

Datum: Rijeka, 16. srpnja 2026.

Kolegij: Osnove biomedicinske statistike

Voditelj: izv. prof. dr.sc. Andrica Lekić

Izvođač: Helena Štrucelj, dipl. psiholog – prof.

e-mail voditelja: andrica.lekic@uniri.hr

Katedra: Katedra za temeljne medicinske znanosti

Studij: Sveučilišni prijediplomski studij - Primaljstvo redovni

Godina studija: 3.

Akadska godina: 2026./2027.

IZVEDBENI NASTAVNI PLAN

Podaci o kolegiju (kratak opis kolegija, opće upute, gdje se i u kojem obliku organizira nastava, potreban pribor, upute o pohađanju i pripremi za nastavu, obveze studenata i sl.):

Kolegij **Osnove biomedicinske statistike** je obavezni kolegij na trećoj godini sveučilišnog prijediplomskog studija Primaljstva. Sastoji se od 25 sati predavanja i 20 sati vježbi te omogućuje stjecanje tri (3) ECTS-boda.

Cilj kolegija je upoznati i usvojiti temeljne statističke pojmove zbog praćenja stručne literature u kojoj su rezultati izraženi statističkim terminima i simbolima.

Ishodi kolegija:

- u konkretnom slučaju odabrati odgovarajuće statističke testove
- analizirati i interpretirati rezultate statističke obrade podataka

Sadržaj kolegija

- Mjerenje i mjerne ljestvice. Osobine biomedicinskih istraživanja.
- Tabelarni i grafički prikaz podataka
- Deskriptivna statistika. Izračunavanje srednjih vrijednosti i mjera varijabilnosti uzorka.
- Normalna distribucija. Populacija i uzorak. Standardna pogreška. Granice pouzdanosti.
- Odabir statističkog testa.
- Parametrijski testovi. Testiranje razlike aritmetičkih sredina.
- Korelacija i regresija.
- Testiranje razlike proporcija.
- Neparametrijski testovi. Tablice kontingencije.
- Hi-kvadrat test.

Izvođenje nastave.

Nastava se izvodi u obliku predavanja i vježbi u prostorijama Fakulteta. Na kraju kolegija održava se pisani završni ispit.

U izvođenju nastave sudjeluju Helena Štrucelj, dipl. psiholog-prof. (helena.strucelj@uniri.hr) i mr. sc. Sanda Tamarut, dipl. san. ing. (sanda.tamarut@uniri.hr).

Popis obvezne ispitne literature:

1. Nastavni materijali, upute i obrasci za seminarski rad i seminarske zadatke (dostupno na platformi Merlin)
2. Petz B, Kolesarić V, Ivanec D. Petzova statistika: Osnovne statističke metode za nematematičare. Jastrebarsko: Naklada Slap; 2012. (odabrana poglavlja)
3. Kolesarić V, Petz B. Statistički rječnik. Jastrebarsko: Naklada Slap; 2003.

Popis dopunske literature:

1. Ferenczi E, Muirhead N. Statistika i epidemiologija. Zagreb: Medicinska naklada; 2012.

Nastavni plan:

Popis predavanja (s naslovima i pojašnjenjem):

P1. Uvod u medicinsku statistiku

Ishodi učenja: Objasniti osobitosti mjerenja u medicinskim istraživanjima i važnost poznavanja statistike za rad u struci.

P2. Vrste podataka

Ishodi učenja: Definirati i razlikovati vrste podataka.

P3. Tablični prikaz podataka

Ishodi učenja: Napraviti pravilan prikaz podataka u tablici.

P4. Grafički prikaz podataka

Ishodi učenja: Napraviti pravilan prikaz podataka stupčastim i kružnim dijagramima te ostalim grafičkim prikazima.

P5. Grafički prikaz podataka u MS Excelu

Ishodi učenja: Nacrtati stupčaste i kružne dijagrame u MS Excelu.

P6. Prikaz grupiranih rezultata: histogram i poligon

Ishodi učenja: Grupirati podatke u razrede te nacrtati histogram i poligon frekvencija.

P7. Mjere centralne tendencije

Ishodi učenja: Objasniti mjere centralne tendencije. Objasniti izraze za izračunavanje aritmetičke sredine, moda, medijana i zajedničke aritmetičke sredine.

P8. Mjere centra grupiranih rezultata

Ishodi učenja: Grupirati podatke u razrede i objasniti izračunavanje aritmetičke sredine na dva načina.

P9. Mjere varijabilnosti negrupiranih podataka

Ishodi učenja: Navesti apsolutne i relativne mjere disperzije. Izračunati standardnu devijaciju za negrupirane rezultate.

