Detaljni izvedbeni plan

Akademska godina: 2026/2027	**Semestar:** Ljetni
Godina studija: 1	**Studij:** Psihologija (R) (Prijediplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Temeljne statističke metode	
Kratica kolegija: PSIHP2-4	
ECTS bodovi: 5	**Šifra kolegija:** 294878
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	30
Vježba u praktikumu	45
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija	
Ime i prezime: Glavaš Dragan	
Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: dragan.glavas@unicath.hr	**Telefon:**
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	
Ime i prezime: Rihtar Stanko	
Akademski stupanj/naziv:	**Izbor:** naslovni viši predavač

Kontakt e-mail: stanko.rihtar@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	
Ime i prezime: Grubor Patrik	
Akademski stupanj/naziv:	**Izbor:** asistent
Kontakt e-mail: pgrubor@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski

Opis kolegija	**Ciljevi kolegija:** Cilj kolegija je usvajanje temeljnih statističkih metoda za analizu razlika, povezanosti i predviđanja u psihologijskim istraživanjima. Student se osposobljava za razumijevanje generalnog linearnog modela kao okvira za više statističkih postupaka, za odabir prikladnog testa s obzirom na istraživački problem i pretpostavke modela te za provedbu analiza i izvještavanje o rezultatima u računalnom programu. **Sadržaj kolegija:** Generalni linearni model kao okvir statističkih analiza. Kovarijanca i korelacija. Pravac regresije, predviđanje i standardna pogreška prognoze. Višestruka, parcijalna i semiparcijalna korelacija. Veličina učinka i statistička snaga te planiranje veličine uzorka. Regresijska analiza s kategorijalnim prediktorima. Jednosmjerna analiza varijance na nezavisnim i zavisnim uzorcima. Parametrijsko i neparametrijsko testiranje, pretpostavke modela i odabir prikladnog statističkog testa. Neparametrijske metode za nezavisne i zavisne uzorke. Hi-kvadrat test. Alternativni koeficijenti korelacije.
Očekivani ishodi učenja na razini kolegija	Odabrati odgovarajući inferencijalni statistički pristup (parametrijski ili neparametrijski) s obzirom na istraživački problem, obilježja podataka i pretpostavke modela. Interpretirati parametre i rezultate korelacijskih, osnovnih regresijskih i jednosmjernih ANOVA modela sukladno istraživačkim pitanjima. Procijeniti veličinu učinka, statističku snagu i pouzdanost zaključaka. Primijeniti odgovarajuće statističke analize u računalnom statističkom programu, uključujući provjeru pretpostavki modela i izračun relevantnih statističkih pokazatelja. Integrirati rezultate statističkih analiza u istraživački izvještaj u skladu s istraživačkim ciljevima i metodologijom istraživanja. Izvijestiti o rezultatima statističkih analiza u skladu sa znanstvenim i etičkim standardima.
Literatura	
Obavezna	Petz, B., Kolesarić, V., & Ivanec, D. (2025). *Petzova statistika: Osnovne statističke metode za nematematičare* (2. promijenjeno izd.). Naklada Slap.
Dopunska	Howell, D. C. (2012). *Statistical methods for psychology* (8th ed.). Wadsworth, Cengage Learning. Field, A. (2013). *Discovering statistics using IBM SPSS Statistics* (4th ed.). SAGE Publications

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 minimalnog uspjeha od 50 % ocjene iz kolegija tijekom nastave

Način ocjenjivanja	1. Nastavne aktivnosti – 70 % ukupne ocjene - Kolokvij 30 bodova - Izvještaj 30 bodova - Kratke provjere znanja 10 bodova 2. Završni ispit – 30 % ukupne ocjene 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	Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti Završni usmeni ispit

Detaljan prikaz ocjenjivanja unutar Europskoga sustava za prijenos bodova

VRSTA AKTIVNOSTI	**ECTS bodovi -** koeficijent opterećenja studenata	**UDIO OCJENE** (%)
Pohađanje nastave	1.9	0
Kolokvij	0.93	30
Izvještaj	0.93	30
Kratke provjere znanja	0.31	10
Ukupno tijekom nastave	**4.07**	**70**
Završni ispit	0.93	30
UKUPNO BODOVA (nastava+zav.ispit)	**5.0**	**100**

IV. TJEDNI PLAN NASTAVE

Predavanja

#	**Tema**
1	Generalni linearni model kao okvir statističkih analiza
2	Kovarijanca i korelacija

3	Pravac regresije, predviđanje i standardna pogreška prognoze
4	Višestruka, parcijalna i semiparcijalna korelacija: uvod u regresijsku analizu
5	Veličina učinka
6	Statistička snaga i planiranje veličine uzorka
7	Regresijska analiza s kategorijalnim prediktorima
8	Uvod u analizu varijance
9	Jednosmjerna analiza varijance na nezavisnim uzorcima
10	Jednosmjerna analiza varijance na zavisnim uzorcima
11	Parametrijsko i neparametrijsko testiranje: pretpostavke i odluke o odabiru statističkog testa
12	Neparametrijske metode za nezavisne uzorke
13	Neparametrijske metode za zavisne uzorke
14	Hi-kvadrat test
15	Alternativni koeficijenti korelacije
Vježbe u praktikumu	
#	**Tema**
1	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
2	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
3	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
4	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
5	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
6	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
7	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
8	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
9	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
10	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
11	Kolokvij
12	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
13	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
14	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
15	Izvještaj