

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Maja Ojsteršek

Ana Lucija Škrjanec

**Ocenjevanje zanesljivosti merjenja s koeficienti Cronbach alfa, omega
in koeficienti iz metode SEM: uporaba Monte Carlo simulacij**

Magistrsko delo

Ljubljana, 2012

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Maja Ojsteršek

Ana Lucija Škrjanec

Mentor: doc. dr. Aleš Žiberna

**Ocenjevanje zanesljivosti merjenja s koeficienti Cronbach alfa, omega
in koeficienti iz metode SEM: uporaba Monte Carlo simulacij**

Magistrsko delo

Ljubljana, 2012

ZAHVALA

Iskreno se zahvaljujeva mentorju doc. dr. Alešu Žiberni za motivacijo in pomoč pri pisanju tega magistrskega dela.

Ocenjevanje zanesljivosti merjenja s koeficienti Cronbach alfa, omega in koeficienti iz metode SEM: uporaba Monte Carlo simulacij

V družboslovju poteka raziskovanje pogosto tudi z merjenjem, ki mora biti za doseg objektivnosti zanesljivo in veljavno. Zanesljivost pomeni, da pridemo do enakih rezultatov, če merjenje izvedemo večkrat na istih enotah, ocena zanesljivosti pa je izražena s koeficientom. V magistrski nalogi je bilo preučevano ocenjevanje zanesljivosti merjenja. Primerjali smo ocene zanesljivosti koeficientov Cronbach alfa, omega in koeficientov iz treh modelov metode SEM. Cronbach alfa je najpogosteje uporabljen koeficient za ocenjevanje zanesljivosti, koeficient omega pa večkrat poda boljšo oceno zanesljivosti, a ga raziskovalci ne uporabijo tako pogosto. Metoda modeliranja struktturnih enačb (SEM) je statistična metodologija, ki izhaja iz faktorske analize in simultanega modeliranja enačb, njena priljubljenost in pogostost uporabe pa narašča. Zanesljivost smo ocenjevali tudi s kongeneričnim, vzporednim in tau-enakovrednim SEM modelom, pri čemer ima vsak specifične predpostavke. Generiranje podatkov, na katerih je bilo izvedeno merjenje in podane ocene zanesljivosti, je bilo izvedeno z Monte Carlo simulacijami. Simulacije so metoda, ki raziskovalcu omogoča manipuliranje z vhodnimi parametri, poljubno določanje merskih pogojev in poznavanje prave (populacijske) vrednosti, kar je v realnosti skoraj nemogoče, hitra in mnogokratna ponovitev postopka pa povečuje možnost posploševanja rezultatov. Simulirali smo 72 realno možnih situacij v merjenju, in sicer glede na tri velikosti vzorca, različne in enake faktorske uteži v kombinaciji z enakimi in različnimi variancami, postopek ocenjevanja zanesljivosti merjenja z naštetimi koeficienti s simulacijami smo ponovili 1.000-krat s programskim paketom R. Cilj naloge je podati predloge, kateri postopek in koeficient za ocenjevanje zanesljivosti je na določenih podatkih in situaciji v merjenju najbolj primeren oz. je najbližje pravi zanesljivosti.

Ključne besede: ocenjevanje zanesljivosti merjenja, Cronbach alfa koeficient, koeficient omega, modeliranje struktturnih enačb (SEM), Monte Carlo simulacije.

Estimating measurement reliability with Cronbach's alpha, Omega and the SEM method coefficients: Use of Monte Carlo simulations

Social science research often uses measurements that require reliability and validity to achieve objectivity. Reliability means yielding the same or compatible results if the measurements are performed repeatedly on the same units, while the estimate of reliability is expressed by a coefficient. This Master's Thesis studies different estimations of measurement reliability. Reliability estimations of Cronbach's alpha and Omega coefficients and of the coefficients of three different models of the structural equation modelling (SEM) method were compared. Cronbach's alpha is the most commonly used coefficient for reliability estimation, but the Omega coefficient is often better though is less often used method at estimating reliability. The SEM method is a statistical methodology derived from factor analysis and simultaneous equation modelling that is gaining in popularity and frequency of use. Reliability was also estimated on the basis congenetic, parallel and Tau-equivalent SEM models, each of them with specific assumptions. The Monte Carlo simulations were used to generate data used for applying measurements and giving reliability estimates. Simulations are a method that enables the researcher to manipulate input parameters, determine specific measurement conditions and get the true (population) score. This is nearly impossible in reality, with fast and multiple repeats of the simulation process increasing the possibility of generalisation of results. 72 in reality possible measurement situations were simulated with three different sample sizes, with different and equal factor loadings and in combination with equal and different variances. The process of measurement reliability estimation with these coefficients was repeated within simulations 1,000 times with the "R" software. The objective of this work is to determine, which method and reliability estimation coefficient performs best with specific data and measurement situations and is closest to true reliability.

Keywords: Measurement reliability estimation, Cronbach's alpha coefficient, Coefficient omega, Structural Equation Modelling (SEM), Monte Carlo simulations.

KAZALO VSEBINE

1 UVOD	8
2 MERJENJE IN ZANESLJIVOST MERJENJA.....	10
2.1 Zanesljivost merjenja	12
3 KLASIČNA TESTNA TEORIJA.....	13
3.1 Merski modeli klasične testne teorije	14
3.2 Kongenerični model.....	16
3.3 „Essentially“ tau-enakovredni model	17
3.4 Tau-enakovredni model.....	18
3.5 Vzporedni ali paralelni model	18
4 OCENJEVANJE ZANESLJIVOSTI MERJENJA.....	19
4.1 Metoda notranje konsistentnosti.....	20
4.1.1 Cronbach koeficient alfa (α)	21
4.2 Komponentna in faktorska analiza.....	26
4.2.1 Koeficient omega (Ω).....	27
4.3 Primerjava / odnos med koeficientom α in koeficientom Ω	28
5 MONTE CARLO SIMULACIJE.....	29
6 MODELIRANJE STRUKTURNIH ENAČB (SEM)	30
6.1 Faktorska analiza in SEM.....	36
6.2 Analiza poti in SEM.....	39
6.3 Hibridni modeli.....	40
6.4 Ocenjevanje zanesljivosti z modeliranjem strukturnih enačb	41
7 IZVEDBA SIMULACIJ IN PRIMERJAVA OCEN ZANESLJIVOSTI	47
7.1 Uporabljeni modeli.....	50
7.2 Opis generiranja podatkov in postopek izračuna	52
8 PREDSTAVITEV REZULTATOV IN INTERPRETACIJA	56
9 ZAKLJUČEK	68

10 LITERATURA	71
PRILOGA A: Programska koda, uporabljena v magistrski nalogi.....	77
PRILOGA B: Standardni odkloni ocen zanesljivosti	102
PRILOGA C: Prave zanesljivosti, izračunane na dva različna načina	103
PRILOGA Č: Razmerje med izračunoma prave zanesljivosti pri 1000 ponovitvah.....	104

KAZALO TABEL

Tabela 3.1: Omejitve in enačbe posameznih modelov.....	15
Tabela 7.1: Matrike uteži glede na vrednosti/način izračuna	47
Tabela 7.2: Matrike varianc glede na vrednosti/način izračuna	48

KAZALO SLIK

Slika 6.1: Običajen pristop modeliranja struktturnih enačb.....	32
Slika 6.2: Standardni CFA merski model.....	32
Slika 6.3: Model analize poti.....	39
Slika 6.4: Hibridni model	40
Slika 7.1: Kongenerični model.....	50
Slika 7.2: Tau-enakovredni model.....	51
Slika 7.6: Vzporedni model	52
Slika 8.1: Povprečne vrednosti koeficientov in ocen zanesljivosti.....	59
Slika 8.2: Relativne vrednosti koeficientov glede na pravo vrednost.....	60

1 UVOD

Merjenje ima v družboslovju prav poseben pomen, saj preko merskega postopka skušajo raziskovalci dognati kvantifikacijo: »prirejanje števil objektom ali dogodkom na temelju izbranih pravil« (Ferligoj in drugi 1995, 1-2). To pomeni, da se skuša v družboslovju dognati neko mero, s katero lahko ugotavljam, v kakšnem »stanju« je merjen pojав, ki se dogaja v družbi, in ga tako primerjati tudi v različnih časovnih obdobjih. Osnove vsakega merjenja se začnejo s preučevanjem teorije (Ferligoj in drugi 1995, 1-11), kljub večkratnim ponavljanjem merjenja z istim merskim postopkom pa ne dobimo zmeraj enakih rezultatov. Ker se seveda želimo prepričati, »da razlike v izmerjenih vrednostih ponovljenih merjenj niso nastale le zaradi uporabljenega merskega postopka, ampak so posledica dejanskih sprememb merjenega pojava, potrebujemo oceno zanesljivosti merjenja« (Ferligoj in drugi 1995, 11). Merjenje je torej zanesljivo, kadar pri enakih pogojih dobimo enake rezultate (Ferligoj in drugi 1995). Zanesljivost je razmerje med varianco opazovane spremenljivke in varianco dejanske spremenljivke (Graham 2006). Zanesljivost lahko merimo z različnimi modeli za ocenjevanje zanesljivosti, pri katerih lahko uporabljam tudi različne koeficiente merjenja ter s koeficienti za merjenje zanesljivosti, ki iz teh modelov izhajajo (vsaj teoretično). V nadaljevanju bosta uporabljena dva pomembna koeficienta, in sicer Cronbachov koeficient alfa (α) in koeficient omega (Ω), ki sta ga utemeljila Heise in Bohrnstedt (Greene in Carmines 1980, 168) ter koeficienti za ocenjevanje zanesljivosti iz treh modelov strukturnih enačb. Za Cronbachov koeficient α smo se odločili, ker je trenutno največkrat uporabljen koeficient za ocenjevanje zanesljivosti med raziskovalci (Cronbach 2004). Prav tako je zelo uporaben tudi koeficient Ω , katerega prednost je predvsem njegova enostavnost izračuna, še posebej s programskimi paketi kot so SPSS, SAS ali R (Revelle in Zinbarg 2008). Zanesljivost bomo v nadaljevanju merili tudi z metodo modeliranja strukturnih enačb (SEM), ker je ta postopek zelo fleksibilen, saj raziskovalcem omogoča ocenjevanje zanesljivosti po različnih modelih, odvisno od predpostavk, ki jim lahko v določeni situaciji zadostimo (Yang in Green 2011, 384).

Cilj naloge je ugotoviti, kako razumeti in interpretirati različne ocene zanesljivosti, ki jih dobimo pri istih pogojih. Te različne ocene zanesljivosti smo med seboj primerjali in

podali ugotovitve, katera ocena je najboljša oz. najbližje pravi zanesljivosti v določeni merski situaciji.

Med seboj smo pri različnih situacijah glede na velikost vzorca, faktorske uteži ter skupne variance, primerjali 7 različnih koeficientov za ocenjevanje zanesljivosti merjenja; dva različna koeficiente alfa (»navadni« Cronbachov α koeficient in standardizirani α koeficient), dva različna koeficiente Ω (izhajajoč iz korelacijskih matrik ter kovariančnih matrik) ter tri koeficiente za ocenjevanje zanesljivosti, ki izhajajo vsak iz svojega modela strukturnih enačb.

Izračunane ocene zanesljivosti iz modelov SEM (kongenerični merski model, tau-enakovredni in vzporedni model) smo preverjali na normalni porazdelitvi (spremenljivke so zvezno normalno porazdeljene), te ocene smo nato primerjali s pravimi ocenami ter s koeficientoma α in Ω . Pri tem nas ne zanima zgolj primerjava slednjih dveh koeficientov z ocenami SEM modelov, temveč želimo vse ocene med seboj primerjati in ugotoviti, kaj so prednosti posameznih načinov ocenjevanja zanesljivosti. Vsi navedeni postopki so bili izvedeni s programskim paketom R. Gre za odprtokodni brezplačen program, ki je kompatibilen s statističnim programiranjem in računalniškim okoljem (Fox 2006). V nadaljevanju sledi najprej teoretični del, nato pa še empirični del, ki obsega sintezo programske kode in simulacij ter interpretacijo rezultatov.

2 MERJENJE IN ZANESLJIVOST MERJENJA

Znanstveno raziskovanje stremi k ugotavljanju zakonitosti, s katerimi je možno pojasniti pojave in situacije npr. v družboslovju, in jih tudi napovedovati (Raykov in Shrout 2002, 196). Del vsakega znanstvenega raziskovanja pa je med drugim tudi zbiranje podatkov, ki ga glede na metodologijo in cilje delimo na kvalitativno in kvantitativno. Pri kvalitativnem raziskovanju gre ponavadi za študije primerov, metode pa so poglobljeni intervju, fokusne skupine, opazovanje z udeležbo itd., kjer se osredotočamo na subjektivne pomene, simbole, opredelitve, specifične primere (Kogovšek 2005, 257). Pri kvantitativnem raziskovanju, kjer je metoda zbiranja podatkov največkrat anketa, pa predpostavljamo, da je možno družboslovne pojme opredeliti kot spremenljivke, s katerimi lahko pojave izmerimo oz. jih opišemo s števili (Neuman 2011, 181-184). Najpogosteje poteka raziskovanje skozi postopek merjenja, kar pomeni, da opažanja kvantificiramo oz. objektom ali konceptom prirejamo števila (Stevens v Ferligoj in drugi 1995, 1). Merjenje v znanosti temelji na teoriji, zato je to deduktivni proces; pomembno pa je, da so koncepti, ki predstavljajo teoretični pojem, in merski instrumenti primerno usklajeni (Kogovšek 2005, 270).

Proces merjenja se torej začne z opredelitvijo teoretičnega pojma, ki se ga v raziskavi obravnava. To je prvi korak merjenja, v katerem se po De Vaus-u (2004, 14) pregleda več definicij pojma in se nato ustrezna definicija izbere oz. prilagodi/spremeni. Nato se oblikuje merski instrument skozi proces operacionalizacije, s katerim se nato izbrana spremenljivka ali spremenljivke izmeri, in sicer skozi premišljeno zasnovane načine merjenja, npr. z mersko lestvico. V družboslovju se za zbiranje podatkov najpogosteje uporablja anketa, npr. za merjenje stališč (Leontitsis in Pagge 2006, 336). Tretji korak v procesu merjenja je zbiranje podatkov z merskim instrumentom. To je ponavadi iterativen postopek, saj želimo, da je merski instrument čim boljši oz. da čim bolje meri izbrane teoretične koncepte (Neuman 2011, 14). Poenostavljen to pomeni, da želimo preveriti, ali s svojimi merskimi instrumenti res merimo, kar želimo izmeriti. Ker je cilj znanstvenega raziskovanja ugotavljanje zakonitosti, s katerimi pojasnjujemo in napovedujemo pojave, je zelo pomembno, da so merski instrumenti za pridobivanje podatkov kakovostni (Kogovšek 2005, 258), predvsem pa je pomembno, da bo merski

instrument smiseln le, če bo zajel vse potrebne atribute entitete oz. koncepta, ki ga želimo izmeriti oz. testirati (Lucke 2005, 66).

