

Detaljni izvedbeni nastavni plan za kolegij:

Uvod u statističke metode analize podataka u istraživanju

Akadska godina: 2026/2027

Studij: Prijediplomski sveučilišni studij Biotehnologija i istraživanje lijekova

Kod kolegija: EBIL 216

ECTS bodovi: 3

Jezik na kojem se izvodi kolegij: hrvatski / engleski

Nastavno opterećenje kolegija: 20 P + 10 S (*online 33 % - e-kolegij na sustavu Merlin*)

Preduvjeti za upis kolegija: nema

Nositelj kolegija i kontakt podaci:

Titula i ime: prof. dr. sc. Marta Žuvić

Adresa: Fakultet biotehnologije i razvoja lijekova, soba O-812

tel: 051 584815

e-mail: marta.zuvic@uniri.hr

Vrijeme konzultacija: prema dogovoru

Obavezna literatura:

1. Harvey Motulsky: Intuitive Biostatistics, Oxford University Press, 2018. (dostupno online)

Preporučena dodatna literatura (izborna):

1. A. Petrie, C. Sabin: Medical Statistics at a Glance, Blackwell Science 2000. (dostupno online)

Opis predmeta (sažetak i ciljevi kolegija)

Cilj kolegija Uvod u statističke metode analize podataka u istraživanju je upoznati studente s osnovnim konceptima statistike i statističkog zaključivanja te ih osposobiti za razumijevanje, organizaciju, analizu i interpretaciju podataka u jednostavnim znanstvenim istraživanjima. Kolegij će omogućiti stjecanje znanja i vještina iz područja poznavanja vrsta istraživanja i njihovih značajki, povezanost vjerojatnosti i matematičke statistike, vrsta podataka i razumijevanja njihovih odnosa, izrade baze podataka, izrada grafičkog načina prikaza podataka i distribucija podataka, vrsta i obilježja uzoraka, testiranja statističke hipoteze, vrsta pogreški u statističkom zaključivanju i povezanosti sa snagom istraživanja, odgovarajućeg odabira statističkog testa te iskaza te analize i interpretacije rezultata za: određivanje razlike proporcija, analizu kontingencijskih tablica, određivanje mjera povezanosti podataka, usporedbu uzorka s danom mjerom u populaciji te usporedbu mjera centralne tendencije dva ili više skupina podataka.

Ishodi učenja

1. Strukturirati jednostavnu bazu podataka, odabrati i provesti osnovni statistički test te interpretirati dobivene rezultate.

Detaljni sadržaj kolegija (teme/naslovi predavanja i seminara)

A. Predavanja

- P1. Statistika kao znanstvena disciplina. Od podataka i činjenica do informacije i znanja. Statističke metode u oblikovanju istraživanja.
- P2. Vjerojatnost i statistika. Slučajna varijabla. Vrste slučajnih varijabli. Diskretna slučajna varijabla i binomna raspodjela. Kontinuirana slučajna varijabla i normalna raspodjela. Teorem centralne granice (Central Limit Theorem, CLT).
- P3. Populacija i uzorci, CLT. Obilježja uzorka i vrste uzoraka. Zaključivanje od uzorka na populaciju.
- P4. Deskriptivna statistika. Baza podataka i vrste podataka (kategorički i numerički podaci). Upoznavanje s osnovnim funkcijama statističkog softvera za unos, obradu i grafički prikaz podataka (Excel, Statistica, MedCalc, GraphPad, R). Tablični i grafički prikaz kategoričkih podataka. Numerički podaci - mjere centralne tendencije (aritmetička sredina, medijan, mod) i mjere rasapa i (standardna devijacija, varijanca, interkvartilni raspon). Grafički prikaz numeričkih podataka (histogram, box-plot).
- P5. Inferencijalna statistika. 95% interval pouzdanosti. Statistička hipoteza i njeno testiranje, pogreške (tip I i II). Parametrijski neparametrijski statistički testovi. Izlazni parametri statističkog testiranja. Interpretacija p-vrijednosti i statističke značajnosti u kontekstu istraživačkog pitanja.
- P6. Jednostavne analize kvalitativnih podataka. Proporcija uzorka i populacije. Testiranje razlika proporcija. Kontingencijske tablice i χ^2 (hi-kvadrat) test. Fisherov egzaktni test. Povezanost kvalitativnih varijabli u zavisnim uzorcima- McNemar test. Mjere povezanosti kvalitativnih podataka. Relativni rizik i omjer izgleda (šanse).
- P7. Jednostavne analize numeričkih podataka I. Studentov t-test. Usporedba uzorka s danom mjerom u populaciji (one sample t-test). Usporedba aritmetičkih sredina uzoraka (nezavisnih i zavisnih). Neparametrijske inačice t-testa: Mann Whitney U-test i Wilcoxon test.

