Faculty of Medicine in Rijeka

Curriculum
2026/2027

For course

Zdravstvena statistika

Study program:	**Sanitarno inženjerstvo (R)** University undergraduate study
Department:	**Department of Medical Physics and Biophysics**
Course coordinator:	**prof. dr. sc. Žauhar Gordana, prof. fizike i kemije**
Year of study:	**2**
ECTS:	**3.5**
Incentive ECTS:	**0 (0.00%)**
Foreign language:	**No**

Course information:

Zdravstvena statistika je obvezni kolegij na 2. godini Preddiplomskog sveučilišnog studija Sanitarno inženjerstvo, sa 20 sati predavanja i 25 sati vježbi. Cilj je kolegija osposobiti studenta za sustavni pristup organizaciji i obradi podataka, informacija i znanja u medicini i zdravstvu. Tijekom izvedbe nastave kolegija studenti će usvojiti znanja o planiranju istraživanja, o prikupljanju podataka i mjerenjima te o obradi tih podataka i njihovom prikazu. Time bi se ostvarila svrha nastave, a to je razvoj kulture kvantitativnog pristupa u prikupljanju, analizi i interpretaciji podataka u biološkim i medicinskim znanostima, što je uvjet stručnog djelovanja, kritičnog praćenja znanstvene i stručne literature i sudjelovanja u njenom kreiranju s aspekta egzaktnosti opažanja i zaključivanja.

Cilj kolegija je osposobiti studenta za sustavni pristup organizaciji i obradi podataka, informacija i znanja u medicini i zdravstvu. Tijekom izvedbe nastave kolegija studenti će usvojiti znanja o planiranju istraživanja, o prikupljanju podataka i mjerenjima te o obradi tih podataka i njihovom prikazu. Time bi se ostvarila svrha nastave, a to je razvoj kulture kvantitativnog pristupa u prikupljanju, analizi i interpretaciji podataka u biološkim i medicinskim znanostima, što je uvjet stručnog djelovanja, kritičnog praćenja znanstvene i stručne literature i sudjelovanja u njenom kreiranju s aspekta egzaktnosti opažanja i zaključivanja.

[Ishodi učenja]:

A. KOGNITIVNA DOMENA – ZNANJE

1. definirati i izračunati osnovne parametre za prikaz numeričkih nizova (srednje vrijednosti, mjere varijabilnosti)
2. prepoznati u kojim je situacijama prikladna upotreba pojedinih statističkih testova.

B. PSIHOMOTORIČKA DOMENA – VJEŠTINE

1. planirati i primijeniti odgovarajuće statističke postupke i metode te interpretirati dobivene rezultate

primijeniti jedan statistički računalni programski paket za obradu, analizu i prikaz rezultata mjerenja.

List of assigned reading:

1. Boris Petz, Vladimir Kolesarić, Dragutin Ivanec: Petzova statistika, Naklada Slap, Jastrebarsko, 2012.

List of optional reading:

1. Triola M.M, Triola M.F, Biostatistics for the Biological and Health Sciences, Pearson, 2018. Dawson B, Trapp R.G,
2. „Basic & Clinical Biostatistics “, McGraw-Hill, 5ed., 2020. (e-udžbenik)https://accessmedicine.mhmedical.com/Book.aspx?bookid=2724)

Method of examination.:

II. ZAVRŠNI ISPIT (DO 30 BODOVA)

Završni ispit je u pravilu pismeni i sastoji se od 29 pitanja. Svako pitanje ili tvrdnja ima pet ponuđenih odgovora, od kojih više njih može biti točnih. Uspješno položen ispit je onaj na kojem je točno riješeno najmanje 50% testa (15 točnih odgovora).

