosti. (1h)
14. tjedan: Micro:bit – programiranje uređaja. JavaScript Blocks. Python editor. Microsoft Block Editor, Microsoft Touch Develop.(1h)
15. tjedan: 2. kolokvij

Vježbe:
1. tjedan: Upoznavanje sa testnom pločicom i pravilima u laboratoriju. Rad sa testnom pločicom. Priključivanje osnovnih elektroničkih elemenata. (1h)
2. tjedan Spajanje Raspberry Pi-a i pokretanje. (1h)
3. tjedan Spajanje i upravljanje LED diodom pomoću Raspberry Pi-a. (1h)
4. tjedan Spajanje motora na testnu pločicu i upravljanje pomoću Raspberry Pi-a. (1h)
5. tjedan Osnovne funkcije i rad u Arduino IDE sučelju. (1h)
6. tjedan Spajanje i upravljanje LED diodom pomoću Arduino UNO uređaja. (1h)
7. tjedan Spajanje senzora i čitanje informacija pomoću Arduino UNO uređaja. (1h)
8. tjedan Spajanje MakeBlock uređaja i mBot robota. (1h)
9. tjedan Programiranje MakeBlock uređaja i mBot robota. (1h)
10. tjedan Sastavljanje Lego Mindstorms robota. (1h)
11. tjedan Izrada jednostavnog programa za upravljanje Lego Mindstorms. (1h)
12. tjedan Konstrukcija jednostavnog robotskog sklopa. (1h)
13. tjedan Spajanje i pokretanje Micro:bit uređaja. Povezivanje s računalom i mobilnim uređajem. (1h)
14. tjedan Micro:bit programiranje i upravljanje. (1h)
15. tjedan Kolokviranje i nadoknada vježbi. (1h)</td></tr>
<tr><td>Sadržaj kolegija detaljno razrađen prema satnici nastave</td><td colspan="5">Predavanja:
1. tjedan: Uvodno predavanje, upoznavanje studenata sa pravilima predmeta, pravilima pohađanja, opća definicija. Uvodno o robotici u nastavi. Upoznavanje studenata sa robotskim sustavima za edukaciju: FischerTechnik, Lego mindstorms, MBlock, Raspberry Pi, Arduino. Micro:bit. (1h)
2. tjedan: Raspberry Pi – hardverski dio. Razvoj uređaja. Hardverski dio. Priključci uređaja. Potrošnja i izbor napajanja. GPIO priključci Raspberry Pi uređaja. Dodaci za Raspberry Pi. (1h)
3. tjedan: Raspberry Pi – softverski dio. Odabir operativnog sustava. Priprema SD kartice i</td></tr>
</table>

	instalacija OS-a. Pokretanje OS-a i instalacija potrebnih programa. Pokretanje Pythona i upravljanje GPIO priključcima koristeći Python. (1h) 4. tjedan: Raspberry Pi – naprednije korištenje. Upravljanje elektromotorima. Motor driver, H-most. Priključivanje upravljačkih izvoda na motor driver. Upravljanje motorima. Spajanje senzora. (1h) 5. tjedan: Arduino. Općenito o Arduino platformi. Verzije Arduina. Detaljni hardverski opis razvojne Arduino pločice. Instalacija i korištenje Arduino IDE. Način pisanja i pokretanja programa u Arduino IDE-u (1h) 6. tjedan: Arduino platforma. Izrada složenijih projekata. Spajanje senzora. Upravljanje temeljem ulaznih podataka. (1h) 7. tjedan: 1. kolokvij 8. tjedan: MakeBlock platforma. mBot edukacijski robot. MakeBlock senzori. (1h) 9. tjedan: mBlock. Blokovsko programiranje pomoću mBlock alata. Izrada programa pomoću mBlock alata. (1h) 10. tjedan: Lego Mindstorms. Osnovni oblici. Sastavljanje Lego Mindstorms robota. Opis robota. (1h) 11. tjedan: Lego Mindstorms NXT. Programiranje Lego Mindstorms EV3. WeDo 2.0 (1h)