B. Seminari (izvještaji)

- S1. Slučajne varijable i raspodjele. Definirati diskretnu slučajnu varijablu, formirati i grafički prikazati odgovarajuću binomnu raspodjelu. Definirati kontinuiranu slučajnu varijablu. Formirati i grafički prikazati normalnu raspodjelu. Prikazati aproksimaciju binomne raspodjele normalnom raspodjelom i interpretirati razliku.
- S2. Struktura baze podataka i deskriptivna statistika. U danoj bazi podataka: identificirati vrste varijabli (kategoričke, numeričke), provjeriti formatiranje i kvalitetu unosa podataka, uvesti bazu u statistički softver, izračunati osnovne deskriptivne pokazatelje (sredina, medijan, standardna devijacija, interkvartilni raspon). Grafički prikazati podatke (histogram, box-plot, stupčasti dijagram).
- S3. Analiza kategoričkih podataka. Za dani istraživački problem i izračunati: proporcije u uzorku, sastaviti kontingencijsku tablicu, provesti χ^2 test, provesti Fisherov egzaktni test, provesti McNemarov test za zavisne uzorke, izračunati relativni rizik (RR) i/ili omjer izgleda (OR). Interpretirati: p-vrijednost, 95% interval pouzdanosti i statističku značajnost rezultata u kontekstu istraživačkog pitanja.
- S4. Analiza numeričkih podataka. Formirati istraživački problem i u odgovarajućem kontekstu usporediti uzorak sa danom mjerom u populaciji (one sample t-test), usporediti dvije skupine pomoću t-testa i neparametrijskih inačica. Interpretirati : p-vrijednost, 95% interval pouzdanosti i statističku značajnost rezultata u kontekstu istraživačkog pitanja.

Obveze, način praćenja i vrednovanje studenata

Od studenata se očekuje redovito pohađanje nastave i aktivan odnos prema nastavi. Obveza studenata na kolegiju jest samostalna izrada 4 seminarska izvještaja koje se predaju na ocjenu putem e-kolegija do odgovarajućeg roka. Opis zadataka i način njihova rješavanja zadaju se u okviru odgovarajuće tematske cjeline. Izrada izvještaja po pojedinoj zadaći predaje u obliku datoteke putem aktivnosti predaje zadaće na e-kolegiju.

Ispitni rokovi

1. ispitni termin 16. lipnja 2027. od 9:00 - 10:00 sati u računalnoj učionici O-339; 2. i 3. ispitni termin u rujnu 2027. prema dogovoru sa studentima.

Formiranje ocjene

Na kolegiju je moguće ostvariti najviše 100,0 ocjenskih bodova. Seminarski izvještaji ocjenjuju se s najviše 10 bodova, a ukupno ocijenjena 4 seminarska izvještaja donosi najviše 70 ocjenskih bodova. Uz uvjet ostvarenost 50% mogućih ocjenskih bodova seminarskih izvještaja (ukupno najmanje 35 ocjenskih bodova), student pristupa završnom ispitu (test), na kojem može steći najviše 30 ocjenskih bodova.

Postotak usvojenog znanja i vještina (ocjenski bodovi)	ECTS ocjena	Brojčana ocjena
90,0 % do 100,0 %	A	Izvrstan (5)
75,0 % do 89,9 %	B	Vrlo dobar (4)
60,0 % do 74,9 %	C	Dobar (3)
50,0 % do 59,9 %	D	Dovoljan (2)
0,0 % do 49,9 %	F	Nedovoljan (1)

Raspored nastave

Datum	Grupa	Vrijeme	Broj sati nastave	Mjesto (učionica)	Oblik nastave	Izvođač
07.06.2027.	svi	12:15-16 h	4	O-268	P1-P3	Prof. dr. sc. Marta Žuvić
08.06.2027.	svi	9-12:30 h	4	O-268	P4	Prof. dr. sc. Marta Žuvić
10.06.2027.	svi	9-12:30 h	4	O-268	P5	Prof. dr. sc. Marta Žuvić
11.06.2027.	svi	9-12:30 h	4	O-268	P6	Prof. dr. sc. Marta Žuvić
14.06.2027.	svi	11:15- 14:45 h	4	O-268	P7	Prof. dr. sc. Marta Žuvić
09.06.2027.	svi	23:55*	2,5	online	S1	Prof. dr. sc. Marta Žuvić
11.06.2027.	svi	23:55*	2,5	online	S2	Prof. dr. sc. Marta Žuvić
14.06.2027.	svi	23:55*	2,5	online	S3	Prof. dr. sc. Marta Žuvić
16.06.2027.	svi	23:55*	2,5	online	S4	Prof. dr. sc. Marta Žuvić

Seminari se izvode kao online nastavne aktivnosti na sustavu Merlin u odgovarajućem e-kolegiju.

**rok za predaju seminarskih izvještaja.*

Dodatne informacije:

Mole se svi studenti da se odazovu vrednovanju kvalitete nastavnog rada nastavnika i suradnika kako bi se na temelju procjena i sugestija mogla unaprijediti nastava na ovom kolegiju. Vrednovanje nastave putem ISVU sustava provodi se aplikacijom „Studomat“ na obrascu definiranom na razini Sveučilišta u Rijeci, a rezultati su anonimni. Više informacija o svim aspektima ovog procesa možete pronaći u Priručniku za kvalitetu studiranja Sveučilišta u Rijeci.

Akadska čestitost

Studenti su dužni poštovati načela akademske čestitosti te se upućuju na dokumente Sveučilišta u Rijeci: *Etički kodeks Sveučilišta u Rijeci* te *Etički kodeks za studente*.