Detaljni izvedbeni plan

Akademska godina: 2025/2026	**Semestar:** Nepoznato
Godina studija: 3	**Studij:** Sociologija (R) (izborni) (Prijediplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Primijenjena statistika

Kratica kolegija: IZBP217

ECTS bodovi: 4	**Šifra kolegija:** 248066

Preduvjeti za upis kolegija: Nema

Ukupno opterećenje kolegija

Vrsta nastave	**Ukupno sati**
Predavanje	30
Vježba	15

Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu

II. NASTAVNO OSOBLJE

Nositelj kolegija

Ime i prezime: Šikić Luka

Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: luka.sikic@unicath.hr	**Telefon:**

Konzultacije: Prema objavljenom rasporedu

Suradnici na kolegiju

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski

Opis kolegija	Cilj ovog predmeta je pružiti studentima snažnu osnovu u statističkim konceptima i tehnikama, te im omogućiti primjenu ovih alata na stvarnim problemima i situacijama. To uključuje učenje kako prikupljati, analizirati i interpretirati podatke, kao i kako koristiti statističke programe i programske jezike u kontekstu statistike. Putem upotrebe primjera iz stvarnog svijeta, vježbi i projekata temeljenih na podacima, studenti će naučiti kako koristiti statističke metode za rješavanje problema u području informacijskih i komunikacijskih znanosti ali i drugim društvenim znanostima.
Očekivani ishodi učenja na razini kolegija	Razlikovati statističke metode za analizu i tumačenje podataka povezanih s komunikacijskim fenomenima, kao što su uporaba medija, javno mnijenje i društvene interakcije. Primijeniti statističku analizu za prepoznavanje trendova, obrazaca i odnosa u komunikacijskim podacima i izvlačenje valjanih zaključaka iz njih. Primijeniti statistički softver za analizu i vizualizaciju komunikacijskih podataka. Povezati statističke tehnike na širok raspon istraživačkih pitanja i različitih disciplina. Demonstrirati rezultate statističkih analiza raznolikoj publici, uključujući istraživače, kreatore politike i širu javnost. Pratiti razvoj statističke metodologije i alata relevantnih za komunikacijske znanosti.
Literatura	
Obavezna	Navarro, D (2018). Learning Statistics with R. University of Adelaide Petz, B. (1997). Osnovne statističke metode za nematematičare. Jatrebarsko: Naklada Slap: 29-206, 237-299, 321-341.
Dopunska	Stevens, J. (2006). Applied Multivariate Statistics for the Social Sciences. Fifth Edition. Lawrence Erlbaum Associates. Aron, A., Aron, E. N., & Coups, E. J. (2017). Statistics for the Behavioral and Social Sciences: A Brief Course. Seventh Edition. Taylor & Francis. Jackson, S. L. (2016). Research Methods and Statistics: A Critical Thinking Approach. Fourth Edition. Cengage Learning. Gravetter, F. J., & Wallnau, L. B. (2017). Data Analysis for the Social Sciences: Integrating Theory and Practice. Second Edition. SAGE Publications. Paolillo, J. C., & Watt, J. H. (2009). Statistics for Communication: A First Course in Applied Statistics. Routledge.
Način ispitivanja i ocjenjivanja	

Polaže se DA	**Isključivo kontinuirano praćenje nastave** NE	**Ulazi u prosjek** DA

Preduvjeti za dobivanje potpisa i polaganje završnog ispita	1. Redovito pohađanje nastave – prisutnost na najmanje 70% nastave prema studijskom programu i izvedbenom nastavnom planu. 2. Uredno izvršene nastavnih obveza u okviru vježbi. 3. Stjecanje minimalnog uspjeha od 35% tijekom nastave unutar zadanih nastavnih aktivnosti kroz vježbe i kolokvije.

Način ocjenjivanja	a) Nastavne aktivnosti – 70% ocjene 1) Vježbe – max. 20 %; 2) 1. kolokvij – max. 25 %; 3) 2. kolokvij – max. 25 %; b) Završni ispit 4) Pismeni ispit – max. 30 % (za prolaz je nužno točno odgovoriti na 50 % postavljenih pitanja). dovoljan (2) – 50-64,9 % dobar (3) – 65-79,9 % vrlo dobar (4) – 80-89,9 % izvrstan (5) – 90-100 %
Način polaganja ispita	1. Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti. 2. Završni pismeni i usmeni ispit (minimum za prolaz na pismenom ispitu je 50% točne riješenosti).

Detaljan prikaz ocjenjivanja unutar Europskoga sustava za prijenos bodova

VRSTA AKTIVNOSTI	ECTS bodovi - koeficijent opterećenja studenata	UDIO OCJENE (%)
Pohađanje nastave	1.2	0
Seminarsko izlaganje	0.56	20
Kolokvij-međuispit	0.7	25
Kolokvij-međuispit	0.7	25
Ukupno tijekom nastave	3.16	70
Završni ispit	0.84	30
UKUPNO BODOVA (nastava+zav.ispit)	4	100

IV. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
1	Uvod u predmet.
2	Uvod u programski jezik R.
3	Deskriptivna statistika.
4	Grafikoni i vizualizacije.
5	Osnove teorije vjerojatnosti.
6	Procjena parametara populacije.
7	Testiranje statističkih hipoteza.
8	Kolokvij.
9	Kategorijalna analiza.
10	Usporedba prosjeka.
11	Linearna regresija.

12	ANOVA.
13	Faktorska ANOVA.
14	Multivarijatni statistički modeli.
15	Kolokvij.
Vježbe	
#	**Tema**
1	Uvod u predmet.
2	Uvod u programski jezik R.
3	Deskriptivna statistika
4	Grafikoni i vizualizacije.
5	Osnove teorije vjerojatnosti
6	Procjena parametara populacije.
7	Testiranje statističkih hipoteza.
8	Kolokvij.
9	Kategorijalna analiza.
10	Usporedba prosjeka.
11	Linearna regresija.
12	ANOVA.
13	Faktorska ANOVA.
14	Multivarijatni statistički modeli
15	Kolokvij.