Transformacijska skala iz točno odgovorenih pitanja u bodove na završnom ispitu je sljedeća:

broj točnih odgovora na testu	ocjenski bodovi
15	15
16	16
17	17
18	18
19	19
20	20
21	21
22	22
23	23
24	24
25	25
26	26
27	27
28	28
29	30

III. Konačna ocjena je zbroj ECTS ocjene ostvarene tijekom nastave i na završnom ispitu:

Konačna ocjena	
A (90-100%)	izvrstan (5)
B (75-89,9%)	vrlo-dobar (4)
C (60-74,9%)	dobar (3)
D (50-59,9%)	dovoljan (2)
F (studenti koji su tijekom nastave ostvarili manje od 30 bodova ili nisu položili završni ispit)	nedovoljan (1)

Termini održavanja testova tijekom nastave:

Parcijalni ispit: 18.01.2027. predavaonica P2, 14:00 - 15:00

Kolokvij: 22.01.2027. predavaonica P9, 11:30 - 15:00

Termini održavanja završnih ispita:

1. rok 12.02.2027.

2. rok 26.02.2027.

3. rok 02.07.2027.

4. rok 03.09.2027.

Curriculum:

Lectures list (with titles and explanation):

P1 Uvod. Važnost poznavanja statistike u stručnom i znanstvenom radu. Vrste statističkih podataka.

- Upoznati se s ciljem kolegija.
- Dati studentima informacije o tome gdje se i u kojem obliku organizira nastava, koji je potreban pribor, upute o pohađanju i pripremi za nastavu, te obvezama studenata.
- Razlikovati vrste podataka, odnosno varijabli i odgovarajućih mjernih ljestvica

P2 Grafički i tabelarni prikaz kvalitativnih podataka

- Analiza, interpretacija i prezentacija tabličnih podataka
- Naučiti studente kako napraviti dobar prikaz podataka u tablici
- Napraviti grafički prikaz kvalitativnih podataka kružnim i stupčastim dijagramom

P3 Grafički prikaz kvantitativnih podataka.

- Znati grupirati numeričke podatke u razrede te izraditi prikaz podataka poligonom i histogramom frekvencija.
- Znati napraviti grafički prikaz empirijske distribucije
- Znati izvršiti testiranje raspodjele na normalnost (Kolmogorov-Smirnov test) uz pomoć računala
- Opis i prepoznavanje osnovnih teorijskih raspodjela podataka

P4 Mjere centralne tendencije

- Znati odrediti osnovne mjere centralne tendencije: aritmetičku sredinu, medijan i mod
- Odabir primjerenih mjera centralne tendencije ovisno o vrsti raspodjele podataka

P5 Mjere varijabilnosti podataka

- Znati odrediti osnovne mjere varijabilnosti podataka: raspon, standardnu devijaciju, varijancu, koeficijent varijabilnosti, kvartile, interkvartilni raspon
- Odabir primjerenih mjera varijabilnosti pri opisu podataka ovisno o vrsti empirijske raspodjele podataka

P6 Normalna raspodjela

- Opis i prepoznavanje osnovnih vrsta raspodjela podataka: binomna, normalna, Poissonova
- Opisati normalnu raspodjelu.
- Definirati svojstva normalne raspodjele.
- Znati odrediti položaj pojedinog rezultata u normalnoj raspodjeli pomoću z-vrijednosti
- Poznavati i znati odrediti centile i decili

P7 Populacija i uzorak

- Razlikovati populaciju i uzorak
- Znati primijeniti postupak generalizacije o populaciji na osnovi uzorka
- Izračunavanje granica intervala pouzdanosti

P8 Testiranje razlike aritmetičkih sredina između dvije velike nezavisne skupine

- Razlikovati zavisne i nezavisne uzorke
- Razlikovati i znati odrediti kad se koriste parametrijski, a kad neparametrijski testovi
- Poznavanje teorije testiranja hipoteza i određivanje signifikantnosti razlike
- Znati testirati razliku aritmetičkih sredina između dvije velike nezavisne skupine Studentovim t-testom
- Znati testirati razliku aritmetičkih sredina između dvije male nezavisne skupine Studentovim t-testom

P9 Testiranje razlike aritmetičkih sredina između malih nezavisnih skupina

P10 Korelacijska analiza

- Analiza povezanosti kvantitativnih obilježja
- Poznavati postupak izračunavanja Pearsonova koeficijenta korelacije
- Opis i primjena modela jednostavne linearne regresije
- Znati odrediti jednadžbu pravca regresije

P11 Regresijska analiza

P12 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina

- Znati kako se provodi testiranje razlike aritmetičkih sredina između dviju zavisnih skupina kvantitativnih podataka primjenom parametrijskog testa

P13 Višestruko testiranje. Analiza varijance.

