Detailed Course Syllabus

Academic year: 2024/2025	**Semester:** Summer semester
Year of study: 2	**Study programme:** Komunikologija - Znanstveno istraživanje medija i odnosi s javnošću (R) (Diplomski)

I. BASIC COURSE INFORMATION

Name: Obrada podataka	
Abbreviation:	
ECTS: 4	**Code:** 248065
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Seminar	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:**
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 osnovno razumijevanje rada s podacima kroz upoznavanje sa principima, tehnikama i alatima koji se koriste za prikupljanje, čišćenje, analizu i vizualizaciju podataka. Neki od specifičnih ciljeva uključuju upoznavanje studenata s tehnologijama koje se koriste u radu s podacima, poput programskih jezika, sustava za pohranu i upravljanje podacima te statističkog softvera. Studenti će također naučiti kako učitavati, obrađivati i čistiti podatke iz različitih izvora, uključujući strukturirane i nestrukturirane podatke. Kolegij će studente upoznati sa osnovama statističkih metoda i strojnog učenja za analizu i modeliranje podataka, poput regresije, klasifikacije, grupiranja, smanjenja dimenzionalnosti i analize teksta. Kolegij će studentima omogućiti razumijevanje kako se podaci i njihova analiza mogu primijeniti u različitim područjima i industrijama s naglaskom na područje komunikacijskih i informacijskih znanosti. Kroz praktično iskustvo rada sa podatcima studenti će naučiti kako efektivno komunicirati podatkovno usmjerene spoznaje putem vizualizacija, izvješća i prezentacija.
Educational Outcomes	dentificirati procese, alate i tehnike koje se koriste u obradi podataka. Razlikovati programske jezike i statistički softver koji se koriste u obradi podataka. Osmisliti istraživanje na osnovi statističkih tehnika i tehnika strojnog učenja za analizu i modeliranje podataka. Osmisliti i provesti obradu podataka i komunicirati rezultate putem vizualizacija, izvješća i prezentacija u odgovarajućem formatu. Primijeniti suvremene načine obrade podataka relevantne za komunikacijske i informacijske znanosti
Textbooks and Materials	
Required	Kelleher, J. D. i Tierney, B. (2021). *Znanost o podatcima.* Zagreb: Naklada Mate. Grolemund, G., and Wickham, H. (2017). *R for Data Science*. O'Reilly Media
Supplementary	Grolemund, G., and Wickham, H. (2017). *R for Data Science*. O'Reilly Media. Wickham H (2016). *ggplot2: Elegant Graphics for Data Analysis*. Springer-Verlag New York. Silge, J. and Robinson, D. (2017) . Text Mining with R: A Tidy Approach. O'Reilly Media
Examination and Grading	
To Be Passed	**Exclusively Continuous Assessment** / **Included in Average Grade**
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	1. a) Nastavne aktivnosti – 70% ocjene 1) Vježbe – max. 20 %; 2) 1. kolokvij – max. 25 %; 3) 2. kolokvij – max. 25 %; 1. 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
Rad na vježbama	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 kolegij.
2	Tradicionalne vrste podataka.
3	Moderni izvori podataka i veliki podatci.
4	Osnove programskog jezika R.
5	Manipulacija i prilagodba podataka.
6	Prikupljanje podataka sa interneta.
7	Rad sa bazama podataka.
8	Kolokvij.
9	Deskriptivna statistika.
10	Univarijatna statistička analiza.
11	Multivarijatna statistička analiza.
12	Uvod u strojno učenje.
13	Strojna analiza teksta.
14	Prezentacija, objava i dijeljenje rezultata i markdown sintaksa.
15	Kolokvij.