Detaljni izvedbeni plan

Akademska godina: 2025/2026	**Semestar:** Ljetni
Godina studija: 2	**Studij:** Psihologija (R) (izborni) (Diplomski)

I. OSNOVNI PODACI O KOLEGIJU

Naziv kolegija: Osnove strukturalnog modeliranja	
Kratica kolegija: IZBD289	
ECTS bodovi: 3	**Šifra kolegija:** 292092
Preduvjeti za upis kolegija: Nema	
Ukupno opterećenje kolegija	
Vrsta nastave	**Ukupno sati**
Predavanje	15
Seminar	15
Vježba u praktikumu	15
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: Rihtar Stanko	
Akademski stupanj/naziv:	**Izbor:** naslovni viši predavač
Kontakt e-mail: stanko.rihtar@unicath.hr	**Telefon:**
Konzultacije: Prema objavljenom rasporedu	

III. DETALJNI PODACI O KOLEGIJU

Jezik na kojem se nastava održava: Hrvatski	
Opis kolegija	**Ciljevi kolegija**. Upoznavanje s osnovama strukturalnog modeliranja (structural equation modeling, SEM). Stjecanje sposobnosti teorijske artikulacije problema, uz postavljanje eksplicitnih hipoteza ili istraživačkih pitanja ovisno o konfirmatornoj ili eksploratornoj strategiji istraživanja. Operacionalizacija hipoteza / istraživačkih pitanja primjereno mogućnostima i dosegu strukturalnog modeliranja: optimalna artikulacija teorijskog i mjernog modela, uz izbjegavanje uobičajenih pogrešaka. Ovladavanje računalnom analizom modela upotrebom namjenskog sofwarea (Amos, R - lavaan, Mplus, Phyton...). **Sadržaj kolegija**. Osvrt na stečeno nužno predznanje: faktorska analiza i višestruka regresija s intervenirajućim varijablama (medijatorima i moderatorima). Sagledavanje spomenutog predznanja iz perspektive teorijski validnog strukturalnog modeliranja: SEM kao fleskibilnija proširena regresija koja omogućuje modeliranje složenijih odnosa između varijabli (manifestnih i latentnih) u širem teorijskom okviru. Artikulacija strukturalnog i mjernog modela upotrebom dijagrama puta (path). Pogreške u mjerenim varijablama kao jamstvo robusnosti. Utjecaj veličine uzorka: minimalan broj opservacija po procijenjenom parametru; minimalna veličina cijelog uzorka (zbog složenosti SEM zahtijeva veće uzorke od regresijske analize). Uobičajene pogreške: pretjerano kompliciranje (previše varijabli i/ili odnosa koji otežavaju procjenu i interpretaciju modela); zanemarivanje pokazatelja slaganja (fit indices); neopravdane pretpostavke o kauzalnosti – SEM provjerava odnose, a kauzalnost ovisi o nacrtu istraživanja (npr. eksperimentalnom ili korelacijskom). Priprema prikupljenih podataka za analizu: distribucije varijabli, nedostajući (missing) i odstupajući podatci (outliers). Provjera i mjere empirijske validnosti pretpostavljenog modela putem slaganja s emprijski prikupljenom građom: hi-kvadrat test, RMSEA, CFI, SRMR. Konfirmatorna faktorska analiza. Formalna pravila i zahtjevi prezentacije i diseminacije nalaza.
Očekivani ishodi učenja na razini kolegija	Ovladati vještinom operacionalizacije ciljeva i hipoteza (istraživačkih pitanja) primjereno naknadnoj analizi modeliranjem strukturalnih jednadžbi. Samostalno artikulirati optimalan i uravnotežen model, uz izbjegavanje pretjerane složenosti, redundantnosti i uobičajenih metodoloških pogrešaka. Operacionalizirati mjerni model i moći provjeriti njegovo post-hoc slaganje s teorijskim. Primjereno interpretirati nalaze, a potom ih prikazati i diseminirati na formalno korektan i elegantan način (primjeren publici, od znanstvene do šire javnosti).
Literatura	
Obavezna	Raykov, T., Marcoulides, G. A. (2006). *A First Course in Structural Equation Modelling*. Lawrence Erlbaum Associates. Schumaker, R. E., Lomax, R. G. (2022). *A beginner's Guide to Structural Equation Modeling*. Taylor and Francis Group, LLC.
Dopunska	Hoyle, R. (Ed.) (2023). Handbook of Structural Equation Modeling (2nd ed.). Guilford Press. Kline, R. B. (2015). *Principles and Practice of Structural Equation Modeling* (4th ed). The Guilford 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 (najmanje 70 %); stjecanje minimalno 50 % bodova tijekom nastave.
Način ocjenjivanja	1. Nastavne aktivnosti – 70 % ocjene (seminarski rad 50 %, aktivno sudjelovanje u nastavi 20 %). 2. Završni usmeni 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

Usmeni.

