Detailed Course Syllabus

Academic year: 2026/2027	**Semester:** Winter semester
Year of study: 1	**Study programme:** Psihologija (R) (Diplomski)

I. BASIC COURSE INFORMATION

Name: Regresijska analiza	
Abbreviation: PSD16	
ECTS: 4	**Code:** 101727
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Practicum exercise	15
Class Time and Place: HKS - according to the published schedule	

II. TEACHING STAFF

Course Holder	
Name and Surname: Pandžić Mario	
Academic Degree:	**Professional Title:** docent
Contact E-mail: mario.pandzic@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	
Course Assistant	

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski	
Course Description	**Ciljevi predmeta**: Stjecanje znanja i sposobnosti upotrebe regersijskih modela analize podataka na razini razumijevanja, planiranja istraživanja i provedbe analize. **Sadržaj predmeta**: Uvod, priprema i kontrola baze podataka, izrada istraživačkih nacrta, jednostavna linearna regresija, multipla regresija, diskriminantna analiza, regresijska analiza s kategoričkim prediktorima, prikaz podataka, interpretacija analiza, izvještavanje o istraživanju – pisanje poglavlja „Rezultati“.

Educational Outcomes	Procijeniti ispunjenost pretpostavki regresijskih modela na temelju dijagnostičkih pokazatelja. Dizajnirati istraživački plan primjeren za primjenu regresijskih modela u empirijskom istraživanju. Analizirati podatke primjenom regresijskih modela u računalnom programu. Izraditi poglavlje „Rezultati" znanstvenog rada s nalazima regresijskih modela u standardnom formatu. Etički odgovorno upravljati analitičkim odlukama i rezultatima regresijskog modeliranja.
Textbooks and Materials	
Required	Field, A. (2013). *Discovering statistics using IBM SPSS Statistics*. SAGE Publications.
Supplementary	Tabachnick, B. G. i Fidell, L. S. (2013). *Using multivariate statistics*. Pearson. Hayes, A. F. (2022). *Introduction to Mediation, Moderation, and Conditional Process Analysis: A Regression-Based Approach*. The Guilford Press.
Examination and Grading	

To Be Passed DA	**Exclusively Continuous Assessment** NE	**Included in Average Grade** DA

Prerequisites to Obtain Signature and Take Final Exam	Redovito pohađanje nastave (prisutnost na najmanje 70% nastave). Stjecanje minimalno 35 bodova (od mogućih 70 bodova) tijekom nastave.
Examination Manner	Način stjecanja bodova: **1. Nastavne aktivnosti – 70 % ocjene:** • Kolokvij 1 – 30 % • Kolokvij 2 – 30 % • Izvještaj – 10 % **2. Završni ispit – 30 % ocjene** 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	Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti. Završni pismeni 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

Kolokvij 1	0.84	30
Kolokvij 2	0.84	30
Izvještaj	0.28	10
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, osnovni pojmovi i definicije, korelacijski nacrti
2	Kovarijanca i korelacija
3	Jednostavna linearnu regresiju: izračun regresijskih koeficijenata i koeficijenta determinacije, interpretacija
4	Jednostavna linearnu regresiju: standardna pogreška prognoze, značajnost modela i regresijskih koeficijenata, standardizirani rezultati.
5	Kolokvij 1
6	Multipla linearna regresija: model, regresijski koeficijenti i interpretacija
7	Multipla linearna regresija: grafički prikaz, zasebni doprinosi prediktora, supresorski učinci, veličina učinka i planiranje veličine uzorka
8	Multipla linearna regresija: stupnjeviti i hijerarhijski modeli
9	Preduvjeti multiple linearne regresije: skale mjerenja, normalnost distribucije, dijagnostika ekstrema i utjecajnih sudionika
10	Preduvjeti multiple linearne regresije: linearnost, homoscedascitet, multikolinearnost, distribucija i neovisnost reziduala
11	Osnovni moderacijski model i interpretacija
12	Osnovni medijacijski model i interpretacija
13	Kolokvij 2
14	Pretvaranje multikategorijalnih varijabli u binarne, binarni prediktori, logistička regresija
15	Diskriminantna analiza

[Vježbe u praktikumu]

#	Topic

1	Uvod, priprema i kontrola baze podataka u SPSS-u
2	Zadaci na temu predavanja u računalnom statističkom programu
3	Zadaci na temu predavanja u računalnom statističkom programu
4	Zadaci na temu predavanja u računalnom statističkom programu
5	Kolokvij 1
6	Zadaci na temu predavanja u računalnom statističkom programu
7	Zadaci na temu predavanja u računalnom statističkom programu
8	Zadaci na temu predavanja u računalnom statističkom programu
9	Zadaci na temu predavanja u računalnom statističkom programu
10	Zadaci na temu predavanja u računalnom statističkom programu
11	Zadaci na temu predavanja u računalnom statističkom programu
12	Zadaci na temu predavanja u računalnom statističkom programu
13	Kolokvij 2
14	Zadaci na temu predavanja u računalnom statističkom programu
15	Izvještaj