Detaljni izvedbeni plan

Akademska godina: 2026/2027	**Semestar:** Ljetni
Godina studija: 2	**Studij:** Psihologija (R) (Prijediplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Modeli analize varijance	
Kratica kolegija: PSIP4-5	
ECTS bodovi: 5	**Šifra kolegija:** 97914
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	30
Seminar	15
Vježba u praktikumu	30
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija	
Ime i prezime: Glavaš Dragan	
Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: dragan.glavas@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	
Suradnici na kolegiju	
Ime i prezime: Užarević Katarina	
Akademski stupanj/naziv:	**Izbor:**
Kontakt e-mail: katarina.uzarevic@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski

Opis kolegija	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.
Očekivani ishodi učenja na razini kolegija	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.
Literatura	
Obavezna	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.
Dopunska	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.
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 minimalno 35% bodova (od ukupno 100 bodova) tijekom nastave (kolokviji)
Način ocjenjivanja	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
Način polaganja ispita	Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti Završni pismeni ispit (minimum za prolaz na pismenom ispitu je 50% točne riješenosti)
Detaljan prikaz ocjenjivanja unutar Europskoga sustava za prijenos bodova	

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. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
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

#	Tema
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	
#	**Tema**
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