- Poznavati postupak testiranja razlike između više nezavisnih skupina kvantitativnih podataka parametrijskim testom (ANOVA)
- Znati čemu služe i kada se koriste naknadni ili tzv. post-hoc testovi

P14 Analiza i usporedba kvalitativnih podataka testom razlike proporcija

- Znati izračunati proporcije i standardnu pogrešku proporcija
- Poznavati postupak testiranja razlike proporcija nezavisnih uzoraka
- Poznavati postupak testiranja razlike proporcija zavisnih uzoraka

P15 Hi-kvadrat test

- Prikaz i analiza tablica kontingencije
- Usporedba kvalitativnih podataka Hi-kvadrat testom
- Razlikovati i znati usporediti dvije zavisne skupine kvalitativnih podataka McNemarovim testom

P16 McNemarov test

P17 Izbor iz neparametrijskih testova.

- Upoznati osnovne neparametrijske testove za usporedbu nezavisnih i zavisnih skupina (Mann-Whitneyjev test, Wilcoxonov test,...)
- Analiza povezanosti i izračun Spearmanovog koeficijenta korelacije

P18 Ocjena valjanosti testova. Dijagnostička točnost

- Znati izračunati kvantitativne pokazatelje dijagnostičke točnosti kao što su:
- osjetljivost, specifičnost, pozitivnu prediktivnu vrijednost, negativnu prediktivnu vrijednost
- Poznavati postupak ROC-analize

P19 Pismena provjera znanja

- Napraviti pismenu provjeru znanja studenata o primjeni odgovarajućih statističkih testova za testiranje razlika, odnosno povezanosti podataka

P20 Završno predavanje i priprema za ispit

Practicals list (with titles and explanation):

V1-2 Upisivanje podataka u program za obradu

- Prepoznavanje različitih tipova podataka i pravilno korištenje skala mjerenja
- Upoznati se sa osnovama korištenja programske podrške za analizu podataka (Statistica)
- Znati napraviti pripremu, učitavanje i upisivanje podataka

V3-4 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.

- Znati kako napraviti grafički prikaz kvalitativnih podataka (kružni i stupčasti dijagram)
- Znati napraviti linijski i kružni vremenski dijagram

V5 Deskriptivna statistika. Grafički prikaz empirijske raspodjele

- Analiza parametara empirijske distribucije.
- Znati izračunati mjera centralne tendencije i mjera varijabilnosti podataka uz pomoć računala.
- Procjena parametara distribucije populacije temeljem uzorka – računanje standardne pogreške i granica intervala pouzdanosti uz pomoć računala
- Znati napraviti grafički prikaz kvantitativnih podataka
- Grupirati rezultate u razrede radi izrade poligona i histograma frekvencije

V6 Provjravanje normalnosti raspodjele podataka uz pomoć računala

Znati testirati raspodjelu podataka na normalnost (Kolmogorov-Smirnov test) uz pomoć računala

V7 z-vrijednosti

- Definirati svojstva normalne raspodjele
- Znati odrediti položaj pojedinog rezultata u normalnoj raspodjeli (izračunavanje z-vrijednosti)

V8-9 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom

- Razlikovati nezavisne od zavisnih skupina
- Razlikovati i znati odrediti kad se koriste parametrijski, a kad neparametrijski testovi
- Znati testirati razliku aritmetičkih sredina između dvije nezavisne skupine Studentovim t-testom računski i uz pomoć računala

V10-11 Korelacije

- Grafički prikaz podataka i izrada korelacijskog dijagrama
- Izračunavanje Pearsonovog koeficijenta korelacije računski i uz pomoć računala.
- Određivanje jednadžbe pravca regresije uz pomoć računala

V12-13 Testiranje razlike aritmetičkih sredina zavisnih uzoraka

- Prepoznati zavisne skupine
- Znati testirati razliku aritmetičkih sredina između dvije zavisne skupine Studentovim t-testom uz pomoć računala

