Detailed Course Syllabus

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

I. BASIC COURSE INFORMATION

Name: Temeljne statističke metode	
Abbreviation: PSIHP2-4	
ECTS: 5	**Code:** 294878
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Practicum exercise	45
Class Time and Place: HKS - according to the published schedule	

II. TEACHING STAFF

Course Holder	
Name and Surname: Glavaš Dragan	
Academic Degree:	**Professional Title:** docent
Contact E-mail: dragan.glavas@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	
Course Assistant	
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	
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 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.
Educational Outcomes	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.
Textbooks and Materials	
Required	Petz, B., Kolesarić, V., & Ivanec, D. (2025). *Petzova statistika: Osnovne statističke metode za nematematičare* (2. promijenjeno izd.). Naklada Slap.
Supplementary	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

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	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
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	1.9	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. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
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]	
#	**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	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