Pri merjenju lahko pride do napak, zato je vprašanje kvalitete merjenja ključno (Ferligoj in drugi 1995, 8). Merske napake¹ so lahko slučajne in sistematične. Pri slučajnih napakah gre »za razliko med dejansko in izmerjeno vrednostjo, če se razlike, ugotovljene za vse enote, med seboj izravnavaajo. Sistematična napaka pa je razlika med izmerjeno in dejansko vrednostjo, če je mogoče v razlikah, ugotovljenih za vse enote, zaznati, da bodisi prevladujejo pozitivne bodisi negativne razlike in se razlike za vse enote ne izravnavaajo« (Košmelj v Ferligoj in drugi 1995, 7).

Pri kvaliteti merjenja sta bistvena predvsem dve razsežnosti, ki se nanašata na merjenje – to sta veljavnost in zanesljivost merjenja, ki sta ključna pogoja, da je merjenje v znanosti čim bolj objektivno. Zanesljivost se na splošno definira kot zmožnost, da pridemo do enakih rezultatov, če merjenje izvedemo večkrat na istih enotah (ob predpostavki, da so dejanske vrednosti enake), pri čemer gre torej za ugotavljanje prisotnosti slučajnih napak. Veljavnost pa pomeni, da ugotavljamo prisotnost oz. odsotnost sistematičnih napak (Tanur v Ferligoj in drugi 1995, 8). V kvantitativni paradigmi znanstvenega raziskovanja so po Kogovšek (2005, 273) koncepti kvalitete merjenja bolj jasno razvidni kot pri kvalitativni metodologiji in bolj sistematizirani, saj so ti koncepti precej natančno definirani in v veliki meri operacionalizirani na kvantitativen način (z natančnimi izračuni).

Veliko avtorjev poudarja problem zanemarjanja pomena kvalitete merjenja v družboslovju (Ferligoj in drugi 1995; Yang in Green 2011; Graham 2006; Cortina 1993; Schmitt 1996), najpogostejsa napaka pa je napačna interpretacija zanesljivosti merjenja, saj se koncept zanesljivosti poenostavlja do te mere, da se velikokrat zanesljivost nanaša na test sam, kar je huda napaka, saj se pojmom zanesljivosti nanaša na rezultate oz. meritve in ne na samo mersko lestvico (Graham 2006, 930).

¹ Po Ferligoj in drugi (1995, 7) je merska napaka definirana kot razlika med opazovano (izmerjeno) in dejansko vrednostjo spremenljivke.

2.1 Zanesljivost merjenja

Ena izmed glavnih skrbi tako v družboslovju kot tudi v behaviorističnih vedah je natančnost merjenja, ki jo najpogosteje kvantificira prav koeficient zanesljivosti (Raykov 1997, 329). Vprašanje zanesljivosti merjenja v znanosti je torej že staro, saj temeljna dela s področja preverjanja kakovosti podatkov izhajajo iz sredine 20. stoletja (Kogovšek 2005, 258). Splichal (v Ferligoj in drugi 1995, 153) pa meni, da je poleg vprašanja veljavnosti ključnega pomena prav tako vprašanje zanesljivosti, saj je bistvenega pomena za razvoj teoretičnega nauka in empiričnega raziskovanja. Veljavnost empirične raziskave namreč sloni na zagotavljanju zanesljivosti merjenja, na podlagi katerih se delajo zaključki (Duhachek in Iacobucci 2004, 792).

Greene in Carmines (1980, 160) navajata, da zanimanje za ocenjevanje zanesljivosti merjenja v družboslovju raste, zlasti za merjenja, ki temeljijo na linearnih kompozitih posameznih indikatorjev merske lestvice, prav tako pa narašča zanimanje za številne koeficiente, s katerimi je moč oceniti zanesljivost merjenja. Hkrati pa avtorja opozarjata na že omenjene pasti pri interpretaciji ocenjevanja zanesljivosti.

Zanesljivost pomeni, da ob večkratni ponovitvi merjenja pri enakih pogojih dobimo (približno) enake rezultate; pomeni torej dopustno stopnjo slučajnih napak. Nunnally (v Cortina 1993, 98) zanesljivost definira kot »mero, do katere so meritve/merjenja ponovljiva, vsak slučajen vpliv, ki povzroči, da se rezultati meritev med seboj včasih razlikujejo, pa je vir merske napake«. Streiner (2003, 100) zanesljivost definira kot stopnjo, do katere dajejo »meritve ob različnih priložnostih ali z različnimi opazovalci, ali s podobnimi ali vzporednimi testi, enake ali podobne rezultate«. Podobno piše tudi Neuman (2011, 189), ki meni, da zanesljivost merjenja pomeni, da se numerični rezultati, ki so produkt indikatorja, ne spreminjači zaradi lastnosti merskega procesa ali pa merskega instrumenta samega.

Zanesljivost govori tudi o obsegu pristranskosti zaradi merske napake pri veljavnosti in napovednih študijah, v katerih se napačna oz. nepravilna merjenja uporabljajo kot pojasnjevalne spremenljivke. Visoka stopnja zanesljivosti je tudi nujen pogoj za visoko stopnjo veljavnosti in je tudi zelo pomemben predpogoji za razvoj teorij (Raykov in Shrout 2002, 195-196).

Poleg ponovljivosti merjenj pa se v družboslovju pojem zanesljivosti pogosto nanaša tudi na konsistentnost merjenj, kar pomeni, da zanesljivost označuje tudi stopnjo enakovrednosti spremenljivk za merjenje izbrane dejanske spremenljivke. Peter (v Peterson 1994, 381) zanesljivost merjenja definira kot stopnjo, do katere so meritve brez napak in tako dajejo skladen in konsistenten rezultat. Splichal (1990, 147-148) definira raziskovanje zanesljivo tedaj, »kadar slučajne napake v celotnem procesu raziskovanja ne vplivajo statistično značilno na izsledke raziskovanja«. Potrebujemo torej oceno zanesljivosti merjenja, ki nam zagotovi, da so razlike v izmerjenih vrednostih pri ponovnih merjenjih posledica dejanskih sprememb pojava. Hafner Fink (2004, 64) navaja, da je zanesljivost merjenja še posebej pomembna pri (medčasovni) primerjalni analizi, kjer gre pravzaprav za stabilnost merskega instrumenta. To se seveda nanaša na kvantitativne načine merjenja in zbiranja podatkov, pri kvalitativnih metodah (npr. študijah primerov) pa je o zanesljivosti merjenja težko govoriti.

3 KLASIČNA TESTNA TEORIJA

Z vprašanjem zanesljivosti merjenja v znanosti se ukvarja tudi priljubljena klasična testna teorija, katere utemeljitelja sta Lord in Novick (Ferligoj in drugi 1995, 12), ki sta to teorijo aplicirala v psihologiji (Armor 1974, 19). Po tej teoriji zanesljivost merjenja predvideva enako oz. podobne rezultate več meritov, zato se lahko korelacijo med več meritvami uporabi pri oceni zanesljivosti. Zanesljivost merjenja spremenljivke X , ki jo označujemo z ρ_x , je definirana (Ferligoj in drugi 1995, 14; Streiner 2003, 99; Yang in Geen 2011, 378) kot razmerje med varianco dejanske spremenljivke T in varianco izmerjene spremenljivke X :

$$\rho_x = \frac{\sigma_x^2}{\sigma_T^2}.$$

Zanesljivost se torej nahaja na intervalu $[0,1]$, saj je varianca vedno nenegativno število.

Ko zanesljivost ocenjujemo z metodo SEM, moramo glede na definicijo zanesljivosti pridobiti ocene dejanskih in izmerjenih varianc (Graham 2006, 933).

Zanesljivost bo manjša, če bo varianca slučajnih napak večja in obratno. Ocena zanesljivosti pa je mogoča le s ponovljenimi meritvami spremenljivke, saj se zanesljivost

izraža z dejansko spremenljivko, ki pa jo lahko neposredno izmerimo (Ferligoj in drugi 1995, 16). Pri ponovitvah merjenja pa je treba biti pozoren, da so zadoščene določene zahteve; povedano drugače – da lahko ocenimo zanesljivost merjenja, morajo biti ponovljene meritve enakovredne. Poznamo več merskih modelov glede na to, v kakšnem odnosu sta dejanski spremenljivki in varianci merskih napak dveh meritev, v katerih je bila merjena ista spremenljivka. Ti modeli so: kongenerični, tau-enakovredni in vzporedni model (Alwin in Jackson v Ferligoj in drugi 1995, 17; Graham 2006, 933).

3.1 Merski modeli klasične testne teorije

Najprej je potrebno definirati merski model. Ferligoj in drugi (1995, 12) in tudi številni drugi avtorji (Armor 1974, 19; Carmines in Zeller 1979, 29; Graham 2006, 931; Yang in Green 2011, 378) merski model definirajo takole:

$$x_p = t_p + e_p \text{ oz. } X = T + E,$$

kjer je X vektor izmerjenih vrednosti x_p (na p-ti enoti), T je vektor dejanskih vrednosti (ang. *true score*) – t_p so dejanske vrednosti na p-ti enoti, E pa je vektor slučajnih napak e_p . Če poimenovanja poenostavimo, X pomeni izmerjeno spremenljivko (ang. *observed score*), T pa dejansko spremenljivko. Dejanska vrednost spremenljivke na določeni enoti (npr. t_p) je aritmetična sredina neskončnega števila merjenj spremenljivke na tej določeni enoti, če ostaja dejanska vrednost konstantna in ni sistematičnih napak. Izmerjena vrednost spremenljivke se od svoje dejanske vrednosti razlikuje zaradi slučajnih napak pri merjenju.

Merskih modelov je torej več. Kongenerični je najbolj splošen (Ferligoj in drugi 1995, 17), vzporedni ali paralelni in tau-enakovredni pa sta manj splošna. Hierarhična razvrstitev modelov glede na njihovo omejenost oz. predpostavke si sledijo od najbolj omejenega do najmanj omejenega v naslednjem vrstnem redu: vzporedni, tau-enakovredni, bistveni (ang. *essentially*) tau-enakovredni in kongenerični model ocenjevanja zanesljivosti (Kline 1998, 219). Njihove omejitve so na kratko predstavljene v naslednji tabeli:

Tabela 3.1: Omejitve in enačbe posameznih modelov

MODEL IN ENAČBA	LASTNOSTI MODELOV
Vzporedni $X_{ik} = T_i + E_i$	<ul style="list-style-type: none"> ■ vsi elementi merijo eno latentno spremenljivko ■ merjene morajo biti na enaki skali ■ z enako stopnjo natančnosti ■ z enakimi variancami napak
Tau-enakovredni $X_{ik} = T_i + E_{ik}$	<ul style="list-style-type: none"> ■ vsi elementi merijo eno latentno spremenljivko ■ merjene morajo biti na enaki skali ■ z enako stopnjo natančnosti ■ lahko so različne variance napak
„Essentially“ tau-enakovredni $X_{ik} = (\alpha_k + T_i) + E_{ik}$	<ul style="list-style-type: none"> ■ vsi elementi merijo eno latentno spremenljivko ■ merjene morajo biti na enaki skali ■ z enako stopnjo natančnosti ■ lahko so različne variance napak ■ razlikovanje za aditivno konstanto glede na tau-enakovredni model
Kongenerični $X_{ik} = [\alpha_k + \beta(T_i)] + E_{ik}$	<ul style="list-style-type: none"> ■ merjene so lahko na različnih skalah ■ stopnje natančnosti so lahko različne ■ lahko so različne variance napak

3.2 Kongenerični model

Za kongenerični meritvi X_i in X_j spremenljivk, je ta model formuliran kot:

$$X_i = T_i + E_i \text{ in}$$

$$X_j = T_j + E_j \text{ ter}$$

$$T_i = \alpha_{ij} + \beta_{ij} T_j$$

Ker sta dejanski spremenljivki T_i in T_j linearno odvisni, med seboj popolnoma korelirata. Zato lahko kongenerični model več meritve obravnavamo kot faktorski model, če varianco vsake izmerjene spremenljivke pojasnjuje en sam faktor in če je teoretična spremenljivka merjena z več indikatorji.

Varianci meritov sta izraženi kot:

$$\sigma_i^2 = \sigma_{Ti}^2 + \sigma_{Ei}^2 = \beta_{ij}^2 \sigma_{Tj}^2 + \sigma_{Ei}^2$$

in

$$\sigma_j^2 = \sigma_{Tj}^2 + \sigma_{Ej}^2$$

kovarianca meritov pa je:

$$\sigma_{ij} = \beta_{ij}^2 \sigma_{Tj}^2 = \beta_{ji}^2 \sigma_{Ti}^2$$

Kongenerični model je najmanj strog izmed vseh merskih modelov in zato tudi najbolj splošen za računanje ocene zanesljivosti merjenja. Ne predpostavlja, da indikatorji merijo spremenljivko na isti lestvici, niti ne zahteva, da so stopnje natančnosti² in merske napake enake (Raykov v Graham 2006, 934), faktorske uteži in napake varianc se lahko razlikujejo (Osburn 2000, 345). Predpostavlja pa linearen odnos med

² Stopnja pomeni razlikovanje natančnosti aritmetičnih sredin posameznih spremenljivk med seboj.

Meritev je bolj natančna, če se merjene vrednosti posameznih spremenljivk nahajajo bolj skupaj glede na mersko skalo (Graham 2006, 935).

dejanskimi vrednostmi spremenljivke, pri čemer so dovoljene tako aditivne kot multiplikativne konstante med parom dejanskih spremenljivk:

$$X_{ik} = [\alpha_k + \beta_k(T_i)] + E_{ik}, \text{ pri čemer je } k \text{ posamezen indikator lestvice, } i \text{ pa enota.}$$

3.3 „Essentially“ tau-enakovredni model

Po Cronbach-u (v Cortina 1993, 101) sta meritvi »essentially«³ tau-enakovredni, če sta linearno povezani in se razlikujeta le za konstanto. Ko se indikatorji lestvice približujejo tau-enakovrednosti, kar tudi se, če so testi sestavljeni iz enakih splošnih in skupinskih faktorskih varianc⁴, se Cronbachov koeficient α približuje zanesljivosti, ki jo dejansko izenači, če so indikatorji merske lestvice natanko »essentially« tau-enakovredni.

