Detailed Course Syllabus

Academic year: 2026/2027	**Semester:** Summer semester
Year of study: 2	**Study Program:** Sociologija (dvopredmetni) (R) (Prijediplomski) Sociologija (R) (Prijediplomski)

I. BASIC COURSE INFORMATION

Name: Statistika u društvenim istraživanjima	
Abbreviation: 2SOCP1-6	
ECTS: 8	**Code:** 197145
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	45
Practicum exercise	60
Class Time and Place: HKS - according to the published schedule	

II. TEACHING STAFF

Course Holder	
Name and Surname: Ježovita Josip	
Academic Degree:	**Professional Title:** docent
Contact E-mail: jjezovita@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	
Course Assistant	
Name and Surname: Martinjak Ivica	
Academic Degree:	**Professional Title:**
Contact E-mail: ivica.martinjak@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski
Course Description

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).

Educational Outcomes	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.	
Textbooks and Materials		
Required	Petz, B., Kolesarić, V. i Ivanec, D. (2012). *Petzova statistika: Osnovne statističke metode za nematematičare.* Jastrebarsko: Naklada Slap	
Supplementary	Milas, G. (2005). Istraživačke metode u psihologiji i drugim društvenim znanostima. Jastrebarsko: Naklada Slap.	
Examination and Grading		
To Be Passed DA	**Exclusively Continuous Assessment** NE	**Included in Average Grade** DA
Prerequisites to Obtain Signature and Take Final Exam	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	
Examination Manner		

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

Grading Manner

1. Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti
2. Završni usmeni ispit (minimum za prolaz na pismenom ispitu je 50% točne riješenosti)

Detailed Overview of Grading within ECTS

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. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
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]	
#	**Topic**
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).