Vrste izvođenja nastave	☑ Predavanja ☐ Seminari ☑ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☑ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☑ Demonstracija rada robota ☐ ☐ ☐
Obveze studenata	Prisustvo na predavanjima Samostalna izrada obrazovnog robotskog sklopa Aktivno sudjelovanje u nastavnom procesu Aktivno sudjelovanje na vježbama 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	Istraživanje		Praktični rad	0.5
	Eksperimentalni rad		Referat		Samostalno učenje za ispit i	1
	Esej		Seminarski rad			
	Kolokviji		Usmeni ispit			
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Ukupno bodovanje (100%): Ispit ili 2 kolokvija - 90 %, vježbe 10% 1. Kolokvij 1 : 45 % (ili ispit) 2. Kolokvij 2 : 45 % (ili ispit) 3. vježbe : 10 % (obvezne) Ocjena po postocima: 50% do 62% - dovoljan (2) 63% do 75% - dobar (3) 76% do 88% - vrlo dobar (4)

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Paolo Zanzerović, Arduino kroz jednostavne primjere		
	Robotika u nastavi – predavanja – interna skripta i online materijali.		

Dopunska literatura	1. Michael Margolis, Arduino CookBook 2. Simon Monk, Raspberry Pi CookBook 3. Guan Xuefeng Team, Scratch, The adventures of Mike 4. Laurens Valk, The LEGO MINDSTORMS EV3 Discovery Book (Full Color): A Beginner's Guide to Building and Programming Robots
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih	Razgovor sa studentima. Mišljenja studenata o kvaliteti nastave putem anonimnih anketa.

ishoda učenja	Nastavnici koji podučavaju srodne predmete surađuju i zajednički vode brigu o kvaliteti nastave. Uspješnost studenata na kolegiju. Samoanaliza.
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Diplomski informatički rad					
Kod	PMIZ50	Godina studija	2.			
Nositelj/i kolegija		Bodovna vrijednost (ECTS)	11.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	6	0	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija			
Ciljevi kolegija	Diplomskim radom student dokazuje stručno znanje i samostalnost u radu.		
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	nema preduvjeta		
Ishodi učenja	1. Definirati problem sukladno pravilima struke. 2. Osmisliti i samostalno provesti istraživanje. 3. Samostalno riješiti praktični problem/zadatak. 4. primjeniti usvojena znanja i opće kompetencije stečene tijekom studija. 5. Primjeniti usvojena znanja i specifične kompetencije pripadnog predmeta. 6. Primjeniti metodologiju pisanja stručnog i znanstvenog djela. 7. Napraviti prikaz rezultata provedenog istraživanja korištenjem multimedijskih alata. 8. Koristiti prezentacijske vještine kod interpretacije rezultata istraživanja.		
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Predavanje o načinu izrade diplomskog rada. (2h) 2. Priprema za izradu diplomskog rada i pretraživanje baza stručnih i znanstvenih radova. (2h) 3. Priprema izlaganja. (2h)		
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, izrada i obrana diplomskog rada pred povjerenstvom.		
Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	1. Pisani dio 40% 2. Usmena obrana rada 60%		

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	How to Write a Better Thesis Autori: David Evans, Paul Gruba, Justin Zobel Izdravač: Springer Science & Business Media, 2014.		