V14-15 Analiza varijance (ANOVA)

- Naučiti kako usporediti tri i više skupina kvantitativnih podataka
- Znati primijeniti naknadne ili tzv. post-hoc testove

V16-17 Usporedba kvalitativnih podataka

- Razlikovati kvalitativne od kvantitativnih podataka
- Naučiti kako testirati razliku proporcija nezavisnih i zavisnih uzoraka računski i uz pomoć računala

V18-19 Hi-kvadrat test za nezavisne skupine

- Prikaz kvalitativnih podataka u tablicama kontingencije
- Znati napraviti usporedbu kvalitativnih podataka Hi-kvadrat testom računski i uz pomoć računala

V20-21 Hi-kvadrat test za zavisne skupine (Mc-Nemar test)

- Razlikovati i znati pravilno odabrati kad treba primijeniti Hi-kvadrat test za zavisne, a kad za nezavisne skupine.
- Znati napraviti usporedbu kvalitativnih podataka Hi-kvadrat testom za zavisne skupine računski i uz pomoć računala.
- Razumjeti i znati pravilno interpretirati ispis rezultata nakon izračuna Hi-kvadrat testa uz pomoć računala.

V22 Neparametrijski testovi

- Razlikovati kad treba primijeniti neparametrijske, a kad parametrijske testove
- Upoznati osnovne vrste neparametrijskih testova za usporedbu nezavisnih i zavisnih skupina podataka

V23 Dijagnostička točnost

Znati izračunati kvantitativne pokazatelje dijagnostičke točnosti kao što su:

- osjetljivost, specifičnost, pozitivnu prediktivnu vrijednost, negativnu prediktivnu vrijednost
- Poznavati postupak ROC-analize

V24-25 Ponavljanje i provjera znanja

- Napraviti provjeru znanja studenata o primjeni odgovarajućih statističkih testova za testiranje razlika, odnosno povezanosti podataka na računalima.

Student obligations:

Sve obavijesti o provođenju kolegija, kao i nastavni materijali bit će dostupni na sustavu za e-učenje Merlin. Studenti trebaju redovito posjećivati navedeni sustav kako bi bili na vrijeme informirani o svim činjenicama ili promjenama koje se tiču kolegija. Nadalje, studenti trebaju redovito pohađati i aktivno sudjelovati u nastavi.

POHAĐANJE NASTAVE:
Nastava je organizirana prema rasporedu objavljenom na sustavu za e-učenje Merlin. Prisustvovanje predavanjima, vježbama i međuispitima je obavezno te se za svaki od navedenih oblika nastave zasebno vodi evidencija za svakog studenta. Svi navedeni oblici nastave započinju u točno naznačeno vrijeme prema navedenom rasporedu te će kašnjenje biti tretirano kao izostanak. Ulasci/izlasci tijekom održavanja nastave se ne uvažavaju.
Student može opravdano izostati do 30 % sati predviđenih zasebno za vježbe, seminare i predavanja, isključivo zbog zdravstvenih razloga, što se opravdava liječničkom ispričnicom (uključujući izostanke s međuispita). Ako student neopravdano izostane s više od 30 % nastave po pojedinom obliku nastave (6 sati predavanja, 8 sati vježbi), ne može nastaviti praćenje kolegija i gubi mogućnost izlaska na završni ispit (0 ECTS bodova, ocjena F).

POSEBNE ODREDBE ZA ONLINE NASTAVU:
Shodno trenutno važećim “Preporukama za primjereno ponašanje u virtualnim sustavima za provođenje online nastave i ostalim oblicima rada u virtualnom okruženju” Sveučilišta u Rijeci (3.3.2021.), određeni oblici nastave mogu biti održani u online okruženju u realnom vremenu prema objavljenom rasporedu. Predavanja i vježbe će se održavati na platformi MS Teams, a studenti trebaju imati uključenu kameru čitavo vrijeme trajanja nastave, te mikrofon u trenutku interakcije. Ponovljena nemogućnost uključivanja kamere i/ili mikrofona bit će tretirana kao izostanak.

PRIPREMANJE ZA NASTAVU :
Prije svake vježbe student treba proučiti gradivo obrađeno na predavanjima i pripremiti se kako bi mogao efikasno odraditi vježbe.