Ta model je v temeljih enak tau-enakovrednemu modelu, le da se lahko dejanska vrednost vsakega indikatorja razlikuje od drugih dejanskih vrednosti posameznih indikatorjev za konstanto (Osburn 2000, 345), ki vpliva le na aritmetično sredino spremenljivke, ne pa tudi na varianco in kovarianco, kar je bistveno, saj se koncept zanesljivosti nanaša na variance in ne na aritmetične sredine. Sicer so vsi indikatorji merjeni na isti lestvici, vendar ni nujno da z enako stopnjo natančnosti (Graham 2006, 935).

Ta enakovrednost je nujen in tudi zadosten pogoj, da koeficient α izenači kompozitno zanesljivost (ang. *composite reliability*) na populacijski ravni (Raykov 1997, 333). Koeficient α je torej v bistvu enak kvadratu korelacije med opazovano in dejansko vrednostjo (Cronbach in Shavelson 2004, 400).

V simulacijah je za potrebe magistrske naloge uporabljen zgolj tau-enakovredni model, saj aditivna konstanta »essentially« tau-enakovrednega modela vpliva le na aritmetične

³ Pojem „essentially“ oz. „v bistvu“/„bistven“ je uporabljen zato, da se nekako ne upošteva dejstva, da bo imel vsak naključno formiran instrument nekoliko drugačno korelacijo z resnično oceno (Chronbach in Shavelson 2002, 400).

⁴ Splošne faktorske variance so variance faktorja, skupinske faktorske variance pa so variance skupinskih faktorjev, ki so faktorji, povezani z vsaj dvema spremenljivkama v modelu, ne pa z vsemi (Košmelj in drugi 2001).

sredine posameznih spremenljivk, ne pa tudi na variance in kovariance (Graham 2006, 935). Iz tega sledi, da bi bile ocene zanesljivosti obeh omenjenih modelov enaki, zato je bil za ocenjevanje zanesljivosti uporabljen le tau-enakovredni model.

3.4 Tau-enakovredni model

Dve meritvi sta tau-enakovredni, če imata isto dejansko spremenljivko ($T_i = T_j = T$) na isti lestvici, stopnja natančnosti pa je tudi enaka, pri čemer sta varianci meritov enaki:

$$\sigma_t^2 = \sigma_T^2 + \sigma_{Et}^2$$

in

$$\sigma_{ij}^2 = \sigma_T^2 \sigma_j^2 = \sigma_T^2 + \sigma_{Ej}^2,$$

kovarianca pa je v tem primeru enaka: $\sigma_{ij} = \sigma_T$.

Tau-enakovredni model dopušča različne merske napake (Raykov v Graham 2006, 934), kar lahko zapišemo tudi kot $X_{it} = T_i + E_{it}$.

Kovarianca med dvema meritvama, ki sta tau-enakovredni, je torej enaka varianci dejanske spremenljivke, zato so tudi variance več tau-enakovrednih meritov enake med seboj. Če so variance meritov različne, je to posledica slučajnih napak, saj so dejanske spremenljivke vseh meritov enake.

3.5 Vzporedni ali paralelni model

Dve meritvi sta vzporedni, če imata isto dejansko spremenljivko ($T_i = T_j = T$) in enaki varianci slučajnih napak ($\sigma_{Et}^2 = \sigma_{Ej}^2 = \sigma_E^2$). Varianci vzporednih meritov sta torej enaki,

kovarianca pa je enaka varianci dejanske spremenljivke. Tudi kovariance več vzporednih ali paralelnih meritov so med seboj enake, prav tako pa so med seboj enaki koeficienti korelacije med več vzporednimi meritvami, kar se okrajšano lahko zapiše kot:

$$\rho_{ij} = \frac{\sigma_T^2}{\sigma_E^2} = \rho_X.$$

Koeficient korelacije je torej enak razmerju med varianco dejanske spremenljivke in varianco izmerjene spremenljivke, to pa je tudi definicija zanesljivosti merjenja.

Vzporedni model ima od vseh merskih modelov najstrožje predpostavke, saj predpostavlja, da so dejanske spremenljivke enake ter da so enake tudi variance slučajnih napak (Ferligoj in drugi 1995, 19; Graham 2006, 934). Prav tako morajo vsi indikatorji lestvice meriti isto spremenljivko, na isti lestvici, z enako stopnjo natančnosti in z enako mersko napako (Raykov v Graham 2006, 934), kar lahko zapišemo kot:

$$X_{ik} = T_i + E_i.$$

Klasična testna teorija v merskih modelih torej upošteva le slučajne napake, vendar pa se lahko pri merjenju pojavijo tudi sistematične napake, ki pa vplivajo na izmerjene vrednosti. Kot pišejo številni avtorji (Graham 2006, 931), se ocena zanesljivosti nanaša na rezultate, ne na sam merski instrument, vendar Alwin (v Ferligoj in drugi 1995, 20) pravi, da je zanesljivost odvisna tudi od merskega postopka (in ne le od rezultatov). Na varianco izmerjene spremenljivke vplivajo tudi dejanska vrednost, lastnosti merskih postopkov, napake pri konceptualizaciji in/ali operacionalizaciji, slučajne napake ter napake, ki so glede na dejansko vrednost slučajne, vendar med seboj pri ponovnih meritvah korelirajo. Vsega skoraj ni mogoče oceniti, vendar bi se nekatere od naštetih komponent vsekakor dalo opazovati.

4 OCENJEVANJE ZANESLJIVOSTI MERJENJA

Obstaja več načinov ocenjevanja zanesljivosti merjenja glede na različne predpostavke (Carmines in Zeller 1979, 37; Ferligoj in drugi 1995, 154).

Metode, s katerimi ocenujemo zanesljivost merjenja, lahko razdelimo v dve skupini.

V prvo skupino spadajo metode, ki temeljijo na ponovljenem postopku merjenja na istih enotah po določenem času (glede na ta kriterij lahko zanesljivost interpretiramo kot mero stabilnosti), v drugo skupino pa uvrščamo metode, ki so zasnovane na merjenju dejanske spremenljivke z več enakovrednimi spremenljivkami v istem času (zanesljivost kot mera enakovrednosti).

Mere stabilnosti zajemajo metodo retesta, kjer se merjenje določene spremenljivke ponovi na istih enotah po določenem času, ter metodo alternativne oblike, ki prav tako zahteva ponovitev merjenja na istih enotah, vendar se pri tem uporabi druga (vendar enakovredna) oblika merjenja, npr. druga merska lestvica (Ferligo in drugi 1995, 33-38).

Mere enakovrednosti pa predpostavlja, da je še posebno v družboslovju težko opraviti več ponovnih merjenj, ker se pojavi, ki ga merimo, hitro spreminja (Splichal v Ferligo in drugi 1995, 39), zato merimo večkrat v istem času (ang. *cross-sectional*), pri čemer se izračuna povprečen koeficient korelacije med izmerjenimi spremenljivkami, ki vse merijo isto dejansko spremenljivko, pri tem pa predpostavljamo, da so izbrane spremenljivke enakovredne.

Mere enakovrednosti pa zajemajo metodo notranje razpolovitve, metodo notranje konsistentnosti ter komponento in faktorsko analizo. Zadnji omenjeni metodi sta za to nalogu ključnega pomena, zato sta opisani v naslednjih podpoglavljih.

4.1 Metoda notranje konsistentnosti

Notranja konsistentnost lestvice pomeni stopnjo medsebojne povezanosti indikatorjev lestvice (Cortina 1993, 100). Ta metoda spada med najlažje izvedljive metode ocenjevanja zanesljivosti merjenja, saj temelji le na izračunu kovarianc ali koeficientov korelacije med vsemi spremenljivkami, ki merijo isto dejansko spremenljivko. Metodo lahko uporabimo takrat, ko je vrednost testa vsota vrednosti komponent (Miller 1992, 261).

Armor (1974, 20) skupno varianco vseh N izmerjenih spremenljivk zapiše takole:

$$\sigma_x^2 = \sum \sigma_{xi}^2 + 2 \sum_{i < j} cov(x_i, x_j)$$

ali poenostavljeno: $S = I + C$,

pri čemer je S skupna varianca, ki je enaka seštevku vsote varianc posameznih spremenljivk (I) in vsote vseh kovarianc med njimi (C). Če vse spremenljivke merijo isti koncept, bi lahko merili kompozitno zanesljivost z enačbo: C/S . To razmerje ni omejeno

z zgornjo vrednostjo 1, saj vsota varianc posameznih faktorjev (I) predvidoma ne bo nikoli enaka nič. Če so spremenljivke vzporedne, je maksimalna vrednost razmerja enaka $(N - 1)/N$ (Armor 1974, 21; Ferligoj in drugi 1995, 41).

Tako lahko zapišemo splošni koeficient zanesljivosti α , ki je definiran na intervalu $[0, 1]$ in ga je l. 1951 zapisal Cronbach:

$$\alpha = \left(\frac{N}{N-1} \right) \left(1 - \frac{\sum_{i=1}^N \sigma_{xi}^2}{\sigma_x^2} \right),$$

pri čemer je σ_x^2 skupna varianca izmerjene spremenljivke, σ_{xi}^2 pa varianca posamezne izmerjene spremenljivke. Koeficient α je mera notranje konsistentnosti in ne mera homogenosti, kot avtorji ponekod površno navajajo. Notranja konsistentnost se nanaša na medsebojno povezanost indikatorjev lestvice, homogenost pa na unidimenzionalnost indikatorjev lestvice. Notranja konsistentnost je potrebna za doseganje homogenosti, vendar ni zadostni pogoj (Osburn 2000, 343; Schmitt 2002, 350).

Bolj podrobno je Cronbachov koeficient α opisan v naslednjem podpoglavlju.

4.1.1 Cronbach koeficient alfa (α)

Merjenje v družboslovju navadno temelji na merskih instrumentih, ki merijo več komponent, kot so npr. lestvice, podlestvice, kompoziti in vprašalniki, pri le-teh pa se najpogosteje za ocenjevanje zanesljivosti merjenja uporablja Cronbachov α koeficient (Raykov in Shrout 2002, 196).

Koeficient α se torej uporablja za ocenjevanje zanesljivosti merjenja, pri čemer gre za ocenjevanje notranje konsistentnosti merske lestvice (Greene in Carmines 1980, 164; Streiner 2003; Cronbach in Shavelson 2004, 396). To pomeni, da ni zahtevanih nobenih ponovitev merjenja, od raziskovalca pa tudi ne zahteva nobenih odločitev. Izračun temelji na kovariankah (ali koeficientih korelacije) med vsemi spremenljivkami, ki merijo isto dejansko spremenljivko (Ferligoj in drugi 1995, 41). Bonett (2002, 335) koeficient α definira kot funkcijo medrazredne korelacije, ki opisuje zanesljivost lestvice,

sestavljeni iz k -delov, ki pogosto predstavljajo k -različne ocenjevalce oz. k kvantitativno pridobljene indikatorje.

Koeficient α označuje spodnjo mejo zanesljivosti vsote N izmerjenih spremenljivk ρ_X (Ferligoj in drugi 1995, 43; Streiner 2003), kar pomeni, da je $\alpha \leq \rho_X$. Da pa α doseže enako vrednost kot ρ_X , mora biti merjenje tau-enakovredno (Novik in Lewis v Ferligoj 1995, 43). Tudi če je v praksi temu pogoju težko zadostiti, α dobro ocenjuje sestavljeni spremenljivki. Cortina (1993, 101) celo opozarja, da veliko avtorjev ta koeficient definira kot spodnjo mejo zanesljivosti, vendar to velja le zato, ker je popolna tau-enakovrednost redka; poudariti je treba, da α dobro oceni zanesljivost (in ni le njena spodnja meja), kadar gre za popolno „essentially“ tau-enakovrednost.

Koeficient α pa je enak zanesljivosti testa, če so vsi pari indikatorjev med seboj „essentially“ tau-enakovredni, kar praktično pomeni, da imajo vsi indikatorji enake faktorske uteži na skupnem faktorju (Miller 1995, 265).

Glede na to, da koeficient α temelji na ocenjevanju notranje konsistentnosti merske lestvice, je torej občutljiv na to, ali gre za visoko ali nizko notranjo konsistentnost indikatorjev lestvice.

Standardiziran α koeficient ponavadi poda boljšo oceno zanesljivosti, saj so pri računanju »navadnega« α koeficiente standardni odkloni in s tem tudi variance spremenljivk različne (Cortina 1993, 99). Ocena zanesljivosti s standardnim α koeficientom presega pravo vrednost v primeru, ko so spremenljivke tau-enakovredne ali kongenerične (Osburn 2000, 348).

Vrednost koeficiente α prav tako odvisna od števila izmerjenih spremenljivk ter od korelacije med njimi (Ferligoj in drugi 1995, 44), vendar pa se α ne veča premo sorazmerno z dodajanjem spremenljivk. Peterson (1994) je dokazal, da se vrednosti koeficiente α večajo, če je v ocenjevani merski lestvici več indikatorjev, vendar samo v primeru, ko so indikatorji med seboj homogeni oz. so homogene njihove variance. Cortina (1993, 102) je v svoji študiji koeficiente α prav tako dokazal, da ima število indikatorjev v lestvici vpliv na vrednost α , in sicer ne glede na stopnjo notranje konsistentnosti. Predvsem to velja za lestvice, ki jih sestavlja več kot 20 indikatorjev (kar

je sicer v praksi izjemno redko) - koeficient α je bil v vseh primerih večji od 0.70, ne glede na število dimenzij in notranjo konsistentnost.

Tudi Lissitz in Green (1975) sta preverjala vrednosti koeficiente α pri različno »dolgh« lestvicah in z različnimi kovariancami med indikatorji lestvice. Rezultati so pokazali, da večje kovariance med indikatorji pomenijo večjo vrednost α , enak rezultat pa poda tudi večje število indikatorjev v lestvici. Pri kovarianci 0.8 in petih indikatorjih je bila α enaka 0.84, če pa je bilo v lestvici 7 ali 14 indikatorjev, pa je bila α enaka 0.85 in 0.86. Pri kovarianci 0.5 je vrednost α pri številu indikatorev 5, 7 in 14 znašala 0.74, 0.75 in 0.76. Pri 0.2, kar je najmanjša kovarianca, pri kateri sta avtorja izvajala simulacije, je bila α pri številu indikatorjev 5, 7 in 14 enaka 0.52, 0.52 in 0.53.

Še en pomemben faktor vpliva na vrednost α , in sicer je to dimenzionalnost. Vrednost α je izračunana pravilno samo, če je izračunana na enem samem faktorju, pri čemer α meri tudi moč faktorja (Cotton in drugi v Cortina 1993, 102).