Dopunska literatura	
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija mentora i povjerenstva
Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Diplomski informatički seminar					
Kod	PMIZ40	Godina studija	2.			
Nositelj/i kolegija		Bodovna vrijednost (ECTS)	4.0			
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	Kroz diskusiju o odabranoj tematici, unaprijediti vještinu pisanja, kao i komunikacijske i prezentacijske vještine studenta.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	nema preduvjeta
Ishodi učenja	1. Definirati područje i temu za izradu diplomskog seminara. sukladno pravilima struke. 2. Osmisliti vanjski oblik i strukturu diplomskog seminara. 3. Samostalno istražiti i analizirati literaturu prikladnu za izradu diplomskog seminara. 4. Primjeniti metodologiju pisanja znanstvenog djela.
Sadržaj kolegija detaljno razrađen prema satnici nastave	1. Predavanje o načinu izrade diplomskog seminara. (2h) 2. Priprema za izradu diplomskog seminara i pretraživanje baza stručnih i znanstvenih radova. (2h) 3. Priprema izlaganja. (2h) 4. Izlaganja seminarskih radova (9h)

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

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

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	1. Pisani dio - 40% 2. Usmena obrana rada - 60%

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	How to write and publish a scientific paper. Autori: Barbara Gastel, Robert A. Day. Izdavač: ABC-CLIO, 2016.		

Dopunska literatura	Rhodes, M. (2012). How to undertake a research project and write a scientific paper. Annals of The Royal College of Surgeons of England, 94(5), 297–299.
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Konzultacije, razgovor, aktivno sudjelovanje, evaluacija mentora i povjerenstva

Ostalo (prema mišljenju predlagatelja)	

Naziv kolegija	Metodički informatički seminar s nastavnom praksom II					
Kod	PMIK61	Godina studija	2.			
Nositelj/i kolegija	doc. dr. sc. Monika Mladenović	Bodovna vrijednost (ECTS)	3.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			0	15	30	0
Status kolegija	Obvezni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Osposobiti studente za kvalitetnu pripremu, izvođenje i analizu svih vrsta nastave informatike, ovladavanje raznovrsnim repertoarom metoda poučavanja, adekvatnu uporabu medija te pripremu učenika srednjih škola za informatička natjecanja.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Odslušana Metodika nastave informatike II. Za ispitni sat preduvjet je položen MNI1. Poznavanje didaktičkih teorija, metoda poučavanja i osnova informatike
Ishodi učenja	Studenti će: 1. izraditi godišnji plan na nastavni predmet Informatika u srednjoj školi te ga razraditi za nastavne cjeline i teme 2.. ovladati raznovrsnim repertoarom modela poučavanja i argumentirano izvršiti izbor najprikladnijeg u datim okolnostima 3. adekvatno koristiti medije 4. napraviti pripremu nastavnog sata temeljenu na vlastitom iskustvu i rezultatima znanstvenih istraživanja vezanih za realizaciju te teme u nastavi, s naglaskom na teškoće učenika i miskoncepcije 5. steći praktične vještine u formativnom i sumativnom vrednovanju (usmeno, pisano, praktično, projekti, portfolio)
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Priprema za nastavu – opći model izveden iz didaktičkih teorija i modela poučavanja te preporuka vodećih teorija učenja. Prema tom modelu izrađuju se pripreme za ključne teme poput proceduralnog programiranja, objektnog programiranja, struktura podataka, baza podataka, operacijskih sustava, programskih paketa za obradu teksta, tablična računanja, izradu web stranica i sl. (0+0+22) 2. Zadaci s informatičkih natjecanja za učenike srednje škole (Infokup, HSIN..). Analiza zadataka, ulaznih i izlaznih podataka, varijabli i njihove namjene, izbora reprezentacije zadatka učenicima, simulacija izvršavanja algoritma papir-olovka, izbor prikladnih struktura podataka i algoritama, analiza efikasnosti, traženje alternativnih rješenja, dekompozicija složenih zadataka u podprobleme, izbor testnih primjera. Kodiranje u Pythonu (0+15+8)
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	1. ispit - zadaci s informatičkih natjecanja učenika srednje škole 2. 12 sati sudjelovanja u nastavi SŠ, 3 pisane pripreme, 1 probni i 1 ispitni sat 3. redovito tjedno rješavanje zadataka s informatičkih natjecanja za učenike SŠ. 4. Esej o održanoj nastavnoj praksi u srednjoj školi

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		Domaće zadaće	1.4
	Esej	0.2	Seminarski rad		Ispitna predavanja	0.4
	Kolokviji		Usmeni ispit			
	Pismeni ispit		Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	1. Hospitacija u srednjoj školi, pripreme, ogledni sat - 60%. 2. Ispit - 40% Studenti koji redovito izvršavaju tjedne obveze (rješavanje 2-3 zadatka) i koji su aktivni na seminaru mogu se osloboditi ispita.