A**KTIVNO SUDJELOVANJE NA NASTAVI**

aktivnost na vježbama (do 3 boda)

Vježbe imaju za cilj poticati analitički, kvantitativni pristup u rješavanju problema iz statistike. Studenti su dužni pripremiti se za vježbe, ponavljanjem teorije, i na vježbama aktivno sudjelovati. Tijekom izvođenja kolegija studenti na vježbama dobivaju i zadatke za zadaću. Bodovanje aktivnosti obavlja se na sljedeći način:

broj riješenih domaćih zadaća	ocjenski bodovi
0	0
1	1
2	2
3	3

Praćenje rada studenata:

Pohađanje nastave	0,25	Aktivnost u nastavi	0,5	Seminarski rad		Eksperimentalni rad	
Pismeni ispit	1,25	Usmeni ispit		Esej		Istraživanje	
Projekt		Kontinuirana provjera znanja	1,0	Referat		Praktični rad	1,0
Portfolio							

ECTS bodovni sustav ocjenjivanja:

Ocjenjivanje studenata provodi se prema važećem Pravilniku o studijima Sveučilišta u Rijeci, te prema Pravilniku o ocjenjivanju studenata na Medicinskom fakultetu u Rijeci (usvojenog na Fakultetskom vijeću Medicinskog fakulteta u Rijeci).

Rad studenata vrednovat će se i ocjenjivati tijekom nastave te na završnom ispitu. Od ukupno 100 ocjenskih bodova, tijekom nastave student može ostvariti najviše 70 ocjenskih bodova (70 %). Od maksimalnih 70 ocjenskih bodova koje je moguće ostvariti tijekom nastave, student mora sakupiti minimalno 50% ili 35 ocjenskih bodova kako bi pristupio završnom ispitu.

Studenti koji sakupe manje od 35 ocjenskih bodova imat će priliku za jedan popravni međuispit te, ako na tom međuispitu ispitu zadovolje, moći će pristupiti završnom ispitu. Studenti koji su tijekom nastave ostvarili od 0 do 49,9% ocjenskih bodova od bodova koje je bilo moguće steći tijekom nastave (odnosno manje od 35 ocjenskih bodova) ocjenjuju se ocjenom F (neuspješan) te moraju ponovno upisati kolegij.

Ocjenske bodove student stječe aktivnim sudjelovanjem u nastavi, izvršavanjem postavljenih zadataka i izlascima na međuispite na sljedeći način:

	Bodovanje	Maksimalan broj bodova
Parcijalni ispit	Numerički problemski zadatci (3 zadatka)	32
Vježbe	Kolokvij - rješavanje problemskih zadataka uz pomoć računalnog programa	35
Aktivnost	aktivnost na vježbama	3
UKUPNO		70
ZAVRŠNI ISPIT	Pismeni ispit (29 pitanja)	30
	ukupno	30
UKUPNO		100

I. TIJEKOM NASTAVE (UKUPNO NAJVIŠE 70 BODOVA):

a**) pismeni međuispit (do 32 boda)**

Pismeni međuispit ima 3 problemska zadatka koji obuhvaćaju gradivo obrađeno na predavanjima. Svaki zadatak se posebno boduje. Ako su točno riješeni svi zadatci moguće je skupiti maksimalno 32 boda. Prag prolaza na testu je 50%, što znači da se test boduje samo ako je na testu ostvareno barem 16 bodova.

b) kolokvij iz vježbi (do 35 bodova)

Vježbe završavaju kolokvijem. Na kolokviju se ispituje rješavanje statističkih zadataka u programu Statistica. Maksimalno je moguće skupiti 35 bodova na temelju kolokvija iz vježbi. Prag prolaza na kolokviju je 50%, što znači da se kolokvij boduje samo ako ostvareno barem 18 bodova.

Exam (exam taking, description of the written/oral/practical part of the exam, point distribution, grading criteria):

Tko može pristupiti završnom ispitu:

Završnom ispitu student/studentica pristupa po završetku nastave i pod uvjetom da je ostvario/la najmanje 50% (35 ocjenskih bodova).

