Detailed Course Syllabus

Academic year: 2024/2025	**Semester:** Unknown
Year of study: 3	**Study programme:** Sociologija (R) (elective) (Prijediplomski)

I. BASIC COURSE INFORMATION

Name: Primijenjena statistika

Abbreviation: IZBP217

ECTS: 4	**Code:** 248066

Prerequisites: No

Total Course Workload

Teaching Mode	**Total Hours**
Lecture	30
Exercise	15

Class Time and Place: HKS - according to the published schedule

II. TEACHING STAFF

Course Holder

Name and Surname: Šikić Luka

Academic Degree:	**Professional Title:** docent
Contact E-mail: luka.sikic@unicath.hr	**Telephone:**

Office Hours: According to the published schedule

Course Assistant

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski

Course Description	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.
Educational Outcomes	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.
Textbooks and Materials	
Required	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.
Supplementary	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.
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 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.

Examination Manner	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 %
Grading Manner	1. Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti. 2. Završni pismeni i 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	1.2	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. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
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]	
#	**Topic**
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.