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Udžbenici informatike za srednju školu.	5	
	Zadaci s informatičkih natjecanja za učenike srednjih škola (Infokup, HSIN,...)		da
Dopunska literatura			
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	1. studentske ankete 2. povratne informacije mentora iz srednjih škola 3. povratne informacije sa stručnih ispita 4. Esej studenata 5. Samoprocjena		
Ostalo (prema mišljenju predlagatelja)			

Naziv kolegija	Izvannastavne i izvanškolske aktivnosti					
Kod	PMS173	Godina studija	2.			
Nositelj/i kolegija	Antonija Bašić Radelja, pred.	Bodovna vrijednost (ECTS)	2.0			
Suradnici		Način izvođenja nastave (broj sati u semestru)	P	S	V	T
			15	15	0	0
Status kolegija	Izborni	Postotak primjene e-učenja	0%			

Opis kolegija	
Ciljevi kolegija	Osvijestiti važnost izvannastavnih i izvanškolskih aktivnosti za razvoj interesa djece, zadovoljenja osobnih potreba i motiva te omogućavanja profesionalnog usmjeravanja. Pozicionirati kod studenata izvannastavne i izvanškolske aktivnosti kao prostor velikih mogućnosti napredovanja nastavnika i učenika kroz zajedničko djelovanje u dobrovoljno odabranim aktivnostima.
Uvjeti za upis kolegija i ulazne kompetencije potrebne za kolegij	Položena Pedagogija (79121)i Didaktika (79107)
Ishodi učenja	1. Osposobljenost za planiranje, programiranje i izvođenje INA/IŠA 2. Uočavanje dispozicija, potencijala te moguće darovitosti učenika 3. Ospobljenost za praćenje i vrednovanje učeničkih postignuća i nagnuća 4. Shvaćanje biti slobodnog stvaralačkog rada te osobitosti darovitih 5. Identificirati područja i mogućnosti rada nastavnika kroz izvanškolske i izvannastavne sadržaje 6. Raspraviti kompetencije potrebne za planiranje aktivnosti INA - IŠA
Sadržaj kolegija detaljno razrađen prema satnici nastave	1.Etimološki i sadržajno srodni pojmovi 2.Uzroci, razlozi i uvjeti uvođenja INA–IŠA 3.Funkcije INA–IŠA 4.Zadaci INA–IŠA 5.Načela organizacije INA–IŠA 6.Vrste INA–IŠA s obzirom na sadržaj 7.Organizacijski oblici izvođenja INA-IŠA 8./9. Stvaralaštvo 10./11. Stvaralaštvo i mišljenje 12./13. Stvaralački čin – procesi i dimenzije 14./15.Stvaralaštvo i odgoj
Vrste izvođenja nastave	☑ Predavanja ☑ Seminari ☐ Vježbe ☐ On line u cijelosti ☐ Mješovito e-učenje	☐ Terenska nastava ☐ Samostalni zadaci ☐ Multimedija ☐ Laboratorij ☐ Mentorski rad	☐ ☐ ☐ ☐			
Obveze studenata	• redovito prisustvovati nastavi • aktivno sudjelovati na nastavi • samostalna priprema i izlaganje seminara					

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	0.5		
	Kolokviji		Usmeni ispit	0		
	Pismeni ispit	1	Projekt			

Ocjenjivanje i vrjednovanje rada studenata tijekom nastave i na završnom ispitu	Pismeni ispit – 50% Prisustvo, seminar - 50%