Shevlin in drugi (2000, 235) so v svoji študiji, ki je temeljila na simulacijah, ugotovili, da na vrednost α vplivajo tudi faktorske uteži, ki odražajo moč povezanosti faktorja in indikatorja lestvice. Avtorji so ugotovili, da večja kot je faktorska utež, večja bo vrednost koeficiente α . Na vrednost α vpliva tudi velikost sistematične napake, pri čemer se je pokazalo, da večje sistematične napake (če so enake na vseh spremenljivkah) večajo vrednost α , prav tako pa tudi velikost vzorca – pri večjih vzorcih je vrednost koeficiente α navadno večja, saj vrednosti bolj skonvergirajo.

Bonett (2002) meni, da je velikost vzorca najpomembnejši premislek v dizajnu raziskav. Premajhni vzorci namreč nimajo dovolj moči, intervali zaupanja pa so preširoki.

Danes je α največkrat uporabljen koeficient za ocenjevanje zanesljivosti, v začetku pa je bil največkrat uporabljen v strokovni literaturi s področja psihometrije (Greene in Carmines 1980, 164); po nekaterih podatkih (Sočan 2000, 23) pa se v psihometriji za ocenjevanje notranje konsistentnosti uporablja zgolj koeficient α .

Yang in Green (2011, 377) navajata več razlogov za množično uporabo koeficiente α . Koeficient α je relativno enostaven za interpretacijo, je precej direkten v tem smislu, da od raziskovalca ne zahteva nobenih subjektivnih odločitev (npr. kot pri metodi

razpolovitve), poleg tega pa lahko s tem koeficientom ocenimo, kako dobra je neka merska lestvica (npr. pri dodajanju ali odvzemanju indikatorjev pri računanju zanesljivosti rezultatov). Streiner (2003, 99) tudi poudarja, da je merjenje zanesljivosti s koeficientom α tudi lažje kot z metodo test-retesta, poleg tega pa je potrebna ocena le enega parametra.

Yang in Green (2011) opozarjata, da je Cronbachov α koeficient mnogokrat interpretiran popolnoma napačno, njegova množična uporaba namreč poenostavlja pomen ocenjevanja zanesljivosti merjenja in popolnoma zanemarja številne druge koeficiente za ocenjevanje zanesljivosti. Koeficient α je treba uporabljati in interpretirati z razmisleki in ne samoumevno.

Pojavlja se veliko polemik glede sprejemljive meje, ki naj bi jo koeficient α dosegel, da lahko rečemo, da gre za zanesljive rezultate (Leontitsis in Pagge 2006, 336; Yang in Green 2011, 381), kajti večji kot je Cronbachov α koeficient, večja je zanesljivost merjenja. Kje na intervalu $[0, 1]$ se mora nahajati koeficient α , da lahko govorimo o zanesljivem merjenju? Nunnally (v Yang in Green 2011, 381) je zapisal naslednje mejne vrednosti:

- $\alpha < 0.70$ za lestvice v začetni fazi razvoja,
- $\alpha < 0.80$ za osnovne lestvice,
- $\alpha < 0.90$ kot minimalna vrednost za lestvice, ki se jih uporablja v kliničnih raziskavah,
- $\alpha < 0.95$ kot idealna vrednost za slednje lestvice.

Peterson (v Yang in Green 2011, 381) je preučeval poročila s področja psihologije in podjetništva, ki so vsebovala tudi izračune koeficiente α . Ugotovil je, da je bila povprečna vrednost koeficiente α izmed 4286 izračunanih koeficientov enaka 0.77, le 14 % vse koeficientov pa je preseglo vrednost 0.90.

Ferligoj in drugi (2011, 157) predlagajo naslednje:

- $\alpha > 0.80$, kar kaže na zgledno zanesljivost,

- $0.70 < \alpha < 0.80$, kar kaže na zelo dobro zanesljivost,
- $0.60 < \alpha < 0.70$, kar kaže na zmerno zanesljivost,
- $\alpha < 0.60$, kar kaže na komaj sprejemljivo zanesljivost.

Streiner (2003, 103) sicer meni, da lestvice, kjer je vrednost α več kot 0.90, kažejo nepotrebno redundanco in ne zaželene ravni notranje usklajenosti. Načeloma pa visoka vrednost koeficienta kaže na zelo zanesljive rezultate določene lestvice na danem vzorcu (Raykov in Shrout 2002, 197).

Cortina (1993, 101) kritizira študije, ki le navedejo vrednost α in meni, da to ni dovolj oz. navajanje le vrednosti koeficienta ni zadostno, da lahko govorimo o zanesljivih rezultatih, brez vsakršne kritične presoje ter brez nadalnjih prilagoditev na lestvici. Strinjata se tudi Duhachek in Iacobucci (2004, 793), ki pravita, da samo navajanje ocene zanesljivosti ne pomeni dovolj brez istočasne navedbe standardne napake izračuna, ki so še posebej koristne za primerjavo različnih testov.

Cortina (1993) meni, da je faktor, ki najbolj vpliva na vrednost α , ravno število indikatorjev v merski lestvici. Vendar to ne pomeni, da morajo biti lestvice dolge (npr. z več kot 10 indikatorji), saj je pri dolgih oz. velikih lestvicah notranja konsistentnost ponavadi velika, kar pomeni, da bo vrednost koeficienta α visoka, kvaliteta lestvice pa ne nujno najboljša. Tudi koeficient α je potrebno interpretirati z nekaj previdnosti kot vsako drugo statistiko. Koeficient α je najbolj primeren za ocenjevanje zanesljivosti takrat, ko nas zanimajo variance indikatorjev (ang. *item-specific variance*) v enodimensionalnem testu (Cortina 1993, 103). Avtor tudi predлага, da se pred ocenjevanjem zanesljivosti rezultatov izvede metoda glavnih komponent, s katero ugotovimo, koliko dimenzij ima lestvica in ali je koeficient α sploh primeren za ocenjevanje zanesljivosti.

Streiner (2003, 102) pa opozarja tudi na to, da večji kot je koeficient α , to ne pomeni nujno tega, da je lestvica bolj homogena. Velikokrat se namreč zgodi, da večja vrednost α pomeni le nepotrebno ponavljanje vsebine znotraj indikatorjev lestvice (npr. da dva ali več indikatorjev meri isti koncept).

Obstaja tudi standardiziran α koeficient, ki oceni zanesljivost na standardiziranih podatkih – opazovane spremenljivke so pred seštevanjem vrednosti standardizirane (Osburn 2000, 348). Standardiziran α koeficient ni enak spodnji meji zanesljivosti tako kot Cronbach α koeficient, temveč je neposreden približek zanesljivosti glede na spremenljivke z enako opazovano varianco (Cortina 1993, 101). Prava vrednost oz. prava zanesljivost pa je pri obeh α koeficientih enaka. Standardiziran α koeficient izračunamo po naslednji formuli:

$$\alpha_{ij} = \frac{n(1 - n/(n + \sum \sum \rho_{ij}))}{(n-1)}, \text{ pri čemer velja } i \neq j, \quad \rho_{ij} \text{ pa je korelacija med } i\text{-to in } j\text{-to spremenljivko.}$$

Standardni odkloni spremenljivk, ki tvorijo lestvico, se pri nestandardiziranih podatkih razlikujejo, te razlike pa vplivajo na oceno notranje konsistencnosti lestvice, kar načeloma ocenjujemo s Cronbachovim koeficientom α , zato naj bi se standardiziran α koeficient uporabljal le v primeru, ko so vse spremenljivke standardizirane (Streiner 2003, 101) oz. če vsote standardnih vrednosti spremenljivk sestavljajo vrednosti lestvice (Cortina 1993, 99).

Standardiziran α koeficient se za ocenjevanje zanesljivosti uporabi namesto »navadne« α tudi takrat, ko je spremenljivke potrebno standardizirati, npr. v primeru, da niso merjene na isti lestvici. V magistrski nalogi smo zanesljivost ocenjevali z obema koeficientoma α .

4.2 Komponentna in faktorska analiza

Komponentna in faktorska analiza sta prav tako primerni za ocenjevanje zanesljivosti sestavljeni spremenljivki. Koeficiente zanesljivosti, ocenjena s temi metodama, sta primerljiva s koeficientom notranje konsistentnosti, saj sta izpeljana iz enakosti:

$$\alpha = \frac{\frac{sc}{N}}{\frac{s^2}{N-1}} = \left(\frac{N}{N-1}\right)\left(\frac{sc}{s}\right) = \left(\frac{N}{N-1}\right)\left(1 - \frac{I}{I+2c}\right), \quad (\text{Ferligoj in drugi 1995, 44; Sočan 2000, 24}).$$

Metoda glavnih komponent je tako kot faktorska analiza metoda za redukcijo podatkov, in sicer se pri tej metodi oblikujejo komponente, s katerimi poskušamo opisati variabilnosti M enot v N -razsežnem prostoru. Komponente so linearne kombinacije

izmerjenih spremenljivk in pojasnijo čim večji del variabilnosti spremenljivk ter so urejene po pomembnosti (od tiste, ki pojasni največ variabilnosti, do tiste, ki pojasni najmanj variabilnosti). Prva komponenta torej pojasni največ variabilnosti izmerjenih spremenljivk (njena varianca je enaka lastni vrednosti λ_1 prve komponente). Komponent je toliko, kot je spremenljivk, vendar so zanimive le tiste komponente, ki pojasnijo pomemben del celotne variance (Armor 1974, 27; Ferligoj in drugi 1995, 45).

4.2.1 Koeficient omega (Ω)

Faktorska analiza ima za cilj poiskati faktorje, ki naj bi predstavljali tisto, kar je izmerjenim spremenljivkam skupno. Vsak faktor predstavlja skupino izmerjenih spremenljivk, ki med seboj močno korelirajo, prav tako pa močno korelirajo tudi s faktorjem. Faktorsko analizo lahko uporabimo kot merski postopek, s katerim merimo latentne, neposredno merjene spremenljivke, pri tem pa gre za povezavo s klasično testno teorijo, saj če več spremenljivk meri isto dejansko spremenljivko, lahko to dejansko spremenljivko obravnavamo kot faktor, s katerim izmerjene spremenljivke močno korelirajo.

Heise in Bohrnstedt (v Armor 1974, 46; Greene in Carmines 1980, 168) sta se ukvarjala s povezavo med faktorsko analizo in ocenjevanjem zanesljivosti merjenja. Po Bohrnstedtu (v Ferligoj in drugi 1995, 46) lahko s faktorskim modelom zanesljivost merjenja ocenimo s koeficientom omega (Ω):

$$\Omega = 1 - \frac{\sum_{i=1}^N a_i^2 - \sum_{i=1}^N \sigma_i^2 h_i^2}{\sum_{i=1}^N \sum_{j=1}^N a_{ij}^2},$$

kjer je a_i^2 komunaliteta i -te izmerjene spremenljivke X_i in N število izmerjenih spremenljivk.

Če pa imamo izračunane koeficiente korelacije med izmerjenimi spremenljivkami in z R označimo vsoto vseh koeficientov korelacije, lahko zgornjo enačbo poenostavimo takole:

$$\Omega = 1 - \frac{N - \sum_{i=1}^N h_i^2}{N + 2R}.$$

V magistrski nalogi smo zanesljivost ocenjevali z obema koeficientoma Ω , ki sta opisana zgoraj – s koeficientom Ω na kovariančni matriki in s koeficientom Ω na korelacijski matriki. Oba izhajata iz faktorske analize, razlika med njima pa je v njuni osnovi za faktorsko analizo; ki je pri enem koeficientu Ω je to kovariančna matrika, pri drugem pa korelacijska matrika.

Koeficient Ω upošteva različne uteži spremenljivk na faktorju in je za iste podatke največji in najbližje dejanski oz. pravi zanesljivosti merjenja (Carmines in Zeller 1979, 62). Ocenhene merske napake so lahko velike zaradi slučajnih napak ali pa zaradi neenakovrednosti izmerjenih spremenljivk. Če za enofaktorski merski model ocenimo nizko zanesljivost, skušamo najti ustrezni dvofaktorski model.

Koeficient Ω torej izhaja iz faktorske analize in ocenjuje pravo vrednost variance s pojasnjeno varianco, ki jo pojasnjujejo faktorji ali pa latentne spremenljivke. Ta pristop ocenjevanja zanesljivosti obsega tako nehomogene kot tudi unidimenzionalne nabore indikatorjev (Raykov in Shrout 2002, 197).

4.3 Primerjava / odnos med koeficientom α in koeficientom Ω

Več teoretikov je že poskušalo ugotoviti, kateri izmed koeficientov za ocenjevanje zanesljivosti merjenja bo podal boljšo oceno. Glede na odnos med koeficientom Ω in Cronbachovim koeficientom α se večina avtorjev (Carmines in Zeller 1979, 62; Greene in Carmines 1980, 168) strinja, da koeficient Ω v splošnem poda boljšo oceno zanesljivosti merjenja kot koeficient α .

Koeficient Ω upošteva različne uteži spremenljivk na faktorju. Ker je določen s komunalitetami, je ocenjeni koeficient Ω v primerjavi s Cronbachovim koeficientom α večji in bližji dejanski zanesljivosti merjenja ter nikoli ne bo podal slabše ocene (Greene in Carmines 1980, 170).

Tako kot koeficient α je tudi koeficient Ω načeloma enak spodnji meji zanesljivosti, le-to vrednost pa Ω izenači v primeru, ko so vse sistematične variance indikatorjev enake splošni varianci oz. ko je diagonalna matrika specifičnih varianc indikatorjev ničelna matrika (Greene in Carmines 1980, 169), koeficient α pa izenači dejansko zanesljivost (in torej ni le enak njeni spodnji meji), ko je izpolnjen pogoj o »essentially« tau-

enakovrednosti. To pa pomeni, da so pogoji za doseganje prave zanesljivosti bolj strogi pri koeficientu α , zato bo Ω večkrat podal boljšo oceno zanesljivosti.

Zveza med koeficientoma je torej: $\alpha \leq \Omega$ (Ferligoj in drugi 1995, 47).

5 MONTE CARLO SIMULACIJE

Simulacije so »empirična metoda za ocenjevanje/vrednotenje statistik« (Paxton v Stephenson in Lance Holbert 2003, 341). So torej metoda oz. eksperiment, s katerim ocenimo verjetnost določenih rezultatov ali pa primerjamo druge metode med seboj. Omogoča pa tudi manipuliranje s statistikami oz. popoln nadzor okolja izvedbe eksperimenta. Z metodo simulacij lahko raziskovalec opazuje spremenjanje določene statistike ali statistik pri določenih/različnih parametrih, ki jih lahko poljubno spremenjam oz. določamo (Stephenson in Lance Holbert 2003, 341). Predvsem je pomembno, da pri simulacijah, kjer podatke generiramo sami, poznamo pravo populacijsko vrednost, ki jo sicer pri »običajnem« naboru podatkov ne poznamo (Carmines in Zeller 1979, 29), saj v družboslovju v vzorec skoraj nikoli ni mogoče zajeti celotne populacije. Tako s simulacijami ustvarimo kontrolirane pogoje, pri katerih so narejene oz. »proizvedene« vzorčne porazdelitve ocene parametra (Paxton in drugi 2001, 289).