P10. Mjere varijabilnosti grupiranih podataka

Ishodi učenja: Navesti apsolutne i relativne mjere disperzije. Izračunati standardnu devijaciju za grupirane rezultate.

P11. Krivulja normalne distribucije

Ishodi učenja: Objasniti osnovne značajke krivulje normalne distribucije. Objasniti razliku standardne devijacije i standardne pogreške.

P12. Z-vrijednost.

Ishodi učenja: Objasniti z-vrijednost. Izračunati granice intervala pouzdanosti.

P13. Testiranje razlike aritmetičkih sredina

Ishodi učenja: Razlikovati tipove uzoraka: zavisne i nezavisne; male i velike. Opisati korištenje tablice B.

P14. Testiranje razlike aritmetičkih sredina velikih nezavisnih uzoraka

Ishodi učenja: Testirati razliku aritmetičkih sredina velikih nezavisnih uzoraka Studentovim t-testom. Koristiti tablicu B.

P15. Testiranje razlike aritmetičkih sredina malih nezavisnih uzoraka

Ishodi učenja: Testirati razliku aritmetičkih sredina malih nezavisnih uzoraka. Primijeniti F test. Koristiti tablicu C.

P16. Testiranje razlike aritmetičkih sredina velikih zavisnih uzoraka

Ishodi učenja: Testirati razliku aritmetičkih sredina velikih zavisnih uzoraka.

P17. Testiranje razlike aritmetičkih sredina malih zavisnih uzoraka

Ishodi učenja: Testirati razliku aritmetičkih sredina malih zavisnih uzoraka. Primijeniti metodu diferencije.

P18. Korelacija

Ishodi učenja: Objasniti pojam linearne korelacije.

P19. Koeficijent korelacije

Ishodi učenja: Objasniti koeficijent korelacije. Izračunati r i odrediti njegovu statističku značajnost.

P20. Pravac regresije.

Ishodi učenja: Metodom najmanjih kvadrata odrediti jednadžbu pravca regresije. Nacrtati točkasti dijagram.

P21. Proporcije

Ishodi učenja: Razlikovati postotke od proporcija. Izračunati proporciju i proporciju suprotne kategorije.

P22. Proporcije nezavisni uzorci

Ishodi učenja: Objasniti način testiranja razlike između proporcija za nezavisne velike i male uzorke.

P23. Proporcije zavisni uzorci

Ishodi učenja: Objasniti način testiranja razlike između proporcija za zavisne velike i male uzorke.

P24. Hi-kvadrat test za dva ili više nezavisnih uzoraka

Ishodi učenja: Izračunati hi-kvadrat test. Primijeniti Yatesovu korekciju. Izraditi tablicu kontingencije.

P25. Hi-kvadrat test za zavisne uzorke

Ishodi učenja: Izračunati McNemarov test

Popis seminara s pojašnjenjem:

/

Popis vježbi s pojašnjenjem:

V1-2. Sumacijski znak

Ishodi učenja: Koristiti znak za sumu. Izračunati postotke i promile u numeričkim zadacima.

V3-4. Mjere centralne tendencije (aritmetička sredina, mod, medijan)

Ishodi učenja: Koristiti algebarske izraze za izračun jednostavne i grupirane aritmetičke sredine.

V5-6. Mjere varijabilnosti (varijanca, standardna devijacija, koeficijent varijabilnosti)

Ishodi učenja: Koristiti algebarske izraze za izračun mjera varijabilnosti za negrupirane i grupirane rezultate.

V7-8. Studentov t test za nezavisne uzorke

Ishodi učenja: Testirati razliku aritmetičkih sredina velikih i malih nezavisnih uzoraka u numeričkim zadacima.

V9-10. Studentov t test za zavisne uzorke

Ishodi učenja: Testirati razliku aritmetičkih sredina za velike i male zavisne uzorke u numeričkim zadacima.

V11-12. Kolokvij 1

V13-14. Korelacija

Ishodi učenja: Izračunati Pearsonov koeficijent korelacije. Odrediti jednadžbu pravca regresije.

V15-16. Proporcije

Ishodi učenja: Izračunati proporcije i standardnu pogrešku proporcije. Primijeniti postupak testiranja razlike proporcija.

V17-18. χ^2 – test

Ishodi učenja: Napraviti hi-kvadrat test za nezavisne i zavisne uzorke.

V19-20. Kolokvij 2

Obveze studenata:

Studenti su obvezni redovito pohađati i aktivno sudjelovati u svim oblicima nastave, pisati oba kolokvija te završni ispit.

Ispit (način polaganja ispita, opis pisanog/usmenog/praktičnog dijela ispita, način bodovanja, kriterij ocjenjivanja):

ECTS bodovni sustav ocjenjivanja:

Ocjenjivanje studenata provodi se prema važećem Pravilniku o studijima i studiranju na Sveučilištu 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 50 bodova, a na završnom ispitu 50 bodova.

