

Sveučilište u Rijeci
Fakultet informatike i digitalnih tehnologija
Radmile Matejčić 2, Rijeka

Akadska godina 2026./2027.

OSNOVNI PODATCI O KOLEGIJU		
Naziv kolegija	Uvod u analizu i vizualizaciju podataka	
Studijski program	Sveučilišni prijediplomski studij Informatika	
Status kolegija	obvezni za modul IS	
Semestar	6.	
Bodovna vrijednost i nastavno opterećenje	Broj ECTS bodova	5
	Broj sati (P+V+S)	30+30+0
Nositelj/ica kolegija	Izv. prof. dr. sc. Lucia Načinović Prskalo	
E-mail	lnacinovic@uniri.hr	
Ured	O-513	
Vrijeme konzultacija	Ponedjeljkom od 12:00 do 13:00 uz prethodnu najavu e-mailom	
Asistent/ica		
E-mail		
Ured		
Vrijeme konzultacija		
DETALJNI OPIS KOLEGIJA		
<i>Ciljevi kolegija</i>		
Ciljevi kolegija su usvajanje temeljnih znanja u postupcima analize i vizualizacije podataka, upoznavanje s postupcima prikupljanja i prilagodbe podataka, izvršavanje različitih postupaka organiziranja i upravljanja nad skupovima podataka, primjena osnovnih statističkih metoda u svrhu analize podataka, osnovnih grafičkih metoda istraživačke analize te različitih metoda vizualizacije podataka.		
<i>Uvjeti za upis kolegija</i>		
Nema uvjeta za upis kolegija.		
<i>Očekivani ishodi učenja za kolegij</i>		
Očekuje se da nakon izvršavanja svih programom predviđenih obveza studenti budu sposobni:		
11. Opisati osnovne pojmove, faze i postupke u procesu analize i vizualizacije podataka.		
12. Primijeniti metode osnovne deskriptivne statistike nad različitim skupovima podataka.		
13. Prikupiti, prilagoditi i očistiti skupove podataka iz različitih vrsta izvora i datoteka različitih formata.		
14. Izvršiti operacije organiziranja i upravljanja nad skupovima podataka kao što su odabiranje, spajanje, preoblikovanje, filtriranje, sortiranje, grupiranje, agregiranje podataka.		
15. Primijeniti osnovne statističke metode u svrhu analize skupa podataka		
16. Primijeniti osnovne grafičke metode istraživačke analize podataka nad različitim skupovima podataka.		
17. Odabrati i primijeniti odgovarajuću vrstu grafikona ili prikaza za određene skupove podataka radi boljeg određivanja i razumijevanja problema.		
<i>Sadržaj kolegija</i>		
Na kolegiju se obrađuju sljedeći sadržaji:		

- Pojmovi podaci, analiza podataka i vizualizacija podataka, povijesni pregled, primjena analize i vizualizacije podataka. (I1)
- Rad s različitim strukturama podataka – vremenski nizovi podataka, podatkovni okviri, indeksirani objekti. (I1, I2, I3, I4)
- Primjena osnovne deskriptivne statistike nad skupovima podataka – mjere centralnosti, disperzija, korelacija i slično. (I1, I2)
- Prikupljanje i čišćenje podataka iz različitih tipova izvora, različiti formati datoteka skupova podataka. (I1, I3, I4)
- Primjena različitih operacija organiziranja i upravljanja nad skupovima podataka - transformiranje, biranje, spajanje, preoblikovanje, filtriranje, sortiranje, grupiranje, agregiranje podataka i slično. (I1, I3, I4)
- Osnovne statističke metode primijenjene u postupku analize podataka (testiranje hipoteze, linearni modeli, višestruki faktori, analiza varijance i slično). (I1, I5)
- Osnovne metode istraživačke analize podataka. (I1, I3, I4, I5, I6)
- Vizualizacija podataka – osnovna načela dobrih grafikona i prikaza. (I1, I6, I7)
- Primjena različitih metoda vizualizacije te vrsta grafikona i prikaza na različite skupove podataka. (I1, I3, I4, I5, I6, I7)

