Detailed Course Syllabus

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

I. BASIC COURSE INFORMATION

Name: Osnove strukturalnog modeliranja

Abbreviation: IZBD289

ECTS: 3	**Code:** 292092

Prerequisites: No

Total Course Workload

Teaching Mode	**Total Hours**
Lecture	15
Seminar	15
Practicum exercise	15

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: Rihtar Stanko

Academic Degree:	**Professional Title:** naslovni viši predavač
Contact E-mail: stanko.rihtar@unicath.hr	**Telephone:**

Office Hours: According to the published schedule

III. DETAILED COURSE INFORMATION

Teaching Language: Hrvatski

Course Description	**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.
Educational Outcomes	Formulirati istraživačke ciljeve i hipoteze za primjenu modeliranja strukturalnih jednadžbi. Dizajnirati strukturni model uz izbjegavanje pretjerane složenosti, redundantnosti i metodoloških pogrešaka. Procijeniti usklađenost mjernog modela s teorijskim modelom. Interpretirati rezultate modeliranja strukturalnih jednadžbi. Prezentirati rezultate modeliranja strukturalnih jednadžbi u skladu sa znanstvenim i stručnim standardima.
Textbooks and Materials	
Required	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.
Supplementary	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.
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 (najmanje 70 %); stjecanje minimalno 50 % bodova tijekom nastave.
Examination Manner	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

Grading Manner

Kontinuirano vrednovanje studentskog rada kroz nastavne aktivnosti

Završni usmeni ispit (minimum za prolaz je 50% bodova)

Detailed Overview of Grading within ECTS

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. WEEKLY CLASS SCHEDULE

[Vježbe]

#	Topic
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.
[Seminari]	
#	**Topic**
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.
[Vježbe u praktikumu]	
#	**Topic**
1	Uvodno predavanje
2	Vježbe vezane uz temu predavanja
3	Vježbe vezane uz temu predavanja
4	Vježbe vezane uz temu predavanja
5	Vježbe vezane uz temu predavanja
6	Vježbe vezane uz temu predavanja
7	Vježbe vezane uz temu predavanja
8	Vježbe vezane uz temu predavanja
9	Vježbe vezane uz temu predavanja
10	Vježbe vezane uz temu predavanja
11	Vježbe vezane uz temu predavanja
12	Vježbe vezane uz temu predavanja

13	Vježbe vezane uz temu predavanja
14	Vježbe vezane uz temu predavanja
15	Završni osvrt
[Predavanja]	
#	**Topic**
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.