Simulacije omogočajo, da so podatki slučajno generirani, določimo pa lahko osnovne parametre in obliko porazdelitve, vse to pa lahko poljubno spremenjam in med seboj primerjamo različne situacije na podatkih (Podgornik in drugi 2004). Izide oz. rezultate določamo z nastavljivo vhodnih parametrov, postopek pa se ponavadi mnogokrat ponovi, npr. 1.000-krat. Glavna prednost metode simulacij pa je možnost generiranja slučajnih spremenljivk, ki jim lahko določimo nabor lastnosti (Stephenson in Lance Holbert 2003, 341).

Monte Carlo simulacije so torej odličen način za ocenjevanje cenilk in statistik, ki merijo, kako dobro se podatki prilegajo določenemu modelu (ang. *goodness-of-fit statistics*) pod različnimi pogoji, npr. pri različnih velikostih vzorca, nenormalni porazdelitvi, dihotomnih ali ordinalnih spremenljivkah, različnih kompleksnostih modela itd. (Paxton in drugi 2001, 288).

Prednost simulacij je slučajno generiranje podatkov in hitra ponovitev postopka, kar povečuje možnost posploševanja in veljavnost rezultatov (Paxton v Stephenson in Lance Holbert 2003, 342), ter poznavanje prave populacijske vrednosti, kar je velika prednost, saj sicer to v raziskovanju skoraj ni mogoče, saj navadno delamo na vzorcu in iz tega sklepamo na populacijo.

6 MODELIRANJE STRUKTURNIH ENAČB (SEM)

Modeliranje strukturnih enačb lahko definiramo kot skupino metodologij, ki imajo za cilj predstavljati hipoteze o povprečjih, variancah in kovariancah na danih podatkih, glede na manjše število »strukturnih« parametrov, ki so definirani v hipotezi modela (Kaplan 2000, 1). Včasih pa je cilj analize le ocenjevanje merskega modela (Ullman 2006, 37). Ta nabor tehnik pa izhaja iz splošnega linearnega modela. S temi tehnikami pa se lahko preučuje, kakšni so odnosi med naborom neodvisnih spremenljivk in naborom odvisnih spremenljivk, pri čemer gre v obeh primerih lahko tako za diskrete kot tudi za zvezne slučajne spremenljivke, ki so direktno opazovane ali pa latentne (Ullman 2006, 35). Ponavadi se analize izvajajo na velikih vzorcih in na velikem številu opazovanih spremenljivk.

Danes je to ena izmed bolj priljubljenih statističnih metodologij, ki jih uporabljamo v družboslovju v kvantitativnih študijah, pogostost uporabe te metodologije pa se še povečuje. Znotraj modeliranja obstaja veliko aspektov, npr. ocenjevanje parametrov, testiranje modelov, ocenjevanje vrednosti in statistične značilnosti parametrov, ocenjevanje prileganja modela, kar je najbolj kritičen korak modeliranja strukturnih enačb (Bentler in Yuan 1999, 181).

Ta metodologija je pravzaprav hibrid dveh različnih statističnih tradicij, in sicer faktorske analize (ki se je razvila v psihologiji in psihometriji) in simultanega modeliranja enačb (ki izhaja iz ekonometrije). Slednje imenujemo tudi analiza poti (ang. *path analysis*). Ta pojem se nanaša na modelirne sisteme strukturnih odnosov med naborom opazovanih spremenljivk (Kaplan 2000, 2).

Splošni model strukturne enačbe, ki ga je l. 1973 predstavil švedski statistik dr. Jöreskog, je sestavljen iz dveh delov, in sicer iz merskega dela (ki povezuje opazovane spremenljivke z latentnimi spremenljivkami skozi potrditveni faktorski model) in

strukturnega dela, ki med seboj povezuje latentne spremenljivke skozi sisteme simultanih enačb.

Diagrami so v metodologiji modeliranja struktturnih enačb bistvenega pomena, saj raziskovalcu omogočajo, da si lažje predstavlja odnose med spremenljivkami, kar tako rekoč že predstavlja določen model. Obstaja naslednja terminologija za načrtovanje in branje diagramov:

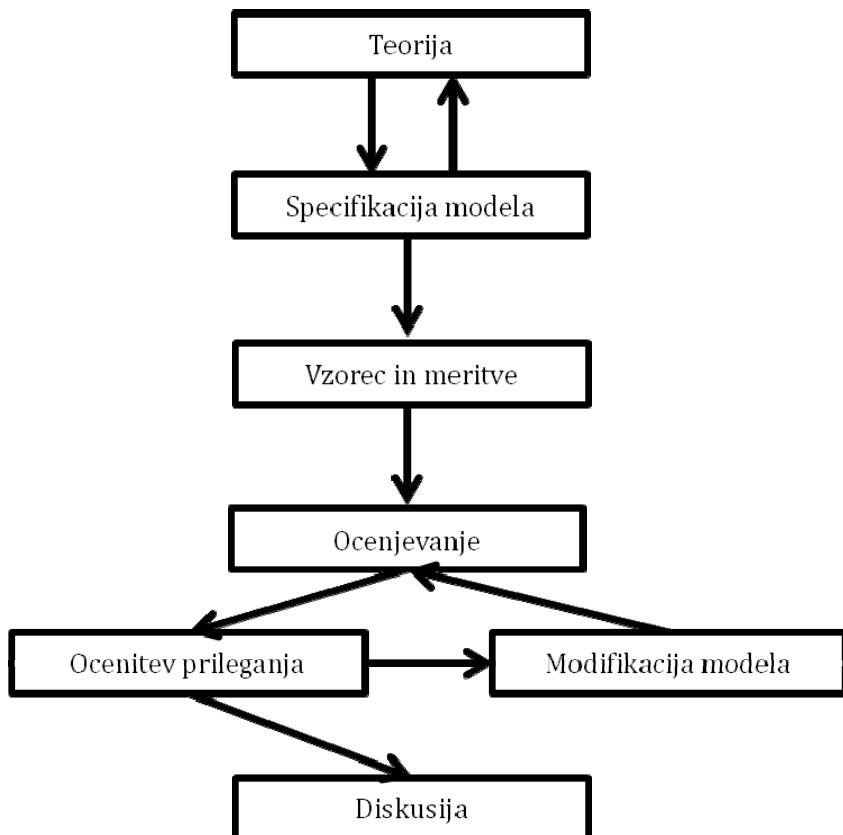
- opazovane spremenljivke se imenujejo tudi merjene spremenljivke, indikatorji ali manifestne spremenljivke;
- faktorji so latentne spremenljivke z dvema ali več indikatorji, ki jih imenujemo tudi konstrukti ali neopazovane spremenljivke, v diagramu pa jih prikažemo s krogi ali ovali;
- povezave v diagramu predstavljajo odnose med spremenljivkami; povezava z eno puščico predstavlja hipotetično direktno povezavo med spremenljivkama (in jasno vedno kaže od neodvisne spremenljivke k odvisni), povezava, ki pa ima na vsakem koncu po eno puščico, pa predstavlja kovarianco med spremenljivkama, brez usmerjenega efekta;
- merski model je del diagrama, ki povezuje opazovane spremenljivke in faktorje, strukturni model pa so hipotetične povezave med konstrukti (Ullman 2006, 36-37).

Relacije v diagramu so direktno pretvorjene v enačbe, na podlagi katerih se lahko model nato oceni; to imenujemo tudi statistična specifikacija modela. Po metodi Bentler-Weeks se strukturalna enačba zapiše za vsako odvisno spremenljivko, ocenjevani parametri pa so regresijski koeficienti in variance ter kovariance neodvisnih spremenljivk (Bentler v Ullman 2006, 40).

Primer zapisa: $Y = X\beta + e$, kjer je Y odvisna spremenljivka, X in e pa sta neodvisni spremenljivki. Zapis enačb so ponavadi v obliki matrične algebре, zato lahko v tem primeru zgornjo enačbo zapišemo:

$\eta = \beta\eta + \gamma\xi$, kjer η vektor $q \times 1$ odvisnih spremenljivk (q je število odvisnih spremenljivk), β je matrika $q \times q$ (regresijski koeficienti med odvisnimi spremenljivkami), γ predstavlja $q \times r$ matriko regresijskih koeficientov med odvisnimi spremenljivkami (r je število neodvisnih spremenljivk) in ξ je vektor $r \times 1$ neodvisnih spremenljivk (Ullman 2006, 40).

Slika 6.1: Običajen pristop modeliranja struktturnih enačb



Vir: Kaplan (2000, 8)

Na Sliki 6.1 je prikazan običajen pristop k modeliranju struktturnih enačb, ki ga najpogosteje uporabljamo v družboslovnih in behaviorističnih vedah. Izhajamo iz teorije, s katero model specificiramo. Nato izberemo vzorec in izvedemo meritve, na podlagi katerih lahko ocenimo parametre modela. Na tej točki lahko najprej ocenimo meritveni model in šele nato struktturni model, ali pa celoten model ocenimo kar v enem koraku. Naslednji korak je ocena prileganja modelu, sledi pa sprememba modela, če je to

potrebno. Ta faza je ponavadi ciklična, kot to kaže slika. Prileganje modelu ocenujemo in model spremojamo toliko časa, dokler le-ta ne zadosti potreb po določenem standardu prileganja (Kaplan 2000, 8). Avtor opozarja, da včasih boljše prileganje pomeni boljšo povezavo s podatki, vendar pa ne nujno tudi s teorijo. Sicer pa se redko zgodi, da modele strukturnih enačb uporabljamo za potrjevanje teoretičnih predpostavk (Kaplan 2000, 9).

Ullman (2006, 39-49) pa predlaga nekoliko poenostavljen različico korakov modeliranja strukturnih enačb, ki sicer temelji na potrdilni faktorski analizi (CFA).

Specifikacija modela

V tem koraku gre za definiranje hipotez v obliki diagrama in v obliki strukturnih enačb, za statistično identifikacijo modela ter za ocenjevanje statističnih predpostavk, ki so osnova modela.

Pri identifikaciji modela najprej preštejemo točke podatkov⁵ in parametre, ki jih bomo ocenili. Točke podatkov so nabor ne-redundantnih vzorčnih varianc in kovarianc, njihovo število pa je enako izrazu: $\frac{p(p+1)}{2}$, kjer je p število opazovanih spremenljivk.

Predpogoj ocenjevanja parametrov modela poti je ugotavljanje, ali so parametri identificirani, kar pomeni, da so parametri enolično določeni z vzorčnimi podatki. Če parametri modela niso identificirani, potem parametrov seveda ne moremo oceniti (Kaplan 2000, 19; Ullman 2006, 40). Da je model lahko ocenjen, pa mora biti število točk podatkov večje od števila ocenjevanih parametrov.

Tudi število faktorjev vpliva na to, ali je model lahko identificiran in nato ocenjen. Če je v modelu en sam faktor, je model lahko identificiran, če ima faktor vsaj tri indikatorje z ne-ničelnimi utežmi in če napake oz. reziduali med seboj ne korelirajo. Če sta v modelu dva faktorja, so premisleki enaki. Če ima vsak faktor tri indikatorje ali več, napake, povezane z indikatorji, med seboj ne smejo korelirati.

⁵ Podatki v metodologiji modeliranja strukturnih enačb so variance in kovariance v vzorčni kovariančni matriki, za to pa so potrebni večji vzorci (Ullman 2006, 40-41).

Ocenjevanje modela

Cilj tega koraka je minimizirati razlike med strukturiranimi in nestrukturiranimi ocenjenimi populacijskimi kovariančnimi matrikami, kar dosežemo z minimiziranjem funkcije F:

$$F = (\mathbf{s} - \boldsymbol{\sigma}(\boldsymbol{\theta}))\mathbf{W}(\mathbf{s} - \boldsymbol{\sigma}(\boldsymbol{\theta})),$$

kjer je \mathbf{s} vektor s podatki, $\boldsymbol{\sigma}$ je vektor ocenjenih populacijskih kovariančnih matrik, $\boldsymbol{\Theta}$ pa kaže na to, da $\boldsymbol{\sigma}$ izhaja iz parametrov. \mathbf{W} je matrika, ki utežuje kvadrirane razlike med vzorčno in ocenjeno populacijsko kovariančno matriko. Načinov optimizacije je več, vendar ne vplivajo bistveno na rezultat, saj optimizacija (v paketku sem se imenuje »optimizer«) pomeni le drugo pot do rešitve, kriterij (v paketku sem se imenuje »objective«) pa išče drugačno rešitev.

Za ocenjevanje parametrov modela obstaja več metod, ki se razlikujejo glede na matriko \mathbf{W} :

- metoda največjega verjetja (ang. *maximum likelihood* – ML): ta metoda je v različnih programskih paketih za SEM analize privzeta metoda in tudi najpogosteje uporabljena metoda pri srednje velikih in velikih vzorcih, saj poda najbolj natančne ocene (torej z najmanjšimi variancami), če so podatki normalno porazdeljeni. Lahko pa se jo uporabi tudi pri manjših vzorcih; sicer pa ta metoda maksimira prileganje podatkov modelu (Bentler in Yuan 1999, 182);
- metoda splošnih najmanjših kvadratov (ang. *generalised least squares* – GLS): ta metoda deluje podobno kot ML pri normalnih porazdelitvah;
- metoda brez predpostavke o porazdelitvah (ang. *asymptotically distribution free* – ADF): ker metoda ne predpostavlja nobene specifične porazdelitve, je najbolj splošna, vendar je zato pri velikih vzorcih tudi najmanj natančna (Kaplan 2000, 25-29; Ullman 2006, 42);
- metoda neuteženih najmanjših kvadratov (ang. *unweighted least squares* - OLS): ta metoda maksimira pojasnjeno varianco in minimizira nepojasnjeno varianco;

metoda je pogosto uporabljena za ocenjevanje zanesljivosti in ta ocena se lahko primerja z oceno zanesljivosti s koeficientom α (Graham 2006, 937).