Način izvođenja nastave

☒ predavanja	☒ samostalni zadaci
☒ seminari i radionice	☒ multimedija i mreža
☒ vježbe	☒ laboratorij
☒ obrazovanje na daljinu	☐ mentorski rad
☐ terenska nastava	☒ problemska nastava
☐ učenje temeljeno na izazovima iz stvarnoga svijeta	☐ ostalo _____

Komentari

Obvezna literatura (u trenutku prijave prijedloga studijskog programa)

1. Grus, J.: Data Science from Scratch, First Principles with Python 1st Edition, O'Reilly Media, 2015.
2. Chen, C., Härdle, W., Unwin A.: Handbook of Data Visualization, Springer, 2008.
3. McKinney, W.: Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython 2nd Edition, O'Reilly Media, 2017.
4. Embarak, O.: Data Analysis and Visualization Using Python, Apress, 2018.
5. VanderPlas, J.: Python Data Science Handbook, O'Reilly Media, 2017.
6. Skripte, prezentacije i ostali materijali za učenje dostupni u e-kolegiju

Dopunska literatura (u trenutku prijave prijedloga studijskog programa)

1. Introduction to Data Analysis Handbook, Migrant & Seasonal Head Start Technical Assistance Center, AED/TAC, 2006.
2. Downey, B. A.: Think Stats, Exploratory Data Analysis in Python, Green Tea Press, Needham, 2014.
3. Stanton, J.: An Introduction to Data Science, Syracuse University, 2013.
4. Madhavan, S. Mastering Python for Data Science, Packt Publishing, 2015.
5. Data Science & Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data, John Wiley & Sons, Inc, Indianapolis, 2015.

Načini praćenja kvalitete koji osiguravaju stjecanje izlaznih znanja, vještina i kompetencija

Predviđa se periodičko provođenje evaluacije s ciljem osiguravanja i kontinuiranog unapređivanja kvalitete nastave i studijskog programa (u okviru aktivnosti Odbora za osiguravanje i unaprjeđivanje kvalitete Fakulteta informatike i digitalnih tehnologija). U zadnjem tjednu nastave provodit će se anonimna evaluacija kvalitete održane nastave od strane studenata. Provest će se i analiza uspješnosti studenata na kolegiju (postotak studenata koji su položili kolegij i prosjek njihovih ocjena).

Jezik izvođenja nastave Hrvatski jezik

Mogućnost izvođenja na stranom jeziku Da

OBVEZE, PRAĆENJE RADA I VREDNOVANJE STUDENATA

Konstruktivno povezivanje

Vrsta aktivnosti	ECTS bodovi			Ishodi učenja	Specifična aktivnost	Metoda procjenjivanja	Bodovi (max.)
	Ukupno	Praktičan rad	Timski projektni rad				
Pohađanje nastave i aktivnosti u nastavi	2	1	1	I1-I7	Prisutnost studenata	Popisivanje (evidencija)	0
Projektni zadaci	1,5	1,5	1,5	I2-I7	3 projektna zadatka	0-10 za prvi, 0-15 za drugi i 0-20 bodova za treći projektni zadatak ovisno o stupnju točnosti i potpunosti	45
Kontinuirana provjera znanja	0,5	0	0	I1	1 provjera znanja (kolokvij)	0-25 bodova za provjeru, ovisno o stupnju točnosti i potpunosti	25
Ispit	1	1	1	I1-I7	Izrada i obrana praktičnog seminarskog rada	0-30 bodova za seminarski rad, ovisno o potpunosti i točnosti izrade prema zadanim uputama	30
UKUPNO	5	3,5	3,5				100

Obveze i vrednovanje studenata – puna nastavna satnica

1. Pohađanje nastave i aktivnosti u nastavi

Nastava se izvodi u hibridnom modelu, kombinacijom izravne, učioničke nastave i *online* oblika nastave uz pomoć sustava za e-učenje prema rasporedu koji je prikazan tablicom u nastavku. Studenti su dužni koristiti sustav za e-učenje Merlin (<https://moodle.srce.hr/>) gdje će se objavljivati informacije o kolegiju, materijali za učenje, zadaci za vježbu, zadaci za domaće zadaće i slične aktivnosti te obavijesti vezane za izvođenje nastave (putem foruma Obavijesti).

