Detailed Course Syllabus

Academic year: 2026/2027	**Semester:** Summer semester
Year of study: 2	**Study programme:** Psihologija (R) (Prijediplomski)

I. BASIC COURSE INFORMATION

Name: Modeli analize varijance	
Abbreviation: PSIP4-5	
ECTS: 5	**Code:** 97914
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Seminar	15
Practicum exercise	30
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: Užarević Katarina	
Academic Degree:	**Professional Title:**
Contact E-mail: katarina.uzarevic@unicath.hr	**Telephone:**
Office Hours: According to the published schedule	

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski

Course Description	Ciljevi kolegija: Stjecanje znanja i sposobnosti upotrebe ANOVA modela analize podataka na razini razumijevanja, planiranja istraživanja, provedbe statističke analize i izvještavanja o dobivenim rezultatima. Sadržaj kolegija: Statističko zaključivanje i testiranje hipoteza. Uvod u analizu varijance i jednosmjerna ANOVA. Provjera pretpostavki modela analize varijance. Apriori i naknadne (višestruke) usporedbe. Intervali pouzdanosti i veličina učinka. Transformacije rezultata. Interpretacija rezultata i znanstveno izvještavanje. Jednosmjerna ANOVA s ponovljenim mjerenjima. Dvosmjerna i višesmjerna ANOVA. Glavni efekti, interakcija, jednostavni efekti i interpretacija rezultata. Višestruke usporedbe, snaga i veličina učinka. Miješani nacrti i interpretacija rezultata. Analiza kovarijance. Multivarijatna analiza varijance. Multivarijatna analiza varijance i multivarijatna analiza kovarijance.
Educational Outcomes	Razlikovati teorijske osnove modela analize varijance i razlike između jednofaktorske, višefaktorske i ponovljenih mjerenja, uključujući pretpostavke modela. Prosuditi populacijske parametre u kontekstu ANOVA modela primjenom odgovarajućih statističkih analiza. Provesti odgovarajuće ANOVA postupke u računalnom statističkom paketu, uključujući provjeru pretpostavki te planirane i post-hoc usporedbe. Samostalno kreirati istraživački izvještaj temeljen na jasno oblikovanim istraživačkim pitanjima i hipotezama, primjenjujući odgovarajuće ANOVA modele. Izvijestiti o rezultatima ANOVA analiza u skladu sa znanstvenim i etičkim standardima struke.
Textbooks and Materials	
Required	Milas, G. (2005). Istraživačke metode u psihologiji i drugim društvenim znanostima. Jastrebarko: Naklada Slap. Petz, B., Kolesarić, V., Ivanec, D. (2012). Petzova statistika: Osnovne statističke metode za nematematičare. Jastrebarsko. Naklada Slap. Winer, B. J. (1962). Statistical Principles in Experimental Design. New York: McGraw-Hill.
Supplementary	Braver, S.L., MacKinnon, D.P. i Page, M. (2003). Levine's Guide to SPSS for Analysis of Variance. Psychology Press. Doncaster, P. i Davey, A.J.H. (2007). Analysis of Variance and Covariance. Cambridge: Cambridge University Press. Howell, D.C. (2010). Statistical Methods for Psychology. Belmont, CA: Wadsworth, Cengage Learning.
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 (kolokviji)
Examination Manner	Način stjecanja bodova: 1. Nastavne aktivnosti – 70% ocjene: 1. kolokvij – 40% 2. kolokvij – 30% 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	0.93	30
Izvještaj	0.93	30
Aktivnost na nastavi	0.31	10
Ukupno tijekom nastave	4.07	70
Završni ispit	0.93	30
UKUPNO BODOVA (nastava+zav.ispit)	5	100

IV. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
1	Statističko zaključivanje i testiranje hipoteza
2	Invervali pouzdanosti i veličina učinka
3	Uvod u analizu varijance i jednosmjerna ANOVA
4	Provjera pretpostavki modela analize varijance i transformacije
5	Apriori i naknadne (višestruke) usporedbe
6	Intepretacija rezultata i znanstveno izvještavanje
7	Jednosmjerna ANOVA s ponavljanim mjerenjima
8	Dvosmjerna i višesmjerna ANOVA
9	Glavni efekti, interakcija, jednostavni efekti i interpretacija rezultata I. dio (Kolokvij 1)
10	Glavni efekti, interakcija, jednostavni efekti i interpretacija rezultata II. dio
11	Mješoviti nacrti i interpretacija rezultata
12	Analiza kovarijance
13	Mješoviti modeli s križanim fiksnim i slučajnim faktorima
14	Multivarijatna analiza varijance (Kolokvij 2)
15	Multivarijatna analiza varijance i kovarijance

[Seminari]

#	Topic
1	Statističko zaključivanje - mjere povezanosti i testiranje razlike (veličina efekta)
2	Pretpostavke analize varijance i narušene pretpostavke
3	Što činiti kad s pretpostavke narušene?
4	Planirani kontrasti i post hoc testovi - koji test odabrati?
5	Analiza trenda
6	Neparametrijske metode

7	Dvosmjerna ANOVA
8	Glavni efekti, interakcija i jednostavni efekti - što nam je i u kojem slučaju zanimljivo
9	Kolokvij 1
10	Ponovljena mjerenja: što je sferičnost?
11	Kontrasti i veličina učinka u ponovljenim mjerenjima
12	Alternativni nacrti. Miješoviti modeli s fiksnim i slučajnim faktorima.
13	Kada koristimo analizu kovarijance? Preduvjeti i interpretacija
14	Kolokvij 2
15	Kada i zašto koristimo MAN(C)OVU?
[Vježbe u praktikumu]	
#	**Topic**
1	Zadaci na temu predavanja (Statističko zuključivanje - mjere povezanosti i testiranje razlike (veličina efekta). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
2	Zadaci na temu predavanja (Pretpostavke analize varijance i narušene pretpostavke). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
3	Zadaci na temu predavanja (Što činiti kad s pretpostavke narušene?). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
4	Zadaci na temu predavanja (Neparametrijske metode). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
5	Zadaci na temu predavanja (Apriori i naknadne usporedbe). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
6	Zadaci na temu predavanja (Invervali pouzdanosti i veličina učinka). Korištenje računalne učionice (jednosmjerna ANOVA s ponavljanim mjerenjima) (SPSS statističkog programa) po potrebi
7	Zadaci na temu predavanja (Intepretacija rezultata i znanstveno izvještavanje). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
8	Zadaci na temu predavanja (Jednosmjerna ANOVA s ponavljanim mjerenjima). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
9	Kolokvij 1
10	Zadaci na temu predavanja (Dvosmjerna i višesmjerna ANOVA). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
11	Zadaci na temu predavanja (Glavni efekti, interakcija, jednostavni efekti i interpretacija rezultata). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
12	Zadaci na temu predavanja(Miješoviti modeli s fiksnim i slučajnim faktorima). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
13	Zadaci na temu predavanja (Analiza kovarijance). Korištenje računalne učionice (SPSS statističkog programa) po potrebi
14	Kolokvij 2
15	Zadaci na temu predavanja (MAN(C)OVA). Korištenje računalne učionice (SPSS statističkog programa) po potrebi