Detaljan prikaz ocjenjivanja unutar Europskoga sustava za prijenos bodova

VRSTA AKTIVNOSTI	ECTS bodovi - koeficijent opterećenja studenata	UDIO OCJENE (%)
Pohađanje nastave	0	0
Seminarsko izlaganje	1,5	50
Kolokvij - međuispit	0	0
Aktivnost na vježbama i seminaru	0,6	20
Ukupno tijekom nastave	2,1	70
Završni ispit	0,9	30
UKUPNO BODOVA (nastava+zav.ispit)	3	100

IV. TJEDNI PLAN NASTAVE

Vježbe

#	Tema
1	Ma kako ovo izbrisati?
2	Upoznavanje s namjenskim softwareom: Amos.
3	Upoznavanje s namjenskim softwareom: R - lavaan.
4	Upoznavanje s namjenskim softwareom: Mplus.
5	Upoznavanje s namjenskim softwareom: Phyton.
6	Samostalna softverska izrada dijagrama puta za vlastiti model.
7	Prezentacija vlastitih modela i zajdničko dotjerivanje: prvi dio.
8	Prezentacija vlastitih modela i zajdničko dotjerivanje: drugi dio.
9	Samostalno odlučivanje o izboru uzoraka za analizu.
10	Samostalan izbor ili pribavljanje empirijskih podataka.

11	Softverska provjera metrijskih kvaliteta izabranih ili prikupljenih podataka.
12	Softverska provjera slaganja teorijskih i mjernih modela.
13	Softverske prilagodbe modela ovisno o zajedničkoj raspravi.
14	Softverska provjera prilagođenih modela.
15	Softverska provedba konfirmatorne faktorske analize na podmodelu.
16	Sofverska izrada prikaza nalaza namijenjenih stručnoj i široj javnosti.
Predavanja	
#	**Tema**
1	Što je strukturalno modeliranje? Faktorska i regresijska analiza u širem kontekstu.
2	Od šire teorije do konceptualnog modela.
3	Operacionalizacija konceptualnog modela primjerena analizi upotrebom SEM-a.
4	Vrste varijabli, parceliranje čestica i njihova upotreba u okviru SEM-a.
5	Vizualna artikulacija teorijskog i mjernog modela upotrebom dijagrama puta (path).
6	Načini redukcije suviše složenih ili predeterminiranih modela.
7	Načini izbjegavanja ostalih pogrešaka pri artikulaciji modela (kvazi-kauzalnost, nemogućnost provjere slaganja teorijskog i mjernog modela).
8	Izbor uzorka vodeći računa o (parametarskoj) složenosti modela.
9	Izbor i pribavljanje empirijskih podataka za analizu upotrebom SEM-a.
10	Analiza mjerenih varijabli i mogući postupci neutralizacije izrazitije asimetrije, odstupajućih i nedostajećih vrijednosti.
11	Provjera slaganja teorijskog modela s empirijskim nalazima upotrebom uobičajenih pokazatelja (hi-kvadrat, RMSEA, CFI, SRMR). Provjera robusnosti modela zbog pogrešaka u mjerenim varijablama.
12	Interpretacija i rasprava o rezultatima.
13	Mogućnost reartikulacije postojećeg modela i/ili izbor novog i primjena na novim podatcima.
14	Konfirmatorna faktorska analiza na izabranom podmodelu i fakultativni uvid u posebne teme: objašnjenje multitrait–multimethod modela, eksploratornog SEM-a, mještvitih modela i SEM-a na malim uzorcima.
15	Formalni kriteriji i optimalni načini prezentacije i diseminacije nalaza stručnoj i široj javnosti.
Seminari	
#	**Tema**
1	Uvodni dogovor o načinu i tempu izrade seminara.
2	Artikulacija prijedloga seminarskih tema.
3	Izbor tema i teorijskih okvira.
4	Zajednička analiza primjerenosti tema i teorijskih okvira za analizu upotrebom sustava strukturalnih jednadžbi.
5	Dorada tema i operacionalizacija modela ovisno o prethodnoj raspravi.
6	Optimalizacija gotovog modela za primjenu u okviru SEM-a.
7	Zajednička rasprava o uočenim pogreškama prilikom optimalizacije.
8	Pojedinačni izbor i zajednička rasprava o uzorcima.
9	Izbor/pribavljanje podataka i zajednička rasprava o njihovoj primjerenosti za analizu.
10	Rasprava o repertoaru potrebnih provjera empirijskih podataka.

11	Zajednička prezentacija izabranih teorijskih i mjernih modela.
12	Rasprava o rezultatima provjere slaganja teorijskih i mjernih modela.
13	Prijedlozi o eventualno potrebnim prilagodbama modela.
14	Izbor podmodela za provjeru konfirmatornom faktorskom analizom.
15	Konceptualni prijedlozi načina prikazivanja nalaza stručnoj i široj javnosti.