Studenti koji studiraju u punoj nastavnoj satnici (u redovitom i izvanrednom statusu) dužni su redovito pohađati nastavu prema predviđenom rasporedu, aktivno sudjelovati u aktivnostima tijekom izvođenja nastave te izvršavati aktivnosti kolegija u okviru sustava Merlin koje će nastavnici najavljivati putem foruma.

2. Projektni zadaci

Tijekom semestra, studenti će dobiti ukupno 3 projektna zadatka. Dinamika rješavanja projektnih zadataka bit će unaprijed zadana. Prvi projektni zadatak nosi 10 bodova, drugi 15, a treći 20 ocjenskih bodova. Za ove aktivnosti nema

praga prolaznosti. Ukupno student iz projektnih zadataka tijekom semestra može skupiti maksimalno 45 ocjenskih bodova.

3. Kontinuirana provjera znanja

Tijekom semestra, na unaprijed definiranom roku, provjeravat će se usvojenost sadržaja kolegija putem provjere znanja (kolokvija) na kojoj je moguće prikupiti maksimalno 25 ocjenskih bodova. Da bi ostvario pravo pristupa ispitu, student na provjeri (kolokviju) mora ostvariti **barem 50% ocjenskih bodova** (12,5 bodova). U zadnjem tjednu nastave organizirati će se popravni kolokvij za studente koji su imali manje od 50% bodova ili su izostali s kolokvija iz opravdanih razloga. U slučaju da student ne može prisustvovati kolokviju iz opravdanih razloga dužan je javiti se nastavniku i donijeti ispričnicu najkasnije tjedan dana nakon održavanja kolokvija.

4. Ispit (problemska nastava)

Ispit se temelji na problemskoj nastavi/metodi. Studentima se zadaje konkretan problemski zadatak, pitanje, dvojba ili problemska situacija koju trebaju analizirati te, primjenjujući stečena znanja i koristeći dostupne izvore, predložiti i obrazložiti odgovarajuće rješenje. Pri vrednovanju se uzima u obzir razumijevanje problema, primjena stečenih znanja, argumentiranost odabranog pristupa te sposobnost kritičkog razmatranja i obrazlaganja rješenja. Ukupno student na ispitu može skupiti 30 ocjenskih bodova, a prag prolaznosti ispita je 50% (15 ocjenskih bodova).

Ocjenjivanje

Kontinuiranim radom tijekom semestra na prethodno opisani način studenti mogu ostvariti najviše 70 ocjenskih bodova, a da bi mogli pristupiti ispitu moraju ostvariti 50% i više ocjenskih bodova (minimalno 35) koje je bilo moguće steći kroz kontinuirano vrednovanje, uz zadovoljenje dodatnih uvjeta propisanih ovim izvedbenim planom.

Ispit nosi udio od maksimalno 30 ocjenskih bodova. Na ispitu student mora ostvariti barem 50% od ocjenskih bodova koje je bilo moguće steći na ispitu kako bi ostvario ECTS bodove kolegija odnosno kako bi uspješno položio kolegij.

Ako je ispit prolazan, konačnu ocjenu na kolegiju čini zbroj ocjenskih bodova postignutih u kontinuiranom praćenju i vrednovanju i ocjenskih bodova postignutih na ispitu. U suprotnom, student ima pravo pristupa ispitu još 2 puta (ukupno do 3 puta tijekom akademske godine).

Konačna ocjena ostvarenosti ishoda učenja na kolegiju

Ocjena ostvarenosti ishoda učenja na kolegiju donosi se kako slijedi:

- za ostvarenih 90 do 100% ocjenskih bodova ocjena izvrstan (5), slovna ocjena A,
- za ostvarenih 75 do 89% ocjenskih bodova ocjena vrlo dobar (4), slovna ocjena B,
- za ostvarenih 60 do 74% ocjenskih bodova ocjena dobar (3), slovna ocjena C,
- za ostvarenih 50 do 59% ocjenskih bodova ocjena dovoljan (2), slovna ocjena D,
- za ostvarenih do 49% ocjenskih bodova ocjena nedovoljan (1), slovna ocjena F.

Sve granične vrijednosti postotaka navedene iznad uključive su za pripadnu ocjenu.

Ispitni termini

15.06.2027.
29.06.2027.
02.09.2027.
09.09.2027.

