Detaljni izvedbeni plan

Akademska godina: 2026/2027	**Semestar:** Ljetni
Godina studija: 2	**Studiji:** Sociologija (dvopredmetni) (R) (Prijediplomski) Sociologija (R) (Prijediplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Statistika u društvenim istraživanjima	
Kratica kolegija: 2SOCP1-6	
ECTS bodovi: 8	**Šifra kolegija:** 197145
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	45
Vježba u praktikumu	60
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija	
Ime i prezime: Ježovita Josip	
Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: jjezovita@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	
Suradnici na kolegiju	
Ime i prezime: Martinjak Ivica	
Akademski stupanj/naziv:	**Izbor:**
Kontakt e-mail: ivica.martinjak@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski
Opis kolegija

predmeta	***Ciljevi predmeta:*** Ponavljanje osnova matematike. Upoznavanje sa statističkim opisom odnosa dviju ili više varijabli izraženih na različitim postavkama i racionalom statističkog zaključivanja s uzorka na populaciju. Usvajanje parametrijskih i neparametrijskih po povezanosti među slučajnim varijablama. Ovladavanje računalnim programima predviđenim za korištenje deskriptivne i ***Sadržaj predmeta:*** Upoznavanje sa svrhom statistike u društvenim znanostima. Tipovi mjerenja, vrste mjernih skala, vrste varijabli. Frekvenc grafičko prikazivanje raspodjele rezultata mjerenja. Mjere središnje tendencije. Mjere varijabilnosti rezultata. Osnovni pojm vjerojatnosti. Normalna raspodjela i druge važne raspodjele u društvenim znanostima. Mjere položaja rezultata u skupini Regresija i predviđanje. Koeficijent korelacije. Efikasnost prognoze i rezidualni varijabilitet. Koeficijent multiple korelacije Koeficijenti korelacije na ordinalnim varijablama. Uvod u statističko zaključivanje, vrste uzoraka i zaključivanje o parame uzorka. Teorijske raspodjele važnih statistika – prikaz, svojstva i stupnjevi slobode. Uvod u testiranje hipoteza, problem h razlika između aritmetičkih sredina dva nezavisna uzoraka. Model zavisnih uzoraka i testiranje razlika između aritmetičk Testiranje razlika među proporcijama. Tipovi grešaka u statističkom testiranju razlika i računanje statističke snage testa. T koeficijenata korelacije i testiranje razlike između dvaju koeficijenata korelacije. Neparametrijska statistika i hi-kvadrat tes između dvaju nezavisnih uzoraka. Neparametrijski testovi razlika između dvaju zavisnih uzoraka. Neparametrijski testov (zavisnih i nezavisnih).

Očekivani ishodi učenja na razini kolegija	1. Opisati osnovnu statističku teoriju i stručne statističke pojmove. 2. Povezati proces grupiranja podataka i rezultata s njihovim tabličnim i grafičkim prikazivanjem. 3. Koristiti osnovne deskriptivne statističke pokazatelje i testove. 4. Protumačiti prednosti i nedostatke osnovnih deskriptivnih statističkih pokazatelja i testova. 5. Primijeniti statističko inferencijalno zaključivanje u društvenim istraživanjima. 6. Koristiti statističke postupke i metodološke istraživačke procedure u društvenim istraživanjima. 7. Primijeniti rad u statističkom programu.	
Literatura		
Obavezna	Petz, B., Kolesarić, V. i Ivanec, D. (2012). *Petzova statistika: Osnovne statističke metode za nematematičare.* Jastrebarsko: Naklada Slap	
Dopunska	Milas, G. (2005). Istraživačke metode u psihologiji i drugim društvenim znanostima. Jastrebarsko: Naklada Slap.	
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) 2. Stjecanje minimalno 35% bodova (od ukupno 100 bodova) tijekom nastave 3. Položena provjera znanja iz Repetitorija matematike	
Način ocjenjivanja		

Način stjecanja bodova:

1. **Nastavne aktivnosti – 70%:**

a) 4 kolokvija – 4×15 = 60 %

b) Rad na vježbama = 10 %

2. **Završni usmeni ispit – 30%**

Brojčana ljestvica ocjenjivanja studentskog rada:

izvrstan (5) – 90 do 100% bodova

vrlo dobar (4) – 80 do 89,9% bodova

dobar (3) – 65 do 79,9% bodova

dovoljan (2) – 50 do 64,9% bodova

nedovoljan (1) – 0 do 49,9 % bodova

Način polaganja ispita

1. Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti
2. Završni 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	1.68	0
Kolokvij-međuispit	3.36	60
Rad na vježbama	0.56	10
Ukupno tijekom nastave	**5.6**	**70**
Završni ispit	2.4	30
UKUPNO BODOVA (nastava+zav.ispit)	**8**	**100**

IV. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
1	Uvodno predavanje. Repetitorij matematike.

2	Uvod u mjerenje, vrste mjernih skala, vrste varijabli. Frekvencije i grupiranje rezultata.
3	Grafičko prikazivanje raspodjele rezultata mjerenja.
4	Mjere središnje tendencije – aritmetička sredina, mod i medijan. Mjere varijabilnosti rezultata.
5	1. kolokvij
6	Normalna raspodjela i druge važne raspodjele u društvenim znanostima.
7	Uvod u statističko zaključivanje (inferencijalnu statistiku), vrste uzoraka i zaključivanje o parametrima populacije na temelju uzorka.
8	2. kolokvij
9	Uvod u testiranje hipoteza (1): testiranje značajnosti razlike aritmetičke sredine i neke zadane vrijednosti (one sample t-test).
10	Uvod u testiranje hipoteza (2): testiranje značajnosti razlike aritmetičkih sredina dva uzorka.
11	Bivarijatna korelacija. Koeficijent multiple korelacije i koeficijent parcijalne korelacije. Regresijska analiza.
12	3. kolokvij
13	HI-kvadrat (Goodness of fit test i tablica kontingencije).
14	Neparametrijski testovi - dva nezavisna uzorka.
15	4. kolokvij
Vježbe u praktikumu	
#	**Tema**
1	Repetitorij matematike.
2	Repetitorij matematike.
3	Repetitorij matematike.
4	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
5	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
6	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
7	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
8	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
9	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
10	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
11	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
12	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
13	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
14	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).
15	Zadaci na temu predavanja. Korištenje računalne učionice po potrebi (SPSS i Excel programi).