Ocjenjivanje studenata vrši se primjenom ECTS (A-F) i brojčanog sustava (1-5). Ocjenjivanje u ECTS sustavu izvodi se apsolutnom raspodjelom.

Od maksimalnih 50 ocjenskih bodova koje je moguće ostvariti tijekom nastave, student treba sakupiti minimum od 25 ocjenskih bodova da bi pristupio završnom ispitu.

Studenti koji su tijekom nastave ostvarili manje od 25 bodova, koji nisu pisali oba kolokvija i koji su izostali s više od 30% nastave nemaju pravo izlaska na završni ispit (upisuju kolegij druge godine).

Uspjeh studenta za predmet izražava se ECTS skalom ocjenjivanja u postocima od 0 do 100% ocjenskih bodova, a ocjenjivanje na temelju konačnog uspjeha obavlja se na sljedeći način:

Izvrstan	5	A	90-100%
Vrlo dobar	4	B	75-89,9%
Dobar	3	C	60-74,9%
Dovoljan	2	D	50-59,9%
Nedovoljan	1	F	0-49,9%

Ocjenske bodove student stječe aktivnim sudjelovanjem u nastavi, izlascima na kolokvije i završni ispit na sljedeći način:

Element ocjenjivanja	Maksimalni bodovi																										
Kolokvij 1 (obvezni) Tri numerička zadatka (deskriptivna statistika, testiranje razlika između skupina)	25																										
Kolokvij 2 (obvezni) Dva numerička zadatka (korelacija, hi-kvadrat test)	25																										
Ispravak kolokvija bit će omogućen u jednom terminu nakon završetka nastave. Na ispravku se može ostvariti maksimalno po 20 bodova iz prvog i drugog kolokvija.																											
Završni ispit (pismeni) Sastoji se od 20 pitanja. Na završnom ispitu student treba riješiti točno minimalno 50% testa (25 bodova). Raspodjela bodova na završnom ispitu: <table border="1"> <tr> <th>Broj točnih odgovora</th><th>Broj bodova</th></tr> <tr> <td>0 – 9,9</td><td>0 (nedovoljan 1)</td></tr> <tr> <td>10</td><td>25 (50% uspješno riješenog ispita)</td></tr> <tr> <td>11</td><td>27,5</td></tr> <tr> <td>12</td><td>30</td></tr> <tr> <td>13</td><td>32,5</td></tr> <tr> <td>14</td><td>35</td></tr> <tr> <td>15</td><td>37,5</td></tr> <tr> <td>16</td><td>40</td></tr> <tr> <td>17</td><td>42,5</td></tr> <tr> <td>18</td><td>45</td></tr> <tr> <td>19</td><td>47,5</td></tr> <tr> <td>20</td><td>50</td></tr> </table>	Broj točnih odgovora	Broj bodova	0 – 9,9	0 (nedovoljan 1)	10	25 (50% uspješno riješenog ispita)	11	27,5	12	30	13	32,5	14	35	15	37,5	16	40	17	42,5	18	45	19	47,5	20	50	50
Broj točnih odgovora	Broj bodova																										
0 – 9,9	0 (nedovoljan 1)																										
10	25 (50% uspješno riješenog ispita)																										
11	27,5																										
12	30																										
13	32,5																										
14	35																										
15	37,5																										
16	40																										
17	42,5																										
18	45																										
19	47,5																										
20	50																										
Ukupno	100																										

Mogućnost izvođenja nastave na stranom jeziku:

Unesite tražene podatke

Ostale napomene (vezane uz kolegij) važne za studente:

Student može izostati s 30% nastave isključivo zbog zdravstvenih razloga što opravdava liječničkom ispričnicom. Nazočnost na svim oblicima nastave je obvezna. Ukoliko student opravdano ili neopravdano izostane s više od 30% nastave ne može nastaviti praćenje kolegija te gubi mogućnost izlaska na završni ispit. Time je prikupio 0 ECTS bodova i ocijenjen je ocjenom F.