- konačno ostvaruju 35 i više ocjenskih bodova, i/ili
- imaju manje od 30 % neopravdanih izostanaka s nastave
- koji su položili parcijalni međuispit i kolokvij na računalima

Tko ne može pristupiti završnom ispitu:

Studenti koji su tijekom nastave ostvarili 0 do 29,9 bodova ili koji imaju 30% i više izostanaka s nastave. Takav student je neuspješan (1) F i ne može izaći na završni ispit, tj. mora predmet ponovno upisati naredne akademske godine.

Other notes (related to the course) important for students:

Nastavnici i suradnici su svakodnevno tijekom radnog vremena dostupni putem e-mail adresa za sva pitanja koja se tiču nastave.

Prof. dr. sc. Gordana Žauhar gordana.zauhar@uniri.hr

Doc. dr. sc. Đeni Smilović Radojčić djenisr@medri.uniri.hr

Marijana Majetić, viša laborantica marijana.majetic@uniri.hr , administratorica katedre

Nastavni sadržaji i sve obavijesti vezane uz kolegij nalaze se na portalu Merlin 2026 /2027

COURSE HOURS 2026/2027

Zdravstvena statistika

Lectures (Place and time or group)	**Practicals** (Place and time or group)
02.11.2026	

P1 Uvod. Važnost poznavanja statistike u stručnom i znanstvenom radu. Vrste statističkih podataka.:
• P07 (10:15 - 11:45) [149]
  ○ ZS
 	
P2 Grafički i tabelarni prikaz kvalitativnih podataka:
• P07 (10:15 - 11:45) [149]
  ○ ZS	

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
05.11.2026	

	V1-2 Upisivanje podataka u program za obradu:
	• P09 - TEACHING IN ENGLISH (13:00 - 15:00) [196]
	  ○ ZSVG1
	• P09 - TEACHING IN ENGLISH (15:00 - 17:00) [196]
	  ○ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
09.11.2026	

P3 Grafički prikaz kvantitativnih podataka.:
• v (10:15 - 11:45) [149]
  ○ ZS
 	
P4 Mjere centralne tendencije:
• v (10:15 - 11:45) [149]
  ○ ZS	

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
10.11.2026	
	V3-4 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.: • P09 - TEACHING IN ENGLISH (14:00 - 16:00) [196] ○ ZSVG2
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
12.11.2026	
	V3-4 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.: • P09 - TEACHING IN ENGLISH (14:00 - 16:00) [196] ○ ZSVG1
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
16.11.2026	

P5 Mjere varijabilnosti podataka: • P04 (10:15 - 12:00) [149] ◦ ZS P6 Normalna raspodjela: • P04 (10:15 - 12:00) [149] ◦ ZS	
prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
23.11.2026	
P7 Populacija i uzorak: • v (10:30 - 12:00) [149] ◦ ZS P8 Testiranje razlike aritmetičkih sredina između dvije velike nezavisne skupine: • v (10:30 - 12:00) [149] ◦ ZS	V5 Deskriptivna statistika. Grafički prikaz empirijske raspodjele: • P03 - IT CLASSROOM (13:30 - 16:00) [196] ◦ ZSVG2 V6 Provjravanje normalnosti raspodjele podataka uz pomoć računala: • P03 - IT CLASSROOM (13:30 - 16:00) [196] ◦ ZSVG2 V7 z-vrijednosti: • P03 - IT CLASSROOM (13:30 - 16:00) [196] ◦ ZSVG2
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
25.11.2026	
	V5 Deskriptivna statistika. Grafički prikaz empirijske raspodjele: • P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196] ◦ ZSVG1 V6 Provjravanje normalnosti raspodjele podataka uz pomoć računala: • P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196] ◦ ZSVG1 V7 z-vrijednosti: • P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196] ◦ ZSVG1
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
30.11.2026	
P9 Testiranje razlike aritmetičkih sredina između malih nezavisnih skupina: • P03 - IT CLASSROOM (10:30 - 12:00) [149] ◦ ZS P10 Korelacijska analiza: • P03 - IT CLASSROOM (10:30 - 12:00) [149] ◦ ZS	
prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
03.12.2026	

