Detaljni izvedbeni plan

Akademska godina: 2025/2026	**Semestar:** Ljetni
Godina studija: 1	**Studij:** Psihologija (R) (Diplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Faktorska analiza	
Kratica kolegija: PSD25	
ECTS bodovi: 4	**Šifra kolegija:** 101734
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	30
Vježba u praktikumu	30
Mjesto i vrijeme održavanja nastave: HKS – prema objavljenom rasporedu	

II. NASTAVNO OSOBLJE

Nositelj kolegija	
Ime i prezime: Pandžić Mario	
Akademski stupanj/naziv:	**Izbor:** docent
Kontakt e-mail: mario.pandzic@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	
Suradnici na kolegiju	

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski	

Opis kolegija	**Ciljevi predmeta**: Stjecanje znanja i sposobnosti upotrebe modela faktorske analize podataka na razini razumijevanja, planiranja istraživanja i provedbe analize. **Sadržaj predmeta**: Osnove matričnog računa. Geometrija vektorskog prostora. Osnovna logika faktorske analize. Modeli ekstrakcije faktora. Model na glavne komponente. Matrica faktorske strukture. Određivanje broja zadržanih faktora. Faktorski bodovi u komponentnoj analizi. Faktorska analiza zajedničkih faktora. Komunalitet i procjena komunaliteta. Matrica faktorske strukture i faktorskog obrasca. Grafička rotacija. Ortogonalne analitičke rotacije. Kosokutne analitičke rotacije. Modeli faktorske analize na transformiranim matricama. Faktori viših redova. Usporedba analize glavnih komponenata i analize zajedničkih faktora. Ostali modaliteti faktorske analize. Korištenje faktora u drugim multivarijatnim analizama.
Očekivani ishodi učenja na razini kolegija	Raščlaniti preduvjete za provedbu i korake postupka provedbe faktorske analize. Odabrati odgovarajući model faktorske analize sukladno teorijskim pretpostavkama. Samostalno kreirati istraživački izvještaj temeljem istraživačkog cilja i analize u softveru. Etički odgovorno upravljati podatcima i rezultatima faktorske analize.
Literatura	
Obavezna	• Fulgosi, A. (1988). *Faktorska analiza*. Zagreb: Školska knjiga.
Dopunska	• Field, A. (2013). *Discovering statistics using IBM SPSS statistics*. London: SAGE Publications Ltd. • Harman, H. H. (1967). *Modern factor analysis*. Chicago: University of Chicago Press. • Reyment, R., Jöreskog, K. G. (1996). *Applied factor analysis in the natural sciences*. Cambridge: Cambridge University Press. • Rummel, R. J. (1970). *Applied Factor Analysis*. Evanston: Northwestern University Press.
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
Način ocjenjivanja	Način stjecanja bodova: **1. Nastavne aktivnosti – 70% ocjene:** • kolokvij – 25% • kolokvij – Računalni praktikum – 25 % • seminarski rad – 20 % **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	1.2	0
Kolokvij-međuispit	0.7	25
Kolokvij-međuispit	0.7	25
Seminarski rad	0.56	20
Ukupno tijekom nastave	**3.16**	**70**
Završni ispit	0.84	30
UKUPNO BODOVA (nastava+zav.ispit)	**4**	**100**

IV. TJEDNI PLAN NASTAVE

Predavanja

#	Tema
1	Vektori i vektorski prostor, algebarske operacije s vektorima, duljina i kut vektora
2	Matrice i tipovi matrica, algebarske operacije s matricama
3	Uvod u FA - statistička logika, osnovna jednadžba i dijelovi varijance manifestnih varijabli
4	Analiza glavnih komponenata - razlozi korištenja, korelacijska matrica i matrica faktorske strukture, procjena komunaliteta, varijanca i kriteriji zadržavanja faktora
5	Analiza zajedničkih faktora - razlozi korištenja, reducirana korelacijska matrica, načini određivanja komunaliteta
6	Rotacije faktorskih osi - tipovi, analitiče rotacije, ortogonalne rotacije, odnosi varijablititeta faktora, komunaliteta, saturacija i ukupne varijance prije i nakon rotacije
7	Rotacije faktorskih osi - kosokutne rotacije, razlozi korištenja, matrice faktorske strukture i faktorskog obrasca
8	Faktorski bodovi - razlozi korištenja, načini procjene, usporedbe faktorskih rješenja
9	Modeli FA - razlozi korištenja, image analiza, alfa analiza
10	Modaliteti FA - R tehnika, Q tehnika
11	Uvod u konfirmatornu FA
12	Kolokvij - međuispit
13	Kolokvij - računalni praktikum
14	Predaja završnog izvještaja
15	Završno predavanje

Vježbe u praktikumu

#	Tema
1	Uvodne vježbe - plan rada i podjela istraživačkih zadataka
2	Razlozi primjene i korištenja FA u psihologijskim istraživanjima

3	Osnovni pojmovi i preduvjeti FA, upoznavanje SPSS okruženja
4	Koraci provedbe FA unutar SPSS okruženja - donošenje odluke o pogodnosti R matrice
5	Koraci provedbe FA unutar SPSS okruženja - odabir metode ekstrakcije faktora
6	Koraci provedbe FA unutar SPSS okruženja - donošenje odluke o broju ekstrahiranih faktora - Osnovni kriteriji i Monte Carlo paralelne analize
7	Koraci provedbe FA unutar SPSS okruženja - ortogonalne i kosokutne rotacije faktora
8	Koraci provedbe FA unutar SPSS okruženja - interpretacija faktorskih rješenja
9	Usporedba faktorskih rješenja - faktorski bodovi i indeksi kongruencije / korelacije u SPSS-u i Excelu
10	Izvještavanje rezultata FA
11	Koraci prije provedbe konfirmatorne FA - parcijalna KFA u SPSS-u i Excelu
12	Kolokvij - međuispit
13	Kolokvij - računalni praktikum
14	Predaja završnog izvještaja
15	Završne vježbe