Ovrednotenje modela

Pri modeliranju strukturnih enačb je zelo pomembno, kako dobro se podatki prilegajo modelu. Obstaja veliko indeksov, s katerimi ovrednotimo prileganje modela, najpogosteje pa je uporabljen primerjalni fit indeks (ang. *comparative fit index*), ki temelji na necentralizirani χ^2 porazdelitvi, njegove vrednosti pa se nahajajo na intervalu [0,1], pri čemer 1 pomeni popolno prileganje podatkov modelu. Pogosto se uporabi tudi indeks, ki temelji na rezidualih, in sicer na korenju povprečne kvadrirane napake približka (ang. *the root mean square error of approximation*), ki pravzaprav ocenjuje pomanjkanje prileganja modelu in to primerja s popolnim modelom (Ullman 2006, 44).

Model pa lahko ovrednotimo tudi z analizo standardiziranih rezidualov (Ullman 2006, 45), ker jih lahko interpretiramo kot rezidualno korelacijo, ki ni pojasnjena z modelom. Če je npr. povprečen standardiziran kovariančni rezidual enak 0.0185 in povprečna standardizirana varianca enaka 0.021 in če obe vrednosti kvadriramo, dobimo odstotek povprečne variance, ki je model ne pojasni, kar v konkretnem primeru pomeni, da model na pojasni 0.035 % varianc v variancah merjenih spremenljivk, prav tako pa ne pojasni 0.044 % varianc v kovariancah. Te zanemarljive številke pa torej pričajo o tem, da gre za dobro prileganje modela podatkom.

Modifikacija modela

Najbolj očitna razloga za modifikacijo modela sta testiranje hipotez (bolj teoretsko delo) in izboljšanje prileganja (predvsem za raziskovalno delo), zato se tudi analiza iz potrditvene ravni premakne na raziskovalno raven. Obstajajo tri osnovne metode za modifikacijo modelov: χ^2 test razlik, LM test in Wald test (Ullman 2006, 47-49).

Modeliranje strukturnih enačb teži k opisovanju aritmetičnih sredin, varianc in kovarianc nabora spremenljivk glede na manjše število »struktturnih parametrov«. Nabor odnosov med spremenljivkami lahko sestavimo v model glede na sisteme enačb in vsak strukturni model lahko izrazimo z vrsto enačb (Kline 1998, 52). Modeliranje

sistemov strukturnih odnosov med opazovanimi spremenljivkami pa imenujemo tudi analiza poti (Kaplan 2000, 13).

Obstajata dva tipa analiz oz. tehnik za modeliranje strukturnih enačb:

- faktorska analiza: znotraj le-te obstajata pojasnjevalna/potrdilna faktorska analiza (CFA – ang. *confirmatory factor analysis*) in raziskovalna faktorska analiza (EFA – ang. *exploratory factor analysis*);
- analiza poti (ang. *path analysis*).

Oba tipa analiz sta opisana v nadaljevanju.

6.1 Faktorska analiza in SEM

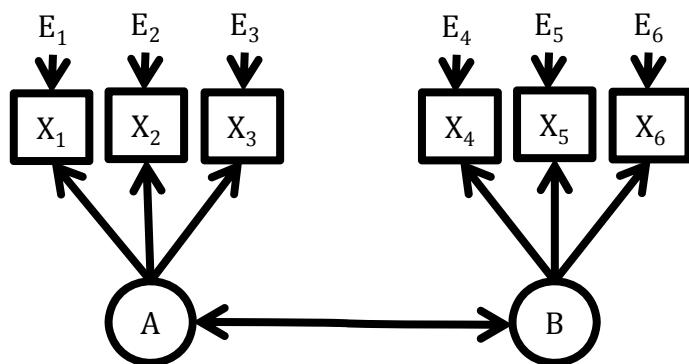
Raziskovalna faktorska analiza (EFA) stremi k odkrivanju zapletene strukture, ki morda povezuje med seboj opazovane spremenljivke. Z vidika faktorske analize to pomeni, da nas zanima število faktorjev, kakšne so povezave med njimi ter kakšne so povezave med spremenljivkami in faktorji. Navadno EFA poda več možnih rešitev, naloga raziskovalca pa je, da izbere najbolj optimalno glede na teorijo in opisno statistiko. Nanaša se na nabor procedur, ki med drugim vključujejo tudi metodo glavnih komponent, predvsem pa nas zanima število faktorjev. Z EFA analizo dobimo informacijo o relacijah med faktorji in o spremenljivkah na posameznem faktorju. EFA je pravzaprav merski model, ki ga lahko gledamo kot strukturni model, ki predpostavlja vzročne odnose latentnih spremenljivk na opazovane spremenljivke (Kline 1998, 58).

Potrdilna faktorska analiza (CFA) je primerna takrat, ko raziskovalec že definira hipotetične odnose med spremenljivkami in faktorji, obravnava pa praktična vprašanja, kot je npr. veljavnost strukture lestvice. CFA omogoča, da natančno določimo in testiramo merske modele ter da določimo uteži na faktorju, z EFA analizo, ki prav tako ocenjuje uteži na faktorju, pa ne moremo testirati modelov (Kline 1998, 60). Cilj te analize je testiranje postavljene hipotetične strukture in včasih tudi testiranje drugih teoretskih modelov o tej strukturi. Z vidika same faktorske analize tu niso vključene faktorske ekstrakcije in rotacije (Ullman 2006, 37).

Glavna razlika med obema tipoma analize je ta, da CFA temelji na statističnem testu, ki primerja ocenjeno ne-strukturirano populacijsko kovariančno matriko in ocenjeno strukturirano populacijsko kovariančno matriko (Ullman 2006, 37).

Pri CFA imamo spremenljivke, ki jih lahko opazujemo le posredno preko drugih spremenljivk, ki jih dejansko lahko izmerimo. Tu velja, da več (smiselnih) indikatorjev kot je vključenih, boljši in bolj zanesljiv je model (Kline 1998, 55). Vendar je model seveda lahko tudi precej drugačen glede na nabor indikatorjev, ki jih v model vključimo. Za latentne spremenljivke oz. faktorje v modelu se predpostavlja, da med seboj korelirajo (Kline 1998, 190-191). V SEM modelu torej na podlagi teorije predpostavljamo o odnosih med indikatorji, in sicer na hipotetičnem konstraktu, ki naj bi ga ti indikatorji merili. Predpostavke pa v modelu analizirano s kovariancami med indikatorji.

Slika 6.2: Standardni CFA merski model



Vir: Kline (1998, 199)

Kline (1998, 199) povzame glavne značilnosti CFA modelov (Slika 6.2):

- vsak indikator v modelu (X_s) ima dva vpliva: faktor (oz. latentni spremenljivki A in B), ki naj bi ga indikator meril, in merske napake (E_s);
- merske napake so neodvisne in nekorelirane med seboj in od faktorjev (velja za osnovne in enostavne CFA modele);
- vse mogoče povezave med faktorji ostanejo neanalizirane.

V nekaterih primerih CFA model, kjer so indikatorji vzrok faktorjev oz. da faktorji vplivajo na indikatorje, ni najbolj primeren, temveč ravno obratno – indikator vpliva na faktor, kar pomeni, da je faktor notranji in ne zunanji del modela, to pa tehnično pomeni, da gre za hibridni model.

Merske napake so vsi viri varianc, ki jih ne znamo pojasniti na podlagi faktorja, lahko pa jih opazujemo tudi kot zunanje spremenljivke, ki jih ne merimo. Če predpostavimo, da ima vsak indikator uteži le na enem faktorju in če so merske napake med seboj neodvisne, potem gre za unidimenzionalen model. Če je kršena vsaj ena predpostavka takih modelov, potem gre za multidimenzionalne modele. CFA modeli so lahko tudi taki, da merske napake med seboj korelirajo znotraj enega faktorja, lahko tudi med faktorji.

Obstaja več načinov za identifikacijo CFA modela (Kline 1998, 203-206), kar je odvisno od njegove strukture. Zapisan je ta, ki je bistven v tej magistrski nalogi.

Imamo unidimenzionalen model z enim faktorjem. Pogoji za identifikacijo modela so naslednji (prva dva sta za identifikacijo nujno potrebna, tretji pogoj pa je zadosten):

- število parametrov v modelu mora biti manjše ali enako številu opazovanj;
- vsak faktor mora imeti lestvico oz. merilo;
- v model morajo biti vključeni vsaj trije indikatorji.

Glede na že omenjene merske modele klasične testne teorije, lahko s CFA analizo testiramo, ali nabor indikatorjev ustreza kongeneričnemu, tau-enakovrednemu ali vzporednemu modelu (Kline 1998, 219-220).

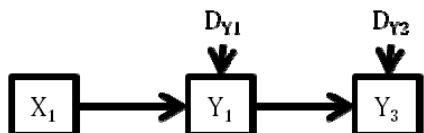
Pri kongeneričnemu modelu gre za preprosto standardni enofaktorski model brez kakršnihkoli drugih omejitev glede napak in faktorjev. Če takemu modelu dodamo zahtevalo, da so vse faktorske uteži enake, testiramo, če so indikatorji v modelu tau-enakovredni. Če slednja trditev drži in dodamo zahtevalo, da so vse napake enake, in prileganje podatkov ni slabše kot pri tau-enakovrednosti, potem gre za vzporedni model.

6.2 Analiza poti in SEM

Analiza poti je primerna tehnika takrat, ko že imamo postavljeno hipotezo o vzročnih odnosih med spremenljivkami; zanima nas ena sama spremenljivka, opazujemo pa vse, ki nanjo vplivajo, odnosi med temi zunanjimi spremenljivkami pa za analizo poti niso bistvenega pomena. V prvem koraku analize poti izberemo struktturni model, ki ustreza hipotezi (Kline 1998, 51).

Cilj analize poti je ocena vzročnih in nevzročnih aspektov opazovanih korelacijs, saj gre pri tej analizi predvsem za preučevanje vzročnih odnosov med opazovanimi spremenljivkami in te odnose želimo pojasniti (Kline 1998, 96).

Slika 6.3: Model analize poti



Vir: Kline (1998, 245)

Ker nas pri analizi poti zanimajo predvsem vzročna razmerja v modelu (primer modela analize poti je prikazan na Sliki 6.3), želimo podrobno preučiti vzroke oz. zunanje dejavnike/spremenljivke (X) za notranje spremenljivke (Y). V modelu so prisotni tudi drugi zunanji vplivi (D) oz. motnje (ang. *disturbances*), ki jih v modelu ne merimo. Lahko gre za direktno ($X_1 \rightarrow Y_1$) ali pa indirektno ($X_1 \rightarrow Y_1 \rightarrow Y_3$) vzročnost, pri čemer pa je v obeh primerih X vzrok za obe notranji spremenljivki. Predvideva se, da so zunanje spremenljivke in motnje ponavadi nepovezane.

Kline (1998, 97) zapiše tri pogoje, ki morajo biti izpolnjeni, da lahko trdimo, da je X vzrok za Y (modela tako ne moremo zavrniti kot napačnega):

- časovna prednost X pred Y (X časovno obstaja pred Y);
- X vpliva na Y in nikoli obratno (smer vpliva je fiksna);
- če so vsi drugi vplivi konstantne, se X - Y odnos ne spremeni.

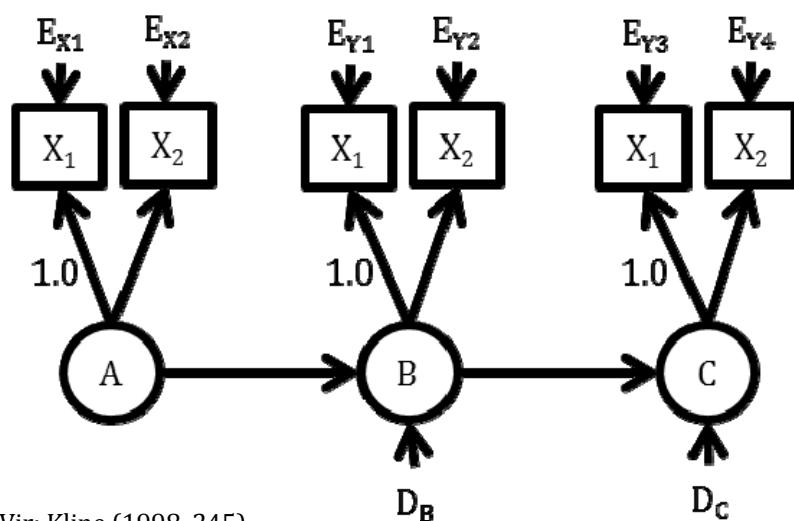
Pogoj za identifikacijo modela analize poti je ta, da mora biti število opazovanj enako ali večje od števila vključenih parametrov.

6.3 Hibridni modeli

Hibridni modeli so pravzaprav sinteza analize poti in merskih modelov, npr. CFA. Ker z njimi lahko testiramo hipoteze o različnih vzročnih odnosih med spremenljivkami, ki so lahko tudi latentne. Gre za zelo fleksibilno metodo, saj lahko v enem samem modelu testiramo hipoteze o strukturnih (izhajajoč iz analize poti) in merskih odnosih, kot npr. iz faktorskega modela (Kline 1998, 62).

Na Sliki 6.4 je prikazan hibridni model, ki vključuje tako strukturne kot tudi merske komponente - tako lahko izmerimo uteži na posameznih faktorjih in tudi odnose med faktorji. Pari opazovanih spremenljivk (od X_1 do Y_4) so na posameznem faktorju (A, B in C), te faktorji pa so med seboj v vzročnih odnosih, kar je podobno kot pri analizi poti, le da so tam v vzročnih odnosih opazovane in ne latentne spremenljivke. Na notranji latentni spremenljivki (B in C) delujejo motnje, ki so v tem primeru le izpuščeni oz neupoštevani vplivi.

Slika 6.4: Hibridni model



Vir: Kline (1998, 245)

S CFA v modelu preučimo indikatorje na posameznem faktorju, z analizo poti pa ocenimo vzročne efekte. Vendar samo z uporabo analize poti ne bi mogli izmeriti teh efektov na latentnih spremenljivkah, temveč samo na opazovanih. Če bi strukturne

odnose ocenili le z analizo poti, ne bi poznali napake merjenja in je tudi ne bi mogli kontrolirati (Kline 1998, 64). Pri analizi in ocenjevanju hibridnih modelov strukturni in merski del obravnavano posebej.

6.4 Ocenjevanje zanesljivosti z modeliranjem strukturnih enačb

Zanesljivost je možno oceniti tudi s pomočjo faktorske analize, vendar je metoda modeliranja strukturnih enačb fleksibilnejša (Yang in Green 2011) in je zato uporabljena v nalogi. Modeliranje strukturnih enačb je torej metoda, s katero lahko ocenjujemo zanesljivost.

