Detaljni izvedbeni plan

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

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Uvod u statistiku	
Kratica kolegija: PSIHP1-3	
ECTS bodovi: 4	**Šifra kolegija:** 294870
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	30
Vježba u praktikumu	30
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija	
Ime i prezime: Pandžić Mario	
Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: mario.pandzic@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	
Suradnici na kolegiju	
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 ovladavanje temeljnim pojmovima deskriptivne statistike te osposobljavanje studenata za prikupljanje, uređivanje, prikazivanje i interpretaciju podataka u psihologiji. Student stječe znanja o vrstama varijabli, mjernim ljestvicama, distribucijama rezultata, mjerama centralne tendencije, raspršenja i položaja rezultata te razvija sposobnost samostalne primjene osnovnih postupaka statističke obrade podataka u računalnom programu. Predmet također uvodi studenta u osnovne koncepte statističkog zaključivanja i inferencijalnih postupaka kao podlogu za usvajanje složenijih statističkih metoda. **Sadržaj kolegija:** Uvod u statistiku i njezinu ulogu u psihologiji. Varijable, mjerne ljestvice i osnovni tipovi podataka. Frekvencije, grupiranje i grafički prikaz podataka. Mjere središnje tendencije i mjere varijabilnosti. Oblik raspodjele rezultata, normalna raspodjela, standardizacija rezultata i mjere položaja. Osnove teorije vjerojatnosti. Uzorak i populacija u statističkom zaključivanju. Raspodjela uzorkovanja i teorem središnje granice. Granice sigurnosti i logika testiranja statističkih hipoteza. Testiranje razlika za jedan uzorak te za dva nezavisna i dva zavisna uzorka.
Očekivani ishodi učenja na razini kolegija	Analizirati podatke primjenom odgovarajućih statističkih postupaka, uzimajući u obzir obilježja varijabli, mjernih ljestvica i raspodjele podataka. Interpretirati položaj rezultata u unutar raspodjele i osnovne pojmove vjerojatnosti. Razlikovati statističko zaključivanje od opisivanja. Primijeniti statistički računalni program za unos, pripremu, osnovnu statističku obradu i prikazivanje podataka. Objasniti temeljne pojmove raspodjele uzorkovanja i teorema središnje granice te postupke testiranja hipoteza za jedan uzorak, dva nezavisna i dva zavisna uzorka. Profesionalno i etički odgovorno prezentirati statističke rezultate.
Literatura	
Obavezna	Petz, B., Kolesarić, V. i Ivanec, D. (2025). *Petzova statistika*: *Osnovne statističke metode za nematematičare* (2. promijenjeno izd.). Naklada Slap.
Dopunska	Howell, D. C. (2012). *Statistical methods for psychology*. Wadsworth, Cengage Learning. Field, A. (2013). *Discovering statistics using IBM SPSS Statistics*. 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

Način stjecanja bodova:

1. Nastavne aktivnosti – 70 % ukupne ocjene:

- Kolokvij 30 bodova
- Izvještaj 30 bodova
- Kratke provjere znanja 10 bodova

2. Završni ispit – 30 % ukupne 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

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	1.5	0
Kolokvij	0.75	30
Izvještaj	0.75	30
Kratke provjere znanja	0.25	10
Ukupno tijekom nastave	**3.25**	**70**
Završni ispit	0.75	30
UKUPNO BODOVA (nastava+zav.ispit)	**4**	**100**

IV. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
1	Definicija i svrha statistike. Uloga statistike u psihologiji
2	Uvod u mjerenje u psihologiji, varijable, mjerne skale
3	Frekvencije, grupiranje podataka i grafički prikaz podataka
4	Mjere središnje tendencije
5	Mjere varijabilnosti
6	Oblik raspodjele rezultata
7	Normalna raspodjela
8	Standardizacija rezultata i mjere položaja
9	Osnove teorije vjerojatnosti
10	Uzorak i populacija u statističkom zaključivanju
11	Raspodjela uzorkovanja i teorem središnje granice
12	Granice sigurnosti i testiranje statističkih hipoteza
13	Testiranje statističkih hipoteza, t-test za jedan uzorak
14	Testiranje razlika aritmetičkih sredina nezavisnih uzoraka
15	Testiranje razlika aritmetičkih sredina zavisnih uzoraka
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	Kolokvij
10	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
11	Zadaci na temu predavanja. Korištenje računalnog statističkog programa po potrebi.
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