Faculty of Medicine in Rijeka

Curriculum
2025/2026

For course

Biostatistika

Study program:	**Medicina (R)** University integrated undergraduate and graduate study
Department:	**Department of Medical Physics and Biophysics**
Course coordinator:	**prof. dr. sc. Žauhar Gordana, prof. fizike i kemije**
Year of study:	**2**
ECTS:	**1.5**
Incentive ECTS:	**0 (0.00%)**
Foreign language:	**No**

Course information:

Kolegij **Biostatistika** je obvezni predmet na 2. godini Integriranog preddiplomskog i diplomskog sveučilišnog studija Medicina koji se održava u ljetnom semestru, a sastoji se od 15 sati predavanja, i 15 sati vježbi, ukupno 30 sati (**1,5 ECTS**).

Cilj je kolegija osposobiti studenta, budućeg liječnika, 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]:

ISHODI UČENJA ZA PREDMET:

I. KOGNITIVNA DOMENA – ZNANJE
1. Opisati i objasniti fizikalne osnove bioloških procesa
2. Razlikovati i znati objasniti različite načine prijenosa energije i tvari unutar organizma i u njegovoj interakciji s okolinom
3. Razlikovati osnovne vrste poluga u ljudskom tijelu, te znati primijeniti zakon poluge na objašnjenje rada
4. poluga u ljudskom tijelu
5. Objasniti nastanak slike u oku i korekcije optičkih pogrešaka oka pomoću naočala
6. Primijeniti osnovne fizikalne zakone hidrodinamike na objašnjenje protoka krvi kroz krvotok
7. Objasniti vezu akustičkih parametara i fizioloških osjeta zvučnih valova
8. Razlikovati intenzitet, akustičku impedanciju, nivo intenziteta i glasnoću zvuka
9. Opisati i objasniti ponašanje tkiva u stalnom i promjenjivom električnom i magnetskom polju te učinke koje može izazvati prolazak struje kroz organizam
10. Opisati i objasniti mehanizme međudjelovanja ionizirajućeg zračenja i tvari, te učinke koje ionizirajuće zračenje može izazvati kod čovjeka

II.PSIHOMOTORIČKA DOMENA – VJEŠTINE
1. Preračunavati mjerne jedinice
2. Grafički prikazati rezultate mjerenja i očitavanje grafova
3. Izračunavati jednostavne pogreške i procjenu točnosti rezultata mjerenja
4. Rukovati jednostavnim mjernim instrumentima
5. Prepoznati i izdvojiti grube od slučajnih pogrešaka tijekom mjerenja

Izvođenje nastave:
Predavanja se održavaju u predavaonici 2, a vježbe u predavsaonici P9 Medicinskog fakulteta. Predviđeno vrijeme trajanja nastave je ukupno 7 tjedana.

Studentu je obveza pripremiti gradivo o kojem se raspravlja
Obveze studenata su redovito pohađanje i aktivno sudjelovanje u nastavi. Studenti su obavezni napraviti sve vježbe. Tijekom vježbi nastavnik pokazuje te nadzire aktivno sudjelovanje studenata u izvođenju vježbi. Vježbe završavaju kolokvijem koji je uvjet za pristupanje završnom ispitu. Na kolokviju se ispituje korištenje programske podrške za analizu podataka (Statistica ili sl.). Tijekom nastave održat će se obvezni kolokvij iz vježbi, te pismeni međuispit.

Nastavnik ocjenjuje sudjelovanje studenta u radu vježbi (pokazano znanje, razumijevanje, sposobnost postavljanja problema, zaključivanje, itd.).

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, „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)

Završnom ispitu ne mogu pristupiti studenti koji:
- konačno ostvaruju manje od 35 ocjenskih bodova, i/ili
- imaju 30 % i više neopravdanih izostanaka s nastave
- koji nisu položili parcijalni međuispit i kolokvij na računalima

Takav student ocjenjuje se ocjenom F (neuspješan), ne može steći ECTS bodove niti izaći na završni ispit, odnosno mora predmet ponovno upisati naredne akademske godine.

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

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).

Tko ne može pristupiti završnom ispitu:
Studenti koji su tijekom nastave ostvarili 0 do 34,9 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.

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:
Pismeni međuispit: 14.04.2026.
Kolokvij iz vježbi: u terminu zadnjih vježbi od 14.04.2026. do 17.04.2026.

Završni ispit:
1. rok 07.05.2026.
2. rok 23.06.2026.
3. rok 10.09.2026.

Curriculum:

Lectures list (with titles and explanation):

P1 Uvod. Važnost poznavanja statistike u medicini. Biološka varijabilnost i priroda podataka u medicini. Ljestvice mjerenja.