Obvezna literatura (dostupna u knjižnici i putem ostalih medija)	Naslov	Broj primjeraka u knjižnici	Dostupnost putem ostalih medija
	Previšić, V. (1987.): Izvannastavne i izvanškolske aktivnosti. Školske novine, Zagreb.		
	Suhodolski, B. (1989.): Permanentno obrazovanje i stvaralaštvo. Školske novine, Zagreb.		dostupno
	Livazović, G. (2018), Uvod u pedagogiju slobodnog vremena. Filozofski fakultet ; Hrvatska sveučilišna naklada		
Dopunska literatura	Rojek, C. i sur. (ur.) (2006), A handbook of leisure studies. Basingstoke/New York: Palgrave Macmillan. (odabrana poglavlja) Dječja prava i slobodno vrijeme (2010). Zagreb: Pravobranitelj za djecu.		
Načini praćenja kvalitete koji osiguravaju stjecanje utvrđenih ishoda učenja	Evaluacijske liste, ispitna postignuća. Evidencija o nazočnosti na predavanjima i seminarima. Aktivnost u seminarskoj raspravi i i vođenje refleksivnog dnevnika. Rezultati na kolokvijima i pismenom ispitu. Zajednička rasprava o načinima unapređenja rada.		
Ostalo (prema mišljenju predlagatelja)			

3. PRILOZI

3.1. Ishodi učenja studijskog programa

1. Planirati, organizirati i realizirati nastavu informatike u osnovnim i srednjim školama primjenjujući načela nastave informatike, koristeći različite nastavne strategije, metode i oblike rada.
2. Pratiti istraživanja u edukaciji informatike i implementirati ih u program.
3. Odrediti ishode učenja za pojedine nastavne cjeline, nastavne teme i zadatke te metodički pravilno artikulirati nastavni sat iz informatike
4. Izraditi pisanu pripremu za izvođenje nastavnog sata iz informatike.
5. Osmisliti, izraditi i primijeniti različita nastavna sredstva i pomagala.
6. Stručno i metodički korektno izvesti nastavni sat iz informatike u osnovnoj i srednjoj školi.
7. Vrednovati nastavu informatike, rad učenika i nastavnika, te napraviti samoevaluaciju.
8. Uočiti mogućnosti pedagoškog djelovanja i razlikovati temeljne pedagoške procese.
9. Interpretirati i primijeniti glavne sadržaje psihologije odgoja i obrazovanja.
10. Objasniti širi društveni kontekst odgoja i obrazovanja (vrijednosti, odnose, funkcije, ne/jednakosti, važnost odgoja-obrazovanja, procese koji utječu na uspjeh učenika, devijacije i sl.).
11. Primijeniti znanstvene metode analize i sinteze, indukcije i dedukcije, generalizacije i specijalizacije, te analogije na informatičke sadržaje kao i u nastavnom procesu.
12. Analizirati, rješavati i pojasniti način rješavanja problema koristeći se argumentirano odabranom paradigmom, programskim jezikom i razvojnim okruženjem.
13. Analizirati vremensku i prostornu složenost algoritama, kreirati strukture podataka.
14. Oblikovati i vrednovati programe: utemeljene na numeričkim metodama, na teoriji grafova i teoriji automata, na bazama podataka te na principima umjetne inteligencije.
15. Formulirati izraze digitalne logike, oblikovati složenije logičke sklopove, predstaviti podatke na način razumljiv računalu, raščlaniti arhitekturu računala i argumentirano obrazložiti organizaciju i funkcije operacijskog sustava, računalnih mreža i komunikacijskih protokola,
16. Razumjeti i koristiti osnovnu matematičku terminologiju u komunikaciji, demonstrirati sposobnost rješavanja matematičkih problema, razumjeti i primijeniti znanja iz: osnova propozicijske i predikatne logike, teorije skupova, teorije grafova, teorije brojeva, numeričkih metoda i statistike.

