Detailed Course Syllabus

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

I. BASIC COURSE INFORMATION

Name: Uvod u statistiku	
Abbreviation: PSIHP1-3	
ECTS: 4	**Code:** 294870
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Practicum exercise	30
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	
Name and Surname: Rihtar Stanko	
Academic Degree:	**Professional Title:** naslovni viši predavač
Contact E-mail: stanko.rihtar@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	
Name and Surname: Grubor Patrik	
Academic Degree:	**Professional Title:** asistent
Contact E-mail: pgrubor@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski

Course Description	**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.
Educational Outcomes	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.
Textbooks and Materials	
Required	Petz, B., Kolesarić, V. i Ivanec, D. (2025). *Petzova statistika*: *Osnovne statističke metode za nematematičare* (2. promijenjeno izd.). Naklada Slap.
Supplementary	Howell, D. C. (2012). *Statistical methods for psychology*. Wadsworth, Cengage Learning. Field, A. (2013). *Discovering statistics using IBM SPSS Statistics*. SAGE Publications.

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 minimalnog uspjeha od 50 % ocjene iz kolegija tijekom nastave.

Examination Manner

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

Grading Manner

Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti.
Završni usmeni ispit.

Detailed Overview of Grading within ECTS

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. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
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]	
#	**Topic**
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