Ishodi učenja:
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 Prikaz kvalitativnih podataka u tabelama i grafički.

Ishodi učenja:
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.

Ishodi učenja:
Napraviti grupiranje podataka u razrede te izraditi prikaz podataka poligonom i histogramom frekvencija.
Napraviti grafički prikaz empirijske distribucije

P4 Mjere centralne tendencije i varijabilnosti podataka.

Ishodi učenja:
Znati odrediti osnovne mjere centralne tendencije: aritmetičku sredinu, medijan i mod
Odabir primjerenih mjera centralne tendencije ovisno o vrsti raspodjele 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
Znati izvršiti testiranje raspodjele na normalnost (Kolmogorov - Smirnov test) uz pomoć računala
Opis i prepoznavanje osnovnih teorijskih raspodjela podataka

P5 Normalna raspodjela. Položaj pojedinog rezultata u grupi (z-vrijednost).

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

P6 Populacija i uzorak. Određivanje granica pouzdanosti.

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

P7 Testiranje razlike između dviju nezavisnih skupina ispitanika parametrijskim testom.

Ishodi učenja:
Razlikovati zavisne i nezavisne uzorke
Poznavanje teorije testiranja hipoteza i određivanje signifikantnosti razlike
Znati testirati razliku aritmetičkih sredina između dvije nezavisne skupine Studentovim t-testom

P8 Korelacija

Ishodi učenja:
Analiza povezanosti kvantitativnih obilježja
Poznavati postupak izračunavanja Pearsonova koeficijenta korelacije

P9 Jednadžba pravca regresije

Ishodi učenja:
Opis i primjena modela jednostavne linearne regresije
Znati odrediti jednadžbu pravca regresije

P10 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina ispitanika.

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

P11 Analiza i usporedba kvalitativnih podataka.

Ishodi učenja:
Znati izračunati proporcije i standardnu pogrešku proporcija
Poznavati postupak testiranja razlike proporcija nezavisnih uzoraka

P12 Hi-kvadrat test.

Ishodi učenja:
Prikaz i analiza tablica kontingencije
Usporedba kvalitativnih podataka Hi-kvadrat testom

P13 McNemar test

Ishodi učenja:
Razlikovati i znati usporediti dvije zavisne skupine kvalitativnih podataka McNemarovim testom

P14 Višestruko testiranje. Analiza varijance. Izbor iz neparametrijskih testova.

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

P15 Izbor iz neparametrijskih testova. Završno predavanje.

Ishodi učenja:
Upoznati osnovne neparametrijske testove za testiranje razlika nezavisnih i zavisnih uzoraka (Mann-Whitneyjev test, Wilcoxonov test...)

Practicals list (with titles and explanation):

V1 Upisivanje podataka u program za obradu. Kreiranje baze podataka.

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

V2 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.

Ishodi učenja:
Znati kako napraviti grafički prikaz kvalitativnih podataka (kružni i stupčasti dijagram)
Znati napraviti linijski i kružni vremenski dijagram

V3 Grafički prikaz empirijske raspodjele.

Ishodi učenja:
Analiza parametara empirijske distribucije.
Znati napraviti grafički prikaz kvantitativnih podataka
Grupirati rezultate u razrede radi izrade poligona i histograma frekvencije

V4 Deskriptivna statistika.

Ishodi učenja:
Znati izračunati mjere 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

V5 Provjeravanje normalnosti raspodjele podataka uz pomoć računala.

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

V6 z-vrijednosti.

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

V7 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom.

Ishodi učenja:
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 uz pomoć računala

V8 Korelacije.

Ishodi učenja:
Grafički prikaz podataka i izrada korelacijskog dijagrama
Izračunavanje Pearsonovog koeficijenta korelacije
Određivanje jednadžbe pravca regresije uz pomoć računala

V9 Testiranje razlike aritmetičkih sredina zavisnih uzoraka.

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

V10 Usporedba kvalitativnih podataka.

Ishodi učenja:
Razlikovati kvalitativne od kvantitativnih podataka
Naučiti kako testirati razliku proporcija nezavisnih uzoraka
Prikaz kvalitativnih podataka u tablicama kontingencije

V11 Hi-kvadrat test za nezavisne skupine.

Ishodi učenja:
Znati napraviti usporedbu kvalitativnih podataka Hi-kvadrat testom.
Razumjeti i znati pravilno interpretirati ispis rezultata nakon izračuna Hi-kvadrat testa uz pomoć računala

V12 Hi-kvadrat test za zavisne skupine (McNemar test). Neparametrijski testovi.