SATNICA IZVOĐENJA NASTAVE – ljetni (VI.) semestar akademske godine 2026./2027.

Nastava će se na kolegiju odvijati u ljetnom semestru prema sljedećem rasporedu:

predavanja: petkom 10:00 – 11:30 u učioni O-359

vježbe: petkom 12:00 – 13:30 u učioni O-359

Tj.	Datum	Prostor ¹	Tema	Nastava ²	Izvođač(i)
1.	5.3.2027.	O-359	Uvod u kolegij	P1	Lucia Načinović Prskalo
1.	5.3.2027.	O-359		V1	Lucia Načinović Prskalo
2.	12.3.2027.	O-359	Analiza podataka i vizualizacija podataka, povijesni pregled, primjena analize i vizualizacije podataka.	P2	Lucia Načinović Prskalo
2.	12.3.2027.	O-359	Python NumPy	V2	Lucia Načinović Prskalo
3.	19.3.2027.	O-359	Rad s različitim strukturama podataka – vremenski nizovi podataka, podatkovni okviri, indeksirani objekti.	P3	Lucia Načinović Prskalo
3.	19.3.2027.	O-359	Python NumPy	V3	Lucia Načinović Prskalo
4.	26.3.2027.		PRAZNIK		
5.	2.4.2027.	O-359	Primjena osnovne deskriptivne statistike nad skupovima podataka – mjere centralnosti, disperzija, korelacija i slično.	P4	Lucia Načinović Prskalo
5.	2.4.2027.	O-359	Python Pandas	V4	Lucia Načinović Prskalo
6.	9.4.2027.	online	Prikupljanje i čišćenje podataka iz različitih tipova izvora, različiti formati datoteka skupova podataka.	P5	Lucia Načinović Prskalo
6.	9.4.2027.	online	Python Pandas	V5	Lucia Načinović Prskalo
7.	16.4.2027.	online	Primjena različitih operacija organiziranja i upravljanja nad skupovima podataka - transformiranje, biranje, spajanje, preoblikovanje, filtriranje, sortiranje, grupiranje, agregiranje podataka i slično.	P6	Lucia Načinović Prskalo
7.	16.4.2027.	online	Python Matplotlib	V6	Lucia Načinović Prskalo
8.	23.4.2027.	O-359	Obrana 1. projektnog zadatka	P7	Lucia Načinović Prskalo
8.	23.4.2027.	O-359		V7	Lucia Načinović Prskalo
8.	30.4.2027.	O-359	Osnovne statističke metode primijenjene u postupku analize podataka (testiranje hipoteze, linearni modeli, višestruki faktori, analiza varijance i slično).	P8	Lucia Načinović Prskalo
8.	30.4.2027.	O-359	Python Matplotlib	V8	Lucia Načinović Prskalo
9.	7.5.2027.	O-359	Obrana 2. projektnog zadatka	P9	Lucia Načinović Prskalo
9.	7.5.2027.	O-359		V9	Lucia Načinović Prskalo
10.	14.5.2027.	online	Osnovne metode istraživačke analize podataka.	P10	Lucia Načinović Prskalo

¹ Upisati broj prostorije ili online

² Upisati P za predavanja ili V za vježbe

10.	14.5.2027.	online	Seaborn	V10	Lucia Načinović Prskalo
11.	21.5.2027.	O-359	Kolokvij	P11	Lucia Načinović Prskalo
11.	21.5.2027.	O-359		V11	Lucia Načinović Prskalo
12.	28.5.2027.		PRAZNIK		
13.	4.6.2027.	O-359	Vizualizacija podataka – osnovna načela dobrih grafikona i prikaza. Primjena različitih metoda vizualizacije te vrsta grafikona i prikaza na različite skupove podataka.	P12	Lucia Načinović Prskalo
13.	4.6.2027.	O-359	Tableau	V12	Lucia Načinović Prskalo
14.	11.6.2027.	O-359	Obrana 3. projektnog zadatka.	P13	Lucia Načinović Prskalo
14.	11.6.2027.	O-359	Nadoknada obrana projektnih aktivnosti, evaluacija kolegija. Popravni kolokvij.	V13	Lucia Načinović Prskalo