3.2. Nastavnici na studijskom programu

Kolegij	Nastavnici i suradnici
Algoritmi u bioinformatici	Damir Vukičević
Analitika učenja u računalom potpomognutom procesu učenja i poučavanja	Ani Grubišić
Arhitekture neuronskih mreža	Goran Zaharija
Didaktika	Anna Alajbeg
Diplomski informatički rad	
Diplomski informatički seminar	
Informatička praksa	
Informatički menadžment	Marko Rosić
Inteligentni agenti	Lada Maleš
Istraživački rad u informatičkom obrazovanju	Monika Mladenović
Izvannastavne i izvanškolske aktivnosti	Antonija Bašić Radelja
Jezični procesori	Tonći Dadić Marko Rosić
Kineziološka aktivnost, fitness i zdravlje	Mladen Hraste
Kognitivna psihologija	Nikola Marangunić
Kognitivni sustavi	Branko Žitko
Matematičke osnove kriptografije	Marija Bliznac Trebješanin Borka Jadrijević
Metodički informatički seminar s nastavnom praksom I	Monika Mladenović
Metodički informatički seminar s nastavnom praksom II	Monika Mladenović
Metodika nastave informatike I	Monika Mladenović
Metodika nastave informatike II	Monika Mladenović
Metodologija dizajna interakcija	Andrina Granić
Metodologija istraživanja u obrazovanju	Anna Alajbeg
Modeliranje sustava programske podrške	Branko Žitko
Multimodalna interakcija i sučelja	Andrina Granić
Napredni modeli nastave	Antonija Bašić Radelja
Nasilje među djecom	Anna Alajbeg
Obrada prirodnog jezika	Branko Žitko
Osnove teorije strategijskih igara	Aljoša Šubašić
Paralelno programiranje	Tonći Dadić
Pedagogija	Anna Alajbeg
Pedagogija adolescencije	Anna Alajbeg
Pedagogija slobodnog vremena	Antonija Bašić Radelja
Podaci i etika	Marko Rosić
Poslovna analitika	Marko Rosić
Poučavanje učenika s posebnim potrebama	Antonija Bašić Radelja
Pozitivna psihologija	Nikola Marangunić
Programiranje mobilnih aplikacija	Goran Zaharija
Programske paradigme	Saša Mladenović Zoran Sambol

Projektiranje sustava za e-učenje	Ani Grubišić
Psihologija odgoja i obrazovanja I	Nikola Marangunić
Psihologija odgoja i obrazovanja II	Nikola Marangunić
Računalna grafika	Hrvoje Kalinić
Računalni vid	Barbara Džaja
Računalom podržani dizajn proizvoda (CAD)	Ivan Peko
Računarstvo u zajednici	Jelena Nakić
Raspodijeljene i nerelacijske baze podataka	Monika Mladenović
Raspodijeljeni sustavi	Marko Rosić
Robotika u nastavi	Barbara Džaja
Rudarenje podataka	Hrvoje Kalinić
Sigurnost računalnih učionica	Goran Zaharija
Sociologija odgoja i obrazovanja	Antonija Bašić Radelja
Strojno učenje	Saša Mladenović
Strojno učenje u bioinformatici i medicini	Dino Nejašmić
Stručno-pedagoška praksa	Anna Alajbeg
Sustavi E - učenja	Ani Grubišić
Tehnologije sustava E-učenja	Marko Rosić
Upravljanje razredom	Antonija Bašić Radelja
Uvod u geoinformacijske sustave	Vlado Dadić
Uvod u obradu prirodnog jezika	Branko Žitko
Uvod u podatkovnu znanost	Divna Krpan
Vizualizacija podataka	Goran Zaharija
Vizualni programski jezici i okružja	Divna Krpan
Znanstveno programiranje	Dino Nejašmić