	V8-9 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom:
	• P03 - IT CLASSROOM (12:00 - 15:00) [196]
	  ◦ ZSVG1
	
	V10-11 Korelacije:
	• P03 - IT CLASSROOM (12:00 - 15:00) [196]
	  ◦ ZSVG1

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
04.12.2026	

	V8-9 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom:
	• P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196]
	  ◦ ZSVG2
	
	V10-11 Korelacije:
	• P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196]
	  ◦ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
07.12.2026	

P11 Regresijska analiza:
• P07 (10:00 - 11:30) [149]
  ◦ ZS
 	
P12 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina:
• P07 (10:00 - 11:30) [149]
  ◦ ZS
	V10-11 Korelacije:
	• P09 - TEACHING IN ENGLISH (12:00 - 16:00) [196]
	  ◦ ZSVG2
	
	V12-13 Testiranje razlike aritmetičkih sredina zavisnih uzoraka:
	• P09 - TEACHING IN ENGLISH (12:00 - 16:00) [196]
	  ◦ ZSVG2
	
	V14-15 Analiza varijance (ANOVA):
	• P09 - TEACHING IN ENGLISH (12:00 - 16:00) [196]
	  ◦ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
08.12.2026	

	V10-11 Korelacije:
	• P09 - TEACHING IN ENGLISH (11:00 - 14:00) [196]
	  ◦ ZSVG1
	
	V12-13 Testiranje razlike aritmetičkih sredina zavisnih uzoraka:
	• P09 - TEACHING IN ENGLISH (11:00 - 14:00) [196]
	  ◦ ZSVG1

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
14.12.2026	

P13 Višestruko testiranje. Analiza varijance.:
• P15 - TOWN HALL (10:15 - 13:00) [149]
  ◦ ZS
 	
P14 Analiza i usporedba kvalitativnih podataka testom razlike proporcija:
• P15 - TOWN HALL (10:15 - 13:00) [149]
  ◦ ZS
 	
P15 Hi-kvadrat test:
• P15 - TOWN HALL (10:15 - 13:00) [149]
  ◦ ZS	

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
16.12.2026	

	V16-17 Usporedba kvalitativnih podataka:
	• P03 - IT CLASSROOM (08:00 - 11:00) [196]
	  ◦ ZSVG2
	
	V18-19 Hi-kvadrat test za nezavisne skupine:
	• P03 - IT CLASSROOM (08:00 - 11:00) [196]
	  ◦ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
17.12.2026	

	V14-15 Analiza varijance (ANOVA):
	• P09 - TEACHING IN ENGLISH (12:00 - 15:00) [196]
	  ◦ ZSVG1
	
	V16-17 Usporedba kvalitativnih podataka:
	• P09 - TEACHING IN ENGLISH (12:00 - 15:00) [196]
	  ◦ ZSVG1

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
07.01.2027	

	V18-19 Hi-kvadrat test za nezavisne skupine:
	• P03 - IT CLASSROOM (08:00 - 10:00) [196]
	  ◦ ZSVG2
	• P03 - IT CLASSROOM (13:00 - 16:00) [196]
	  ◦ ZSVG1
	
	V16-17 Usporedba kvalitativnih podataka:
	• P03 - IT CLASSROOM (13:00 - 16:00) [196]
	  ◦ ZSVG1

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
11.01.2027	

P16 McNemarov test:
• P07 (12:15 - 14:00) [149]
  ◦ ZS
 	
P17 Izbor iz neparametrijskih testova.:
• P07 (12:15 - 14:00) [149]
  ◦ ZS	

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
13.01.2027	

	V20-21 Hi-kvadrat test za zavisne skupine (Mc-Nemar test):
	• P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196]
	  ◦ ZSVG2
	
	V22 Neparametrijski testovi:
	• P09 - TEACHING IN ENGLISH (08:00 - 11:00) [196]
	  ◦ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
14.01.2027	

	V20-21 Hi-kvadrat test za zavisne skupine (Mc-Nemar test):
	• P03 - IT CLASSROOM (14:00 - 16:30) [196]
	  ◦ ZSVG1
	
