Detailed Course Syllabus

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

I. BASIC COURSE INFORMATION

Name: Faktorska analiza	
Abbreviation: PSD25	
ECTS: 4	**Code:** 101734
Prerequisites: No	
Total Course Workload	
Teaching Mode	**Total Hours**
Lecture	30
Practicum exercise	30
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	

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski

Course Description	**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.
Educational Outcomes	Raščlaniti preduvjete za provedbu i korake postupka provedbe faktorske analize. Odabrati odgovarajući model faktorske analize sukladno teorijskim pretpostavkama. Izraditi istraživački izvještaj koji kritički interpretira rezultate faktorske analize u odnosu na teorijski okvir istraživanja. Etički odgovorno upravljati odlukama i rezultatima faktorske analize.
Textbooks and Materials	
Required	Fulgosi, A. (1988). *Faktorska analiza*. Školska knjiga.
Supplementary	Field, A. (2013). *Discovering statistics using IBM SPSS statistics*. SAGE Publications. Tabachnick, B. G. i Fidell, L. S. (2013). *Using multivariate statistics*. Pearson.
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 mogućih 70 bodova) tijekom nastave.
Examination Manner	Način stjecanja bodova: **1. Nastavne aktivnosti – 70 % ocjene:** • Kolokvij – 35 % • Izvještaj – 35 % **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	1.5	0
Kolokvij	0.875	35
Izvještaj	0.875	35
Ukupno tijekom nastave	**3.25**	**70**
Završni ispit	0.75	30
UKUPNO BODOVA (nastava+zav.ispit)	**4**	**100**

IV. WEEKLY CLASS SCHEDULE

[Predavanja]

#	Topic
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
13	Izvještaj
14	Analiza klastera
15	Pregled preostalih multivarijatnih analiza

[Vježbe u praktikumu]	
#	**Topic**
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
13	Izvještaj
14	Provedba klaster analize unutar SPSS okruženja - hijerarhijsko grupiranje
15	Provedba klaster analize unutar SPSS okruženja - nehijerarhijsko grupiranje