Detaljni izvedbeni plan

Akademska godina: 2025/2026	**Semestar:** Zimski
Godina studija: 1	**Studij:** Psihologija (R) (Diplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Regresijska analiza	
Kratica kolegija: PSD16	
ECTS bodovi: 4	**Šifra kolegija:** 101727
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	30
Vježba u praktikumu	15
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija

Konzultacije: Prema objavljenom rasporedu

Suradnici na kolegiju

Ime i prezime: Pandžić Mario

Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: mario.pandzic@unicath.hr	**Telefon:**

Konzultacije: Prema objavljenom rasporedu

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski

Opis kolegija	**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“.
Očekivani ishodi učenja na razini kolegija	Utvrditi preduvjete primjene regresijskih modela. Izraditi nacrt istraživanja primjeren za provedbu modela regresijske i/ili diksriminantne analize. Provesti regresijsku i diskriminantnu analizu u računalnom programu. Samostalno napisati poglavlje „Rezultati“ znanstvenog rada u kojem je kao statistički postupak upotrijebljena regresijska odnosno diskriminantna analiza.
Literatura	
Obavezna	• Rawlings, J. O., Pantula, S. G., & Dickey, D. A. (1998). *Applied regression analysis: a research tool*. Springer Science & Business Media. (dostupno u digitalnom obliku)
Dopunska	• Chen, X., Ender, P., Mitchell, M. and Wells, C. (2003). *Regression with SPSS*, from https://www.ats.ucla.edu/stat/spss/webbooks/reg/default.htm • Znanstveni radovi u kojima je korištena regresijska analiza

Način ispitivanja i ocjenjivanja

Polaže se DA	**Isključivo kontinuirano praćenje nastave** NE	**Ulazi u prosjek** DA

Preduvjeti za dobivanje potpisa i polaganje završnog ispita	Redovito pohađanje nastave (prisutnost na najmanje 70% nastave) Stjecanje minimalno 35 bodova (od mogućih 70 bodova) tijekom nastave (kolokviji + izvještaj o istraživanju)
Način ocjenjivanja	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. Nastavne aktivnosti – 70% ocjene: • 1. kolokvij – 25%; • 2. kolokvij – 25%; • Pismeni izvještaj o provedenom istraživanju – 20 %; 2. Završni ispit – 30 % ocjene

Detaljan prikaz ocjenjivanja unutar Europskoga sustava za prijenos bodova

VRSTA AKTIVNOSTI	ECTS bodovi - koeficijent opterećenja studenata	UDIO OCJENE (%)
Pohađanje nastave	1.2	0
Kolokvij-međuispit	0.7	25

Kolokvij-međuispit	0.7	25
Izvještaj	0.6	20
Ukupno tijekom nastave	3.2	70
Završni ispit	0.8	30
UKUPNO BODOVA (nastava+zav.ispit)	4	100

IV. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
1	Uvod, osnovni pojmovi i definicije, korelacijski nacrti
2	Jednostavna linearna regresija
3	Kolokvij 1, diskusija, rekapitulacija
4	Uvod u multiplu regresijsku analizu
5	Parcijalna i semi-parcijalna korelacija
6	Preduvjeti za regresijsku analizu (veličina uzorka, normalnost distribucije, linearnost)
7	Homoscedascitet, multikolinearnost, tretman ekstremnih vrijdnosti
8	Analiza distribucije reziduala
9	Pretvaranje multi-kategorijalnih varijabli u binarne indikator varijable
10	Hijerarhijska regresijska analiza
11	Izvještavanje o provedenoj regresijskoj analizi
12	Logistička regresija
13	Diskriminantna analiza
14	Kolokvij 2, diskusija, rekapitulacija
15	Usmena izlaganja o provedenim istraživanjima

Vježbe u praktikumu

#	Tema
1	Uvod, priprema i kontrola baze podataka u SPSS-u
2	Jednostavna linearna regresija
3	Kolokvij 1, diskusija, rekapitulacija
4	Izrada nacrta istraživanja
5	Izrada nacrta istraživanja
6	Provjera normalnosti distribucije, linearnosti među varijablama i multikolinearnosti
7	Provjera homoscedasciteta i tretman ekstremnih vrijednosti
8	Provođenje multiple regresijske analize
9	Provođenje multiple regresijske analize
10	Hijerarhijska regresijska analiza
11	Hijerarhijska regresijska analiza

12	Analiza distribucije reziduala
13	Izvještavanje o provedenoj regresijskoj analizi
14	Izvještavanje o provedenoj regresijskoj analizi
15	Prezentacija provedenih istraživanja