	V22 Neparametrijski testovi:
	• P03 - IT CLASSROOM (14:00 - 16:30) [196]
	  ◦ ZSVG1

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
18.01.2027	

P18 Ocjena valjanosti testova. Dijagnostička točnost:
• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [149]
  ◦ ZS
 	
P19 Pismena provjera znanja:
• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [149]
  ◦ ZS
 	
P20 Završno predavanje i priprema za ispit:
• P02 (14:00 - 15:30) [149]
  ◦ ZS	

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
21.01.2027	
	V23 Dijagnostička točnost: • P03 - IT CLASSROOM (10:00 - 12:00) [196] ◦ ZSVG2
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
22.01.2027	
	V23 Dijagnostička točnost: • P09 - TEACHING IN ENGLISH (11:30 - 13:30) [196] ◦ ZSVG1
doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	
25.01.2027	

	V24-25 Ponavljanje i provjera znanja:
	• P09 - TEACHING IN ENGLISH (08:30 - 09:30) [196]
	  ◦ ZSVG1
	• P09 - TEACHING IN ENGLISH (09:30 - 11:00) [196]
	  ◦ ZSVG2

doc.dr. sc. Smilović-Radojčić Đeni, med. fiz. [196]	

List of lectures, seminars and practicals:

LECTURES (TOPIC)	Number of hours	Location
P1 Uvod. Važnost poznavanja statistike u stručnom i znanstvenom radu. Vrste statističkih podataka.	1	P07
P2 Grafički i tabelarni prikaz kvalitativnih podataka	1	P07
P3 Grafički prikaz kvantitativnih podataka.	1	v
P4 Mjere centralne tendencije	1	v
P5 Mjere varijabilnosti podataka	1	P04
P6 Normalna raspodjela	1	P04
P7 Populacija i uzorak	1	v
P8 Testiranje razlike aritmetičkih sredina između dvije velike nezavisne skupine	1	v
P9 Testiranje razlike aritmetičkih sredina između malih nezavisnih skupina	1	P03 - IT CLASSROOM
P10 Korelacijska analiza	1	P03 - IT CLASSROOM
P11 Regresijska analiza	1	P07
P12 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina	1	P07
P13 Višestruko testiranje. Analiza varijance.	1	P15 - TOWN HALL
P14 Analiza i usporedba kvalitativnih podataka testom razlike proporcija	1	P15 - TOWN HALL
P15 Hi-kvadrat test	1	P15 - TOWN HALL
P16 McNemarov test	1	P07
P17 Izbor iz neparametrijskih testova.	1	P07
P18 Ocjena valjanosti testova. Dijagnostička točnost	1	P09 - TEACHING IN ENGLISH
P19 Pismena provjera znanja	1	P09 - TEACHING IN ENGLISH
P20 Završno predavanje i priprema za ispit	1	P02

PRACTICALS (TOPIC)	Number of hours	Location
V1-2 Upisivanje podataka u program za obradu	2	P09 - TEACHING IN ENGLISH
V3-4 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.	2	P09 - TEACHING IN ENGLISH
V5 Deskriptivna statistika. Grafički prikaz empirijske raspodjele	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V6 Provjravanje normalnosti raspodjele podataka uz pomoć računala	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V7 z-vrijednosti	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V8-9 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom	2	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V10-11 Korelacije	2	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V12-13 Testiranje razlike aritmetičkih sredina zavisnih uzoraka	2	P09 - TEACHING IN ENGLISH
V14-15 Analiza varijance (ANOVA)	2	P09 - TEACHING IN ENGLISH

V16-17 Usporedba kvalitativnih podataka	2	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V18-19 Hi-kvadrat test za nezavisne skupine	2	P03 - IT CLASSROOM
V20-21 Hi-kvadrat test za zavisne skupine (Mc-Nemar test)	2	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V22 Neparametrijski testovi	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V23 Dijagnostička točnost	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V24-25 Ponavljanje i provjera znanja	2	P09 - TEACHING IN ENGLISH

EXAM DATES (final exam):

1.	12.02.2027.
2.	26.02.2027.
3.	02.07.2027.
4.	03.09.2027.