Detailed Course Syllabus

Academic year: 2024/2025	**Semester:** Summer semester
Year of study: 1	**Study programme:** Psihologija (R) (Prijediplomski)

I. BASIC COURSE INFORMATION

Name: Deskriptivna statistika	
Abbreviation: PSIP2-4	
ECTS: 6	**Code:** 97885
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: 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 predmeta: Ovladavanje numeričkim i grafičkim opisom rezultata kvantitativnog pristupa čovjekovom ponašanju te usvajanje vjerojatnosnog poimanja psihičkih procesa i čovjekova ponašanja. Upoznavanje sa statističkim opisom odnosa dviju ili više varijabli izraženih na različitim mjernim skalama. Ovladavanje računalnim programima predviđenim za korištenje deskriptivne statistike u praksi.

Sadržaj predmeta: Upoznavanje sa svrhom statistike u društvenim znanostima. Tipovi mjerenja, vrste mjernih skala, vrste varijabli. Frekvencije i grupiranje rezultata te grafičko prikazivanje raspodjele rezultata mjerenja. Mjere središnje tendencije. Mjere varijabilnosti rezultata. Osnovni pojmovi kombinatorike i matematičke vjerojatnosti. Normalna raspodjela i druge važne raspodjele u društvenim znanostima. Mjere položaja rezultata u skupini (z-vrijednosti, centili, decili). Regresija i predviđanje. Koeficijent korelacije. Efikasnost prognoze i rezidualni varijabilitet. Koeficijent multiple korelacije i koeficijent parcijalne korelacije. Koeficijenti korelacije na ordinalnim varijablama.

Educational Outcomes

Usporediti obilježja mjernih ljestvica. Odabrati prikladne mjere središnje tendencije i raspršenja ovisno o distribuciji podataka i vrsti statističkog testa. Procijeniti vjerojatnost određene vrijednosti parametra i odnos promatranih pojava. Samostalno koristiti računalni program za unos, pripremu, prikazivanje i jednostavnije statističke postupke obrade podataka. Razviti odgovornost preciznog prikazivanja deskriptivnih podataka.

Textbooks and Materials

Required

- Petz, B., Kolesarić, V. i Ivanec, D. (2012). *Petzova statistika: Osnovne statističke metode za nematematičare.* Jastrebarsko: Naklada Slap.
- Milas, G. (2005). *Istraživačke metode u psihologiji i drugim društvenim znanostima.* Jastrebarsko: Naklada Slap.

Supplementary

- Howell, D.C. (1998). *Statistical Methods for Psychology.* Belnout, CA: Duxbury Press.
- Pavlić, I. (1970). *Statistička teorija i primjena.* Zagreb: Tehnička knjiga.

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 minimalno 35% bodova (od ukupno 100 bodova) tijekom nastave

Examination Manner

Način stjecanja bodova:

1. Nastavne aktivnosti – 70% ocjene:

- 1. kolokvij 30%
- 2. kolokvij 30%
- kratke provjere znanja – 10 %

2. Završni ispit – 30% 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 pismeni ispit (minimum za prolaz na pismenom ispitu je 50% točne riješenosti)

Detailed Overview of Grading within ECTS

VRSTA AKTIVNOSTI	ECTS bodovi - koeficijent opterećenja studenata	UDIO OCJENE (%)
Pohađanje nastave	1.9	0
Kolokvij-međuispit	1.23	30
Kolokvij-međuispit	1.23	30
Rad na vježbama	0.41	10
Ukupno tijekom nastave	**4.77**	**70**
Završni ispit	1.23	30
UKUPNO BODOVA (nastava+zav.ispit)	**6**	**100**

IV. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
1	Uvodno predavanje. Što je statistika? Svrha statistike. Važni pojmovi.
2	Uvod u mjerenje, vrste mjernih skala, vrste varijabli
3	Frekvencije i grupiranje rezultata te grafičko prikazivanje raspodjele rezultata mjerenja
4	Osnovni pojmovi vjerojatnosti, mjere središnje tendencije
5	Osnovni pojmovi vjerojatnosti, mjere središnje tendencije
6	Mjere varijabilnosti rezultata (2.dio)
7	Normalna raspodjela i druge važne raspodjele u društvenim znanostima
8	Standardizacija varijable i mjere i mjere položaja rezultata u skupini (z-vrijednosti, centili, decili)
9	Kolokvij 1
10	Uvod u statističko zaključivanje (inferencijalnu statistiku), vrste uzoraka i zaključivanje o parametrima populacije na temelju uzorka
11	Teorijska raspodjela aritmetičke sredine (teorem središnje granice), svojstva i stupnjevi slobode
12	Uvod u testiranje hipoteza: testiranje razlika između aritmetičke sredine i fiksne vrijednosti
13	Uvod u testiranje hipoteza: testiranje razlika između aritmetičkih sredina velikih uzoraka (nezavisnih i zavisnih)
14	Uvod u testiranje hipoteza, problem homogenosti varijance i testiranje razlika između aritmetičkih sredina malih uzoraka (nezavisnih i zavisnih)
15	Kolokvij 2

[Vježbe u praktikumu]

#	Topic
1	Upoznavanje s primjerima i primjenom statistike
2	Tipovi mjerenja, vrste mjernih skala, vrste varijabli
3	Zadaci na temu predavanja. Upoznavanje SPSS programskog paketa
4	Zadaci na temu predavanja. Unos podataka u SPSS statistički program
5	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
6	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
7	Kolokvij 1
8	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
9	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
10	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
11	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
12	Kolokvij 2
13	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
14	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)
15	Zadaci na temu predavanja. Korištenje računalne učionice (SPSS statističkog programa po potrebi)