Zanesljivost sva ocenjevali na tri načine, ki so podrobneje opisani v poglavju 7.2 (Opis generiranja podatkov in postopek izračuna). Gre za zanesljivost, ki se nanaša na notranjo konsistentnost lestvice in je razmerje med variancama dejanske in opazovane spremenljivke. Za ocenjevanje zanesljivosti z metodo SEM je torej potrebno dobiti ocene varianc dejanskih in opazovanih spremenljivk. Varianca dejanske spremenljivke enaka varianci latentne spremenljivke, varianco opazovane spremenljivke pa dobimo s kreiranjem kompozita opazovane spremenljivke, ki ga sestavlajo variance posameznih opazovanih spremenljivk. Ocena zanesljivosti se z metodo SEM izračuna kot kvadrat korelacije med kompozitom latentne dejanske spremenljivke T in kompozitom opazovane spremenljivke X (Graham 2006, 933).

Programski paketi oz. programska oprema, s katero lahko preko modeliranja strukturnih enačb ocenjujemo veljavnost, so LISREL, Amos, CALIS, EQS, LISCOMP, RAMONA, SEPATH (Kline 1998), R in drugi. V nalogi je bila zanesljivost z modeliranjem strukturnih enačb ocenjevana s pomočjo programske opreme R. Brezplačen odprtokodni program R je fleksibilen in zadostuje potrebam v nalogi. Modeliranje strukturnih enačb poteka po korakih, ki so navedeni in na kratko opredeljeni v nadaljevanju.

Koraki modeliranja strukturnih enačb (SEM) so:

1. Določitev modela v obliki strukturne enačbe (ang. *structural equation model*), lahko tudi v obliki diagrama.

2. Preverjanje, ali je model že morda opredeljen. To pomeni, da moramo preveriti, ali je teoretično možno s pomočjo računalnika pridobiti unikatne ocene posameznih parametrov v modelu.
3. Izbera merskih instrumentov in zbiranje podatkov.
4. Analiza modela.
5. Preverjanje ali se model dobro prilagaja na podatke. V večini primerov se model ne prilagaja popolno, v primeru, da se model zelo slabo prilagaja ali se ne prilagaja, je potrebno preurediti model in ga ponovno preveriti (od koraka 1) (Kline 1998, 48-51).

Glede na različne tipe analiz oz. tehnik za modeliranje strukturnih enačb (opisane v prejšnjem poglavju), gre v našem primeru za modeliranje strukturnih enačb s potrdilno faktorsko analizo (CFA). CFA modeli uporabljeni v naši nalogi so: kongenerični, tau-enakovredni in vzporedni model. Zadnjo točko (5) o preverjanju prilagajanja modela izpustili, saj je v našem primeru model točno določen in sprememjanje ni dovoljeno. Gre namreč zato, da smo s pomočjo točeno določenih modelov ocenjevali zanesljivost in že pred analizo modela (glede na 2. točko) nismo iskali drugih modelov. Prilagoditev, ki naj bi po točki (5) sledile po analizi modela, v našem primeru ni, saj smo zanesljivost ocenjevali po »prednastavljenih« modelih in smo želeli ugotoviti, v katerih situacijah določen model najbolje oceni zanesljivost.

Pri ocenjevanju zanesljivosti z modeliranjem strukturnih enačb Graham (2006, 396) predлага naslednje.

Najprej ocenimo prileganje kongeneričnega modela in izračunamo statistike, ki merijo stopnjo prileganja modelov. Kongenerični model je najbolj splošen in bo načeloma vedno boljši od drugih modelov. Nato s statistikami izračunamo prileganje (»essentially«) tau-enakovrednega modela in naredimo primerjavo s prileganjem kongeneričnega modela. Če je razlika velika, to pomeni, da se kongenerični model neprimerno boljše prilega in ga uporabimo za ocenjevanje zanesljivosti. Če pa so rezultati precej podobni, s statistikami izračunamo še prileganje vzporednega modela in ga primerjamo s prileganjem tau-enakovrednega modela. Če je razlika velika, uporabimo

tau-enakovredni model, sicer pa vzporedni model. Prileganje torej testiramo od najbolj splošnega do najstrožjega modela. V nalogi v simulacijah nismo sledili temu postopku, ampak smo zanesljivost ocenili po treh SEM modelih (kongenerični, tau-enakovredni in vzporedni model), saj smo želeli preveriti, kako dobro posamezni model oceni zanesljivost.

Pri postopku najprej določimo vhodne parametre, generiramo podatke in nato nastavimo model (npr. funkcijo, statistični test itd.) oz. izračun, ki ga mnogokrat ponovimo.

Paxton in drugi (2001) predlagajo naslednjih 9 korakov, po katerih se izvede analiza z Monte Carlo simulacijami pri modeliranju strukturnih enačb.

1. Oblikovanje raziskovalnega vprašanja, ki izhaja iz teorije

Potrebna je močna teoretska podlaga, ki vodi celotno oblikovanje in analizo simulacij. Potrebno je natančno vedeti, kaj se raziskuje in kaj želimo ugotoviti, saj je navadno po izvedenem postopku simulacij pridobljenih mnogo podatkov, zato mora biti raziskovalno vprašanje zelo fokusirano in močno vezano na statistično teorijo (Paxton in drugi 2001, 291-292).

2. Izdelava reprezentativnih modelov

Pri oblikovanju Monte Carlo simulacij je ta korak ključen - izdelati je potrebno model, ki je reprezentativen glede na izhodišča (Paxton in drugi 2001, 291-293). Avtorji predlagajo, da raziskovalec pregleda veliko strukturnih modelov enačb s področja, ki ga raziskuje, ter se tako pouči o nekaterih splošnih modelih določenega aplikativnega področja. Tako raziskava dobi neko zunanjost veljavnost, saj se uporabi metod simulacij pogosto očita, da se nekateri povzeti modeli ne skladajo z drugimi modeli, ki so navadno v uporabi v določenih aplikativnih raziskavah. Cilj – pridobiti zunanjost veljavnost – je torej enako pomemben kot testiranje naše hipoteze. Pri tem koraku se je tudi potrebno odločiti, ali bo model bolj splošen ali bolj specifičen, kako kompleksen bo ter kakšni tipi spremenljivk bodo vključeni.

3. Načrtovanje specifičnih eksperimentalnih pogojev

Ko imamo že izbran strukturni model, se odločimo, kako bomo simulacije izvedli, kar pomeni, da določimo, katere predpostavke, ki sledijo iz statistične teorije, bomo kršili oz. pri katerih pogojih bomo simulacije izvedli (Paxton in drugi 2001, 293-296). Obstaja nekaj skoraj »univerzalnih« spremenljivk v simulacijah (saj običajno ne poznamo lastnosti cenilk ali pa statistik za dobro prileganje modelom za male vzorce), ki jih poljubno (a premišljeno) spremišljamo. Take spremenljivke so velikost vzorca, pri čemer so zlasti pomembni vzorci, manjši od 100 enot (še posebno v uporabi v psihologiji in političnih znanostih), oblika porazdelitve opazovanih spremenljivk ter metoda ocenjevanja. Prav tako se navadno naredi kršitev na celotnem modelu – ocenjujemo torej model, ki se od definiranega/izdelanega modela nekoliko razlikuje.

V tem koraku dokončno začrtamo pogoje, pri katerih bomo preverjali raziskovalno vprašanje/hipotezo. Če simulacije npr. izvajamo za tri modele, ki imajo po pet specifikacij (pogojev) na sedmih različnih velikostih vzorcev ter ocenjujemo dve cenilki, dobimo kar 210 povsem originalnih eksperimentalnih pogojev, pri katerih smo simulacije izvedli – to dokazuje, da se s simulacijami pridobi veliko podatkov.

4. Izberi vrednosti populacijskih parametrov

Tukaj izhajamo iz teorije in rezultatov že narejenih raziskav – izberemo vrednosti populacijskih parametrov, pri katerih bomo simulacije izvedli. Izbrane vrednosti parametrov modela odražajo realnost (take vrednosti so bile dosežene v preteklih raziskavah) ter so statistično značilne tudi pri majhnih vzorcih. Nekateri avtorji (v Paxton in drugi 2001, 298-300) predlagajo, da je potrebno oceniti moč modela, pri kateri lahko zavrnemo napačen model (uporabi se χ^2 test). Premisliti je treba tudi o velikosti učinka (vrednosti R^2 , ki pomenijo delež pojasnjene variance, naj bi bile smiselne glede na pretekle raziskave).

5. Izberi pravega programskega paketa

Vse je odvisno od programa, s katerim simulacije izvajamo. Paxton in drugi (2001) so simulacije izvedli s programom SAS (Statistical Analysis System), ki ima seveda drugačne programske paketke kot program R, v katerem so izvedene simulacije za potrebe te magistrske naloge.

6. Dejansko izvajanje simulacij

Poleg dejanskega zapisa simulacij s programom ali v programu je na tem mestu pomembno vprašanje števila ponovitev izračuna za posamezen parameter na posameznem vzorcu. Velja pravilo: več kot je ponovitev, bolj vrednosti skonvergirajo k pravi vrednosti, ki pa jo sicer pri simulacijah poznamo. Za potrebe magistrske naloge smo postopek ponovili 1.000-krat.

7. Shranjevanje datotek

Ker se običajno zgenerira velika količina podatkov, je potrebno premisliti o vprašanjih, kot npr. ali je smiselno shranjevati t.i. surove podatke. Predvsem pa je treba paziti, da si sproti delamo arhiv rezultatov in rezervno kopijo (Paxton in drugi 2001, 306).

8. Odpravljanje težav in preverjanje

Po izvedenih simulacijah je seveda potrebno preveriti, če so se izvedle pravilno, kar lahko ugotovimo z relativno logičnimi in enostavnimi testi, npr. datoteke, ki vsebujejo rezultate večjih vzorcev, zasedejo več prostora v pomnilniku (Paxton in drugi 2001, 308).

9. Povzetek rezultatov

S simulacijami pridobimo veliko podatkov, vendar so običajno le določeni bistveni za raziskovalno vprašanje. Treba je izbrati primeren način prikaza, ki je lahko deskriptivni, grafični ali inferenčni, odvisno od tega, katere statistike so ključen del rezultatov (Paxton in drugi 2001, 308).

V magistrski nalogi sta torej uporabljeni dve pogosto uporabljeni in pomembni metodi v raziskovanju: SEM in metoda simulacij. O prednostih simulacij smo že govorili v enem izmed prejšnjih poglavij. Prednosti metode modeliranja struktturnih enačb je veliko, npr. da pri raziskovanju povezav med faktorji med povezavami teoretično ni merskih napak, saj so bile ocenjene in odstranjene, kar povečuje zanesljivost merjenja. Poleg tega je modeliranje struktturnih enačb edina analiza, s katero lahko simultano testiramo vse povezave oz. odnose v modelu – da lahko testiramo hipoteze na ravni konstrukta in ne le

na ravni merjene spremenljivke je zelo pomembna prednost pred ostalimi metodami (Ullman 2006, 38).

O simuliranju in modeliranju strukturnih enačb v tej magistrski nalogi podrobneje v nadaljevanju.

7 IZVEDBA SIMULACIJ IN PRIMERJAVA OCEN ZANESLJIVOSTI

Cilj magistrske naloge je na generiranih podatkih oceniti zanesljivost merjenja s 7 različnimi koeficienti za ocenjevanje zanesljivosti (»navadni« Cronbachov α koeficient in standardizirani α koeficient, dva različna koeficiente Ω , izhajajoč iz korelacijskih matrik in kovariančnih matrik, ter 3 koeficienti, ki izhajajo vsak iz svojega strukturnega modela, pri čemer ima vsak model svoje predpostavke). Cilj naloge je tudi te ocene zanesljivosti med seboj primerjati in podati predloge, katere koeficiente za ocenjevanje zanesljivosti je priporočljivo in primerno uporabiti pri različnih podatkih oz. v določenih merskih situacijah. Postopek generiranja podatkov smo ponovili 1.000-krat, izračune koeficientov in celotne ponovitve pa smo izvedli z Monte Carlo simulacijami.

Podatke smo generirali na podlagi štirih različnih varianc in šestih različnih faktorskih uteži. Faktorske uteži smo definirali z matrikami oz. vektorji z enakimi faktorskimi utežmi, različnimi faktorskimi utežmi in ekstremno različnimi faktorskimi utežmi. Poimenovali smo jih A1, A2, A3, A4, A5 in A6. Definirali smo jih na naslednji način:

Tabela 7.1: Matrike uteži glede na vrednosti/način izračuna

VREDNOSTI/NAČIN IZRAČUNA	
A1: ENAKE NIZKE UTEŽI	0.3, 0.3, 0.3, 0.3, 0.3
A2: ENAKE SREDNJE UTEŽI	0.5, 0.5, 0.5, 0.5, 0.5
A3: ENAKE VISOKE UTEŽI	0.8, 0.8, 0.8, 0.8, 0.8
A4: RAZLIČNE UTEŽI	0.17, 0.33, 0.50, 0.67, 0.83
A5: VEČJE MANJ RAZLIČNE UTEŽI	0.5, 0.6, 0.7, 0.8, 0.9
A6: BOLJ RAZLIČNE UTEŽI	0.19, 0.38, 0.58, 0.77, 0.96

Matrike oz. vektorji A1, A2 in A3 imajo enake faktorske uteži. Ker predvidevamo, da le-te vplivajo na zanesljivost, smo to tudi preizkusili, in sicer tako, da smo generirali nizke, vendar enake faktorske uteži, srednje visoke enake faktorskse uteži in visoke enake faktorskse uteži. V matriki A1 so nizke enake faktorske uteži, ki imajo vse vrednosti 0.3;

gre za matriko dimenzijske 1x5 oz. vektor z vrednostmi 0.3. Vektor A2 je vektor srednje velikih, vendar enakih faktorskih uteži, vse njegove vrednosti so enake 0.5. Vektor A3 ima visoke faktorske uteži, in sicer so enake 0.8. Vektorja A4 in A5 imata različne faktorske uteži. Prvi (A4) ima različne faktorske uteži, in sicer z vrednostmi 0.1666667, 0.3333333, 0.5000000, 0.6666667, 0.8333333. Izračunan je tako, da je vsaki prejšnji vrednosti prišteta ena šestina (1/6 oz. 0.1666667). Večje manj različne faktorske uteži so predstavljene z vektorjem A5, ki ima vrednosti: 0.5, 0.6, 0.7, 0.8, 0.9 (začetni vrednosti 0.5 je prišteto 0.1, prav tako pa vsaki naslednjem). Te so sicer manj različne kot pri A4, vendar pa so v povprečju večje. V zadnji različici faktorskih uteži so bolj različne faktorske uteži, gre za vektor A6 z vrednostmi 0.1923077, 0.3846154, 0.5769231, 0.7692308, 0.9615385. Faktorske uteži tega vektorja so med seboj zelo različne. Izračunane so tako, da je vsak deljenec (zaporedje števil od 5 do 25, ki se povečujejo za 5) deljen s 26 oz. drugače povedano, če je i indeks spremenljivke od 1 do 5), potem je faktorska utež $5i/26$.