SATNICA IZVOĐENJA NASTAVE (za akademsku 2026./2027. godinu)

Raspored nastave

Datum	Predavanja (vrijeme i mjesto)	Seminari (vrijeme i mjesto)	Vježbe	Nastavnik
28.9.2026. (ponedjeljak)	P1 – P3 8:00 – 11:00 Z1	/	/	H. Štrucelj, dipl. psih. – prof.
30.9.2026. (srijeda)	P4 – P6 8:00 – 10:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.
1.10.2026. (četvrtak)	P7 8:00-9:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.
	/	/	V1 – V2 9:00 – 11:00 Informatička uč.	mr. sc. S. Tamarut, dipl. san. ing.
6.10.2026. (utorak)	/	/	V3 – V5 8:00 – 11:00 Informatička uč.	mr. sc. S. Tamarut, dipl. san. ing.
8.10.2026. (četvrtak)	P8 – P10 8:00 – 11:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.
14.10.2026. (srijeda)	P11 – P13 8:00 – 11:00 Z4	/	/	H. Štrucelj, dipl. psih. – prof.
22.10.2026. (četvrtak)	/	/	V6 – V7 8:00 – 10:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.
23.10.2026. (petak)	/	/	V8 – V9 8:00 – 10:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.
28.10.2026. (srijeda)	P14 – P15 8:00 – 10:00 Z4	/	/	H. Štrucelj, dipl. psih. – prof.
30.10.2026. (petak)	P16 – P18 13:00 – 16:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.
2.11.2026. (ponedjeljak)		/	V10 – V12 8:00 – 11:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.
4.11.2026. (srijeda)	P19 – P22 8:00 – 11:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.
6.11.2026. (petak)	P23 – P25 8:00 – 11:00 Informatička uč.	/	/	H. Štrucelj, dipl. psih. – prof.

9.11.2026. (ponedjeljak)	/	/	V13 – V15 11:00 – 14:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.
11.11.2026. (srijeda)	/	/	V16 – V18 8:00 – 11:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.
13.11.2026. (petak)	/	/	V19 – V20 13:00 – 15:00 Informatička uč.	H. Štrucelj, dipl. psih. – prof.

Popis predavanja, seminara i vježbi:

P	PREDAVANJA (tema predavanja)	Broj sati nastave	Mjesto održavanja
P1	Uvod u medicinsku statistiku	1	Z1
P2	Vrste podataka	1	Z1
P3	Tablični prikaz podataka	1	Z1
P4	Grafički prikaz podataka	1	Informatička uč.
P5	Grafički prikaz podataka u MS Excelu	1	Informatička uč.
P6	Prikaz grupiranih rezultata: histogram i poligon	1	Informatička uč.
P7	Mjere centra	1	Informatička uč.
P8	Mjere centra grupiranih rezultata	1	Informatička uč.
P9	Mjere varijabilnosti negrupiranih podataka	1	Informatička uč.
P10	Mjere varijabilnosti grupiranih podataka	1	Informatička uč.
P11	Krivulja normalne distribucije	1	Z4
P12	Krivulja normalne distribucije. Z-vrijednost	1	Z4
P13	Testiranje razlike aritmetičkih sredina	1	Z4
P14	Testiranje razlike aritmetičkih sredina velikih nezavisnih uzoraka	1	Z4
P15	Testiranje razlike aritmetičkih sredina malih nezavisnih uzoraka	1	Z4
P16	Testiranje razlike aritmetičkih sredina velikih zavisnih uzoraka	1	Z5
P17	Testiranje razlike aritmetičkih sredina malih zavisnih uzoraka	1	Z5
P18	Korelacija	1	Z5
P19	Koeficijent korelacije	1	Informatička uč.
P20	Pravac regresije	1	Informatička uč.
P21	Proporcije	1	Informatička uč.
P22	Proporcije nezavisni uzorci	1	Informatička uč.
P23	Proporcije zavisni uzorci	1	Informatička uč.

P24	Hi-kvadrat test za dva ili više nezavisnih uzoraka	1	Informatička uč.
P25	Hi-kvadrat test za zavisne uzorke	1	Informatička uč.
	Ukupan broj sati predavanja	25	

V	VJEŽBE (tema vježbe)	Broj sati nastave	Mjesto održavanja
V1-2	Sumacijski znak	2	Informatička uč.
V3-4	Mjere centralne tendencije (aritmetička sredina, mod, medijan)	2	Informatička uč.
V5-6	Mjere varijabilnosti (varijanca, standardna devijacija, koeficijent varijabilnosti)	2	Informatička uč.
V7-8	Studentov t test za nezavisne uzorke	2	Informatička uč.
V9-10	Studentov t test za zavisne uzorke	2	Informatička uč.
V11-12	Kolokvij 1	2	Informatička uč.
V13-14	Korelacija	2	Informatička uč.
V15-16	Proporcije	2	Informatička uč.
V17-18	χ^2 – test	2	Informatička uč.
V19-20	Kolokvij 2	2	Informatička uč.
	Ukupan broj sati vježbi	20	

	ISPITNI TERMINI (završni ispit)
1.	27. 11. 2026.
2.	11. 12. 2026.
3.	5. 2. 2027.
4.	19. 2. 2027.