Ishodi učenja:
Razlikovati i znati pravilno odabrati kad treba primijeniti Hi-kvadrat test za zavisne, a kad za nezavisne skupine.
Razlikovati kad treba primijeniti neparametrijske, a kad parametrijske testove
Upoznati osnovne vrste neparametrijskih testova za usporedbu nezavisnih i zavisnih skupina podataka

V13 Višestruko testiranje. Analiza varijance.

Ishodi učenja:
Znati napraviti testiranja razlike između više nezavisnih skupina kvantitativnih podataka parametrijskim testom (ANOVA)
Objasniti čemu služe I kada se koriste naknadni ili tzv. Post-hoc testovi

V14-15 Ponavljanje i provjera znanja

.

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. Studenti su obvezni redovito pohađati i aktivno sudjelovati u svim oblicima nastave. Svaki student je dužan izraditi seminarski rad i izložiti ga pred svojom seminarskom grupom.

POHAĐANJE NASTAVE:
Nastava je organizirana prema rasporedu objavljenom na sustavu za e-učenje Merlin i INP aplikaciji Medicinskog fakulteta u Rijeci. Prisustvovanje predavanjima, seminarina, 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 (_ sati predavanja, _ sati seminara, _ sata 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 će biti održani u online okruženju u realnom vremenu prema objavljenom rasporedu. Predavanja, seminari 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.

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

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 izvođenja nastave, te na završnom ispitu. Od ukupno 100 bodova, tijekom nastave student može ostvariti 70 bodova, a na završnom ispitu 30 bodova.

I. Tijekom nastave vrednuje se (maksimalno do 70 bodova):
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**

a) 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. Na vježbama studenti 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

b) 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.

c) 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 je ostvareno barem 18 bodova.

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

KONTAKTIRANJE S NASTAVNICIMA:
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
Asistent, Ivan Pribanić ipribanic@uniri.hr
Asistentica, Doris Šegota Ritoša doris.segota.ritosa@uniri.hr
Marijana Majetić, viša laborantica marijana.majetic@uniri.hr

Nastavni sadržaji i sve obavijesti vezane uz kolegij nalaze se na portalu Merlin 2025. /2026.

AKADEMSKA ČESTITOST:
Očekuje se da će nastavnik poštivati Etički kodeks Sveučilišta u Rijeci, a studenti Etički kodeks za studente Sveučilišta u Rijeci.

COURSE HOURS 2025/2026

Biostatistika

Lectures (Place and time or group)	**Practicals** (Place and time or group)
02.03.2026	
P1 Uvod. Važnost poznavanja statistike u medicini. Biološka varijabilnost i priroda podataka u medicini. Ljestvice mjerenja.: • P02 (16:15 - 17:00) [149] ○ B	
prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
03.03.2026	

P2 Prikaz kvalitativnih podataka u tabelama i grafički.:
• P02 (12:15 - 14:00) [149]
  ○ B
 	
P3 Grafički prikaz kvantitativnih podataka.:
• P02 (12:15 - 14:00) [149]
  ○ B
	V1 Upisivanje podataka u program za obradu. Kreiranje baze podataka.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ○ BG3
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [149]
	  ○ BG5
	
	V2 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ○ BG3
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [149]
	  ○ BG5

Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
05.03.2026	

	V1 Upisivanje podataka u program za obradu. Kreiranje baze podataka.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [199]
	  ○ BG6
	
	V2 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [199]
	  ○ BG6

naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199]	
06.03.2026	

	V1 Upisivanje podataka u program za obradu. Kreiranje baze podataka.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG2
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG4
	
	V2 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG2
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG4

Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
10.03.2026	

P4 Mjere centralne tendencije i varijabilnosti podataka.:
• P02 (12:00 - 13:30) [149]
  ◦ B
 	
P5 Normalna raspodjela. Položaj pojedinog rezultata u grupi (z-vrijednost).:
• P02 (12:00 - 13:30) [149]
  ◦ B
	V3 Grafički prikaz empirijske raspodjele.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199]
	  ◦ BG3
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [199]
	  ◦ BG5
	
	V4 Deskriptivna statistika.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199]
	  ◦ BG3
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [199]
	  ◦ BG5

naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
12.03.2026	

	V3 Grafički prikaz empirijske raspodjele.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG6
	
	V4 Deskriptivna statistika.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG6

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
13.03.2026	

	V3 Grafički prikaz empirijske raspodjele.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG1
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG2
	
	V4 Deskriptivna statistika.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG1
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG2

Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
17.03.2026	
P6 Populacija i uzorak. Određivanje granica pouzdanosti.: • P02 (12:15 - 14:00) [149] ◦ B P7 Testiranje razlike između dviju nezavisnih skupina ispitanika parametrijskim testom.: • P02 (12:15 - 14:00) [149] ◦ B	V5 Provjeravanje normalnosti raspodjele podataka uz pomoć računala.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5 V6 z-vrijednosti.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5
Pribanić Ivan, mag. edu. phys. et math. [457] · naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
19.03.2026	
	V5 Provjeravanje normalnosti raspodjele podataka uz pomoć računala.: • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG6 V6 z-vrijednosti.: • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG6
prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
20.03.2026	
	V5 Provjeravanje normalnosti raspodjele podataka uz pomoć računala.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG2 V6 z-vrijednosti.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG2
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
24.03.2026	

P8 Korelacija: • P02 (12:15 - 14:00) [149] ◦ B P9 Jednadžba pravca regresije: • P02 (12:15 - 14:00) [149] ◦ B	V7 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5 V8 Korelacije.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5
Pribanić Ivan, mag. edu. phys. et math. [457] · naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
26.03.2026	
	V7 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom.: • P09 - TEACHING IN ENGLISH (13:15 - 14:45) [149] ◦ BG6 V8 Korelacije.: • P09 - TEACHING IN ENGLISH (13:15 - 14:45) [149] ◦ BG6
prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
27.03.2026	
	V7 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG2 V8 Korelacije.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] ◦ BG2
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
31.03.2026	
P10 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina ispitanika.: • P01 (12:15 - 14:00) [149] ◦ B P11 Analiza i usporedba kvalitativnih podataka.: • P01 (12:15 - 14:00) [149] ◦ B	V9 Testiranje razlike aritmetičkih sredina zavisnih uzoraka.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5 V10 Usporedba kvalitativnih podataka.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [199] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5

Pribanić Ivan, mag. edu. phys. et math. [457] · naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
01.04.2026	
	V9 Testiranje razlike aritmetičkih sredina zavisnih uzoraka.: • P09 - TEACHING IN ENGLISH (16:00 - 17:30) [457] [149] ◦ BG4 • P09 - TEACHING IN ENGLISH (17:30 - 19:00) [457] ◦ BG1 V10 Usporedba kvalitativnih podataka.: • P09 - TEACHING IN ENGLISH (16:00 - 17:30) [457] [149] ◦ BG4 • P09 - TEACHING IN ENGLISH (17:30 - 19:00) [457] ◦ BG1
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
02.04.2026	
	V9 Testiranje razlike aritmetičkih sredina zavisnih uzoraka.: • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] [457] ◦ BG6 • P09 - TEACHING IN ENGLISH (14:00 - 15:30) [457] ◦ BG2 V10 Usporedba kvalitativnih podataka.: • P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149] [457] ◦ BG6 • P09 - TEACHING IN ENGLISH (14:00 - 15:30) [457] ◦ BG2
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
07.04.2026	
P12 Hi-kvadrat test.: • P02 (12:15 - 14:00) [149] ◦ B P13 McNemar test: • P02 (12:15 - 14:00) [149] ◦ B	V11 Hi-kvadrat test za nezavisne skupine.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5 V12 Hi-kvadrat test za zavisne skupine (McNemar test). Neparametrijski testovi.: • P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457] ◦ BG3 • P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457] ◦ BG5
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
09.04.2026	

	V11 Hi-kvadrat test za nezavisne skupine.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG6
	
	V12 Hi-kvadrat test za zavisne skupine (McNemar test). Neparametrijski testovi.:
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG6

prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
10.04.2026	

	V11 Hi-kvadrat test za nezavisne skupine.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG1
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG2
	
	V12 Hi-kvadrat test za zavisne skupine (McNemar test). Neparametrijski testovi.:
	• P09 - TEACHING IN ENGLISH (08:15 - 10:00) [457]
	  ◦ BG4
	• P09 - TEACHING IN ENGLISH (10:15 - 12:00) [457]
	  ◦ BG1
	• P09 - TEACHING IN ENGLISH (12:15 - 14:00) [149]
	  ◦ BG2

Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
14.04.2026	

P14 Višestruko testiranje. Analiza varijance. Izbor iz neparametrijskih testova.:
• P02 (12:00 - 13:30) [149]
  ◦ B
 	
P15 Izbor iz neparametrijskih testova. Završno predavanje.:
• P02 (12:00 - 13:30) [149]
  ◦ B
	V13 Višestruko testiranje. Analiza varijance.:
	• P09 - TEACHING IN ENGLISH (09:00 - 12:00) [199]
	  ◦ BG3
	