Drugi parameter, s katerim smo upravljali, so variance, in sicer smo generirali podatke glede na:

- enake skupne variance (ki so izračunane tako, da so pri vnaprej določenih faktorskih utežeh pri vseh spremenljivkah enake),
- različne variance (1:3), kar pomeni, da je v matriki različnih varianc razmerje med najmanjšo in največjo varianco 1:3,
- na zelo različne variance (1:10), kjer je razmerje med najmanjšo in največjo varianco 1:10,
- na enake variance napak – poimenovali smo jih Psi1 (enake skupne variance), Psi2 (različne variance 1:3), Psi3 (različne variance 1:10) in Psi4 (enake variance napak) in jim priredili naslednje vrednosti:

Tabela 7.2: Matrike varianc glede na vrednosti/način izračuna

DIAGONALNE VREDNOSTI MATRIKE/NAČIN IZRAČUNA	
Psi1: ENAKE SKUPNE VARIANCE	1-diag(A^*A^T)
Psi2: RAZLIČNE VARIANCE 1:3	0.2, 0.3, 0.4, 0.5, 0.6
Psi3: RAZLIČNE VARIANCE 1:10	0.09, 0.29, 0.495, 0.698, 0.9
Psi4: ENAKE VARIANCE NAPAK	0.75, 0.75, 0.75, 0.75, 0.75

Psi1 oz. matrika enakih skupnih varianc, dimenzije 5×5 , ima vrednosti na diagonali izračunane glede na matriko faktorskih uteži (A), kjer je vrednosti 1 odštet vektor oz. diagonala, ki je matrični zmnožek matrike faktorskih uteži (A) in njene transponirane matrike (A^T), ali drugače povedano kvadrat matrike faktorskih uteži (A^2). Druga matrika je matrika (Psi2) z različnimi variancami, ki ima razmerje med najmanjšo in največjo vrednostjo 1:3. Te vrednosti so 0.2, 0.3, 0.4, 0.5, 0.6 in predstavljajo diagonalo matrike Psi2, vse ostale vrednosti v matriki so enake 0. Psi3 je matrika zelo različnih varianc, katere vrednosti so v razmerju 1:10 (razmerje med najmanjšo in največjo vrednostjo na diagonali matrike). Vrednosti matrike Psi3 so 0.090, 0.2925, 0.495, 0.6975, 0.9, vse ostale vrednosti pa so enake 0. Matrika Psi4 je matrika enakih varianc napak in je izračunana na podlagi vektorja enakih faktorskih uteži, in sicer enakih srednjih faktorskih uteži, ki imajo vrednosti 0.5 (v našem primeru ima ta vektor matrika A2). Če so uteži na vseh spremenljivkah enake, so posledično tudi variance napak enake, zato smo se odločili za take variance napak. Če uteži na spremenljivkah niso enake, potem je varianca napak razlika med 1 in kvadratom uteži. Psi4 je torej matrika, ki ima na diagonali razliko med 1 in zmnožkom matrike oz. vektorja z enakimi srednjimi faktorskimi utežmi (A2), vse druge vrednosti izven diagonale pa so enake 0.

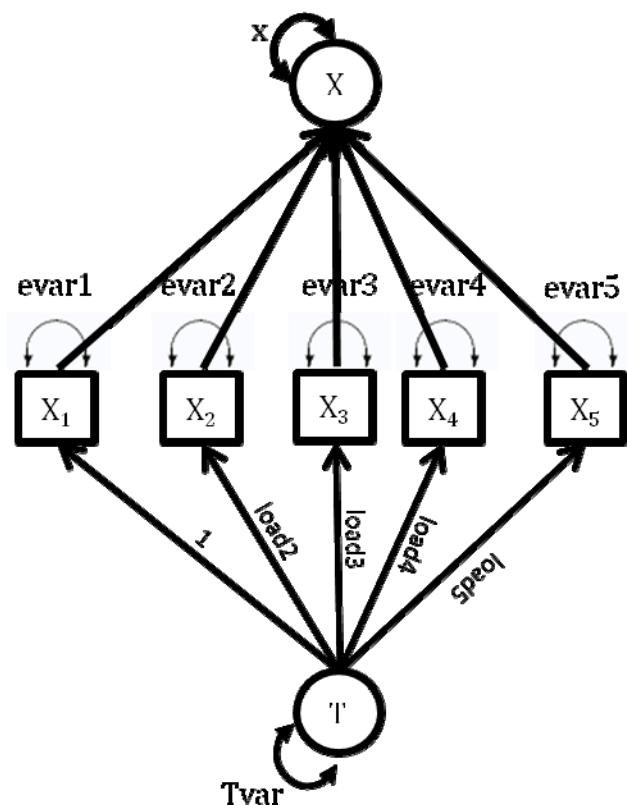
Generirali smo vse možne kombinacije faktorskih uteži in različnih varianc.

Simulacije za vsako izmed zgoraj navedenih kombinacij parametrov smo računali na treh različno velikih vzorcih, in sicer malem, ki ima 100 enot, srednjem (500 enot) in velikem (1.000 enot).

7.1 Uporabljeni modeli

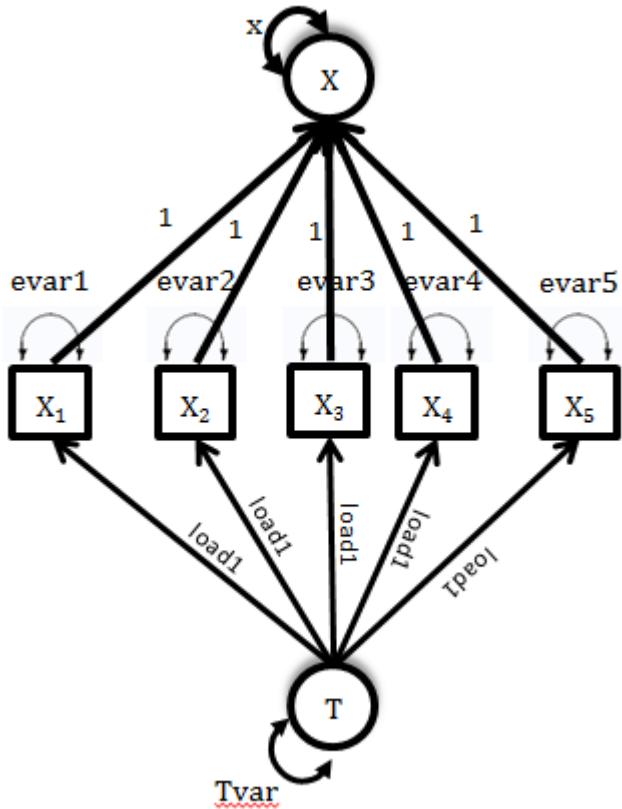
Na spodnjih slikah so prikazani posamezni modeli, kot so implementirani v R-u. T je latentna spremenljivka ali faktor, X_1, X_2, X_3, X_4 in X_5 predstavljajo spremenljivke, ki sestavljajo spremenljivko X . Pri vseh modelih (Slika 7.1, Slika 7.2, Slika 7.3) so torej označeni faktorji, spremenljivke, faktorske uteži in variance napak. Faktor T ima določeno varianco $Tvar$, njeno začetno vrednost pa bo izračunala funkcija `sem` (Fox, Nie in Byrnes 2012; R Core Team 2012b, 35).

Slika 7.1: Kongenerični model



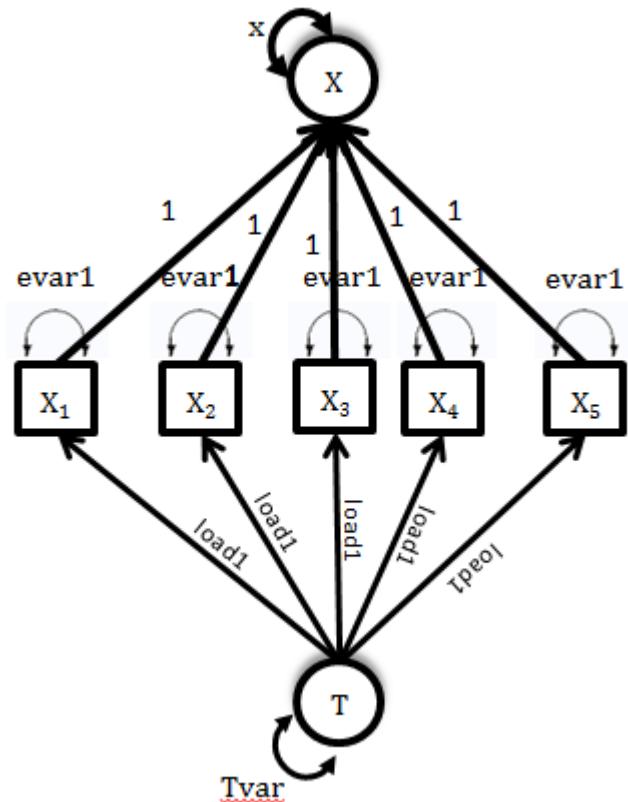
Pri kongeneričnem modelu so predpostavke najmanj zahtevne. Faktorske uteži ($load1$ - $load5$) so lahko različne (pri spremenljivki X_1 je faktorska utež fiksirana na 1), prav tako so lahko med seboj različne variance napak posameznih spremenljivk ($evar1$ - $evar5$).

Slika 7.2: Tau-enakovredni model



Edina razlika med kongeneričnim modelom (prikazanim na Sliki 7.1) in tau-enakovrednim modelom (prikazanim na Sliki 7.2) je v vrednostih med latentno spremenljivko (ali faktorjem) T in indikatorji (X_1, X_2, X_3, X_4 in X_5), ki predstavljajo faktorske uteži in smo jih v simulacijah določili vnaprej, in sicer so imajo vse vrednost 1. Pri variancah napak ($evar1-evar5$), ki so bile določene iz teh uteži, pa pri tau-enakovrednem modelu ni pogoja, da so pri posameznih spremenljivkah enake. Varianca sestavljenih spremenljivk X je fiksirana na 1.

Slika 7.3: Vzporedni model



Vzporedni model (Slika 7.3) se od tau-enakovrednega (Slika 7.2) razlikuje le po vrednostih na indikatorjih (X_1, X_2, X_3, X_4 in X_5). Te vrednosti so variance napak ($evar1$) in so na vseh indikatorjih enake, prav tako pa so enake tudi uteži ($load1$), in sicer so bile nastavljene na vrednost 1; to so vhodni parametri pri simulacijah, ostali parametri pa so izračunane (s sēm paketkom) in nato je podana ocena zanesljivosti. Varianca sestavljene spremenljivke X je tudi tu fiksirana na 1.

Vzporedni model je torej najstrožji model glede na predpostavke, kar se vidi v enakih variancah na posameznih spremenljivkah. Kongenerični model je najbolj splošen model in ne predpostavlja enakosti posameznih parametrov (različne stopnje natančnosti, različne napake, različne variance).

7.2 Opis generiranja podatkov in postopek izračuna

Izračuni so bili v obliki programske kode zapisani in izvedeni s programskim paketom R, ki že od svojega začetka od sredine 90. let 20. stoletja postaja vse bolj priljubljen

program za raznovrstne statistične analize, tako pri statistikih, kot tudi pri drugih strokovnjakih, npr. programerjih. Program je v celoti brezplačno dostopen in deluje pod GNU (»General Public License«) licenco. Gre za odprtokodni program, ki ima na voljo že več kot 700 dodatnih paketkov za specifične analize (Fox 2006, 466). Programski paket R uporablja istoimenski programski jezik R (»nadgradnja« programskega jezika S), ki je namenjen predvsem za statistične analize in grafiko. Deluje na različnih operacijskih sistemih (UNIX, FreeBSD, Linux, Windows in MacOS), vendar se posamezni deli oz. elementi jezika R razlikujejo glede na operacijski sistem, ki ga uporabljamo.

V magistrski nalogi smo uporabili programsko verzijo R 2.15.1 (2012-06-22) »Roasted Marshmallows« in operacijski sistem Windows 7.

V R-u smo uporabili paketke: `sem`, `psych`, `MASS` in `matrixcalc`. Paketek `sem`, avtorja Johna Foxa, vsebuje osnovne zmogljivosti SEM modeliranja (Fox 2006) in je osnovni paketek v magistrski nalogi. Paketek `psych` (avtor William Revelle), se primarno uporablja pri lestvicah faktorske analize, računanju zanesljivosti in drugih opisnih statistik (Revelle 2012). Pri optimizaciji smo si posredno pomagali s paketkom `MASS`. Paketek `matrixcalc` vsebuje celo paletu funkcij za računanje z matrikami (Novomestky 2012). V nalogi smo uporabili že definirane funkcije:

- za izračun Ω koeficietov `myOmega`,
- za optimizacijo smo uporabili funkcijo `objectiveULS` in
- funkcijo `SigmaWhole`, ki je definirana na podlagi funkcije `fcores` in je uporabna v povezavi s SEM modeli in ocenjevanjem zanesljivosti (Žiberna 2012).

Podatke smo nato generirali tako, da smo najprej generirali faktor (delali smo na enofaktorskem modelu) in napake (generirane so bile na podlagi varianc napak), uteži pa smo določili že vnaprej; tako smo dobili spremenljivke x_1, x_2, x_3, x_4 in x_5 , ki so zvezno normalno porazdeljene.

Podatke smo generirali na treh različnih velikostih vzorcev, in sicer na malem ($n = 100$), srednje velikem ($n = 500$) in velikem vzorcu ($n = 1.000$). Za vsako velikost vzorca smo generirali podatke glede na uteži in variance, ki so predstavljeni v Tabeli 7.1. Uporabili

smo enake uteži, in sicer nizke enake uteži (0.3), srednje enake uteži (0.5) in visoke enake uteži (0.8). Testirali smo tudi manj različne (1:3), bolj različne (1:10) in bolj različne uteži (podrobneje opisane v prejšnjem poglavju). V vseh možnih kombinacijah smo uporabili enake variance napak, različne variance napak v razmerju 1:3 (razlika med najmanjšo in največjo vrednostjo v matriki različnih varianc napak je 1:3) in zelo različne variance napak v razmerju 1:10 (razlika med najmanjšo in največjo vrednostjo v matriki zelo rabičnih varianc napak je 1:10) in enake variance napak.

Pravo zanesljivost, ki se nahaja na intervalu [0,1], smo najprej računali na tri načine:

- Kot korelacijo med F in L na kvadrat (Ferligoj in drugi 1995, 15):

$$\rho_{xx} = \text{cor}(F, L)^2.$$