Titula, ime i prezime nositelja	doc. dr. sc. Anna Alajbeg
Kolegij koji predaje na predloženom studijskom programu	Didaktika Metodologija istraživanja u obrazovanju Nasilje među djecom Pedagogija Pedagogija adolescencije Stručno-pedagoška praksa
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Ruđera Boškovića 33, 21000 Split
Telefon	+38521619316
E-mail	aalajbeg@pmfst.hr
Osobna web stranica	
Godina rođenja	28.02.1984.
Matični broj iz Upisnika znanstvenika	361306
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	Znanstveni suradnik, 17.12. 2017.
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	Docent, 14.7.2021.
Područje i polje izbora u znanstveno ili umjetničko zvanje	Društvene znanosti, polje pedagogija
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	Prirodoslovno-matematički fakultet
Datum zaposlenja	21.11.2019.
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	profesor
Područje rada	Znanstveno-nastavni rad
Funkcija	Docent, pročelnica Samostalne katedre za društveno-humanističke znanosti
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	doktorica znanosti
Ustanova	Učiteljski fakultet Sveučilišta u Zagrebu
Mjesto	Zagreb
Nadnevak	10.01.2017.
PODACI O USAVRŠAVANJU	
Godina	
Mjesto	
Ustanova	
Područje usavršavanja	
MATERINSKI I STRANI JEZICI	
Materinski jezik	Hrvatski jezik
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	Engleski jezik, 5

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	Jezični procesori Paralelno programiranje
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Plančićeva 8, 21000 SPLIT
Telefon	095 905 3400
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	prof. dr. sc. Ani Grubišić
Kolegij koji predaje na predloženom studijskom programu	Analitika učenja u računalom potpomognutom procesu učenja i poučavanja Projektiranje sustava za e-učenje Sustavi E - 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	doc. dr. sc. Nikola Marangunić
Kolegij koji predaje na predloženom studijskom programu	Kognitivna psihologija Pozitivna psihologija Psihologija odgoja i obrazovanja I Psihologija odgoja i obrazovanja II
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	nikola@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	298981
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	Istraživački rad u informatičkom obrazovanju Metodički informatički seminar s nastavnom praksom I Metodički informatički seminar s nastavnom praksom II Metodika nastave informatike I Metodika nastave informatike II 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	Informatički menadžment Jezični procesori Podaci i etika Poslovna analitika Raspodijeljeni sustavi Tehnologije sustava E-učenja
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	Antonija Bašić Radelja
Kolegij koji predaje na predloženom studijskom programu	Izvannastavne i izvanškolske aktivnosti Napredni modeli nastave Pedagogija slobodnog vremena Poučavanje učenika s posebnim potrebama Sociologija odgoja i obrazovanja Upravljanje razredom
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	abasic2@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	prof. dr. sc. Andrina Granić
Kolegij koji predaje na predloženom studijskom programu	Metodologija dizajna interakcija Multimodalna interakcija i sučelja
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	granic@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	182954
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. Divna Krpan
Kolegij koji predaje na predloženom studijskom programu	Uvod u podatkovnu znanost Vizualni programski jezici i okružja
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	Programske paradigme Strojno učenje
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	doc. dr. sc. Aljoša Šubašić
Kolegij koji predaje na predloženom studijskom programu	Osnove teorije strategijskih igara
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	aljsub@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	327176
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	Kognitivni sustavi Modeliranje sustava programske podrške Obrada prirodnog jezika Uvod u obradu 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. Hrvoje Kalinić
Kolegij koji predaje na predloženom studijskom programu	Računalna grafika Rudarenje podataka
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	izv. prof. dr. sc. Marija Bliznac Trebješanin
Kolegij koji predaje na predloženom studijskom programu	Matematičke osnove kriptografije
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Ruđera Boškovića 33
Telefon	
E-mail	marbli@pmfst.hr
Osobna web stranica	https://mapmf.pmfst.unist.hr/~marbli/
Godina rođenja	
Matični broj iz Upisnika znanstvenika	360634
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	izvanredni profesor, 17.9.2024.
Područje i polje izbora u znanstveno ili umjetničko zvanje	prirodne znanosti, matematika
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	Prirodoslovno-matematički fakultet
Datum zaposlenja	01.03.2017.
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	izvanredni profesor
Područje rada	prirodne znanosti, matematika
Funkcija	
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	doktorica znanosti
Ustanova	Prirodoslovno-matematički fakultet, Sveučilište u Zagrebu
Mjesto	Zagreb
Nadnevak	25.01.2018.
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. Borka Jadrijević
Kolegij koji predaje na predloženom studijskom programu	Matematičke osnove kriptografije
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	borka@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	164842
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. Jelena Nakić
Kolegij koji predaje na predloženom studijskom programu	Računarstvo u zajednici
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	jnakic@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	276001
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. Goran Zaharija
Kolegij koji predaje na predloženom studijskom programu	Arhitekture neuronskih mreža Programiranje mobilnih aplikacija Sigurnost računalnih učionica 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	doc. dr. sc. Barbara Džaja
Kolegij koji predaje na predloženom studijskom programu	Računalni vid Robotika u nastavi
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Valpovačka 11
Telefon	00385989123602
E-mail	bdzaja@pmfst.hr
Osobna web stranica	
Godina rođenja	07.01.1981.
Matični broj iz Upisnika znanstvenika	303552
Znanstveno ili umjetničko zvanje i datum posljednjega izbora	doktor znanosti,
Znanstveno-nastavno, umjetničko-nastavno ili nastavno zvanje i datum posljednjega izbora	profesor stručnih studija
Područje i polje izbora u znanstveno ili umjetničko zvanje	tehničke znanosti, elektrotehnika
PODACI O SADAŠNJEM ZAPOSLENJU	
Ustanova zaposlenja	Sveučilište u Splitu
Datum zaposlenja	20.02.2007.
Naziv radnoga mjesta (profesor, istraživač, suradnik i sl.)	profesor
Područje rada	nastava
Funkcija	nastava
PODACI O ŠKOLOVANJU - Najviši postignuti stupanj	
Zvanje	doktor znanosti
Ustanova	Fakultet elektrotehnike, strojarstva i brodogradnje
Mjesto	Split
Nadnevak	22.01.2013.
PODACI O USAVRŠAVANJU	
Godina	2009.
Mjesto	Oxford, UK
Ustanova	Sveučilište u Oxfordu, Odjel za inženjersku znanost
Područje usavršavanja	Znanstveno usavršavanje u području računalnog vida
MATERINSKI I STRANI JEZICI	
Materinski jezik	Hrvatski
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	Engleski (5)
Strani jezik i poznavanje jezika na ljestvici od 2 (dovoljno) do 5 (izvrsno)	Španjolski (5)

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. Ivan Peko
Kolegij koji predaje na predloženom studijskom programu	Računalom podržani dizajn proizvoda (CAD)
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	ipeko@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	356845
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. Lada Maleš
Kolegij koji predaje na predloženom studijskom programu	Inteligentni agenti
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Trondheimska 9, Split
Telefon	0915124259
E-mail	lada@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	prof. dr. sc. Vlado Dadić
Kolegij koji predaje na predloženom studijskom programu	Uvod u geoinformacijske sustave
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	vdadic@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	prof. dr. sc. Damir Vukičević
Kolegij koji predaje na predloženom studijskom programu	Algoritmi u bioinformatici
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	Zoran Sambol
Kolegij koji predaje na predloženom studijskom programu	Programske paradigme
OPĆE INFORMACIJE O NOSITELJU	
Adresa	Sedam Kaštela 6, 21000 Split
Telefon	+385 98 781614
E-mail	zsambol@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	prof. dr. sc. Mladen Hraste
Kolegij koji predaje na predloženom studijskom programu	Kineziološka aktivnost, fitness i zdravlje
OPĆE INFORMACIJE O NOSITELJU	
Adresa	
Telefon	
E-mail	mhraste@pmfst.hr
Osobna web stranica	
Godina rođenja	
Matični broj iz Upisnika znanstvenika	210025
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	