	V14-15 Ponavljanje i provjera znanja:
	• P09 - TEACHING IN ENGLISH (09:00 - 12:00) [199]
	  ◦ BG3

naslovna asistentica Šegota Ritoša Doris, prof. fiz. i info. [199] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
16.04.2026	

	V13 Višestruko testiranje. Analiza varijance.:
	• P03 - IT CLASSROOM (12:00 - 14:30) [149]
	  ◦ BG6
	• P03 - IT CLASSROOM (14:30 - 17:00) [457]
	  ◦ BG5
	
	V14-15 Ponavljanje i provjera znanja:
	• P03 - IT CLASSROOM (12:00 - 14:30) [149]
	  ◦ BG6
	• P03 - IT CLASSROOM (14:30 - 17:00) [457]
	  ◦ BG5

Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	
17.04.2026	

	V13 Višestruko testiranje. Analiza varijance.: • P09 - TEACHING IN ENGLISH (08:00 - 10:30) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:30 - 13:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (13:00 - 15:30) [149] ◦ BG2 V14-15 Ponavljanje i provjera znanja: • P09 - TEACHING IN ENGLISH (08:00 - 10:30) [457] ◦ BG4 • P09 - TEACHING IN ENGLISH (10:30 - 13:00) [457] ◦ BG1 • P09 - TEACHING IN ENGLISH (13:00 - 15:30) [149] ◦ BG2
Pribanić Ivan, mag. edu. phys. et math. [457] · prof. dr. sc. Žauhar Gordana, prof. fizike i kemije [149]	

List of lectures, seminars and practicals:

LECTURES (TOPIC)	Number of hours	Location
P1 Uvod. Važnost poznavanja statistike u medicini. Biološka varijabilnost i priroda podataka u medicini. Ljestvice mjerenja.	1	P02
P2 Prikaz kvalitativnih podataka u tabelama i grafički.	1	P02
P3 Grafički prikaz kvantitativnih podataka.	1	P02
P4 Mjere centralne tendencije i varijabilnosti podataka.	1	P02
P5 Normalna raspodjela. Položaj pojedinog rezultata u grupi (z-vrijednost).	1	P02
P6 Populacija i uzorak. Određivanje granica pouzdanosti.	1	P02
P7 Testiranje razlike između dviju nezavisnih skupina ispitanika parametrijskim testom.	1	P02
P8 Korelacija	1	P02
P9 Jednadžba pravca regresije	1	P02
P10 Testiranje razlike aritmetičkih sredina između dviju zavisnih skupina ispitanika.	1	P01
P11 Analiza i usporedba kvalitativnih podataka.	1	P01
P12 Hi-kvadrat test.	1	P02
P13 McNemar test	1	P02
P14 Višestruko testiranje. Analiza varijance. Izbor iz neparametrijskih testova.	1	P02
P15 Izbor iz neparametrijskih testova. Završno predavanje.	1	P02

PRACTICALS (TOPIC)	Number of hours	Location
V1 Upisivanje podataka u program za obradu. Kreiranje baze podataka.	1	P09 - TEACHING IN ENGLISH
V2 Grafički prikaz kvalitativnih podataka. Izrada linijskog i kružnog vremenskog dijagrama.	1	P09 - TEACHING IN ENGLISH
V3 Grafički prikaz empirijske raspodjele.	1	P09 - TEACHING IN ENGLISH
V4 Deskriptivna statistika.	1	P09 - TEACHING IN ENGLISH
V5 Provjeravanje normalnosti raspodjele podataka uz pomoć računala.	1	P09 - TEACHING IN ENGLISH

V6 z-vrijednosti.	1	P09 - TEACHING IN ENGLISH
V7 Testiranje razlike aritmetičkih sredina nezavisnih skupina Studentovim t-testom.	1	P09 - TEACHING IN ENGLISH
V8 Korelacije.	1	P09 - TEACHING IN ENGLISH
V9 Testiranje razlike aritmetičkih sredina zavisnih uzoraka.	1	P09 - TEACHING IN ENGLISH
V10 Usporedba kvalitativnih podataka.	1	P09 - TEACHING IN ENGLISH
V11 Hi-kvadrat test za nezavisne skupine.	1	P09 - TEACHING IN ENGLISH
V12 Hi-kvadrat test za zavisne skupine (McNemar test). Neparametrijski testovi.	1	P09 - TEACHING IN ENGLISH
V13 Višestruko testiranje. Analiza varijance.	1	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH
V14-15 Ponavljanje i provjera znanja	2	P03 - IT CLASSROOM P09 - TEACHING IN ENGLISH

EXAM DATES (final exam):

1.	07.05.2026.
2.	23.06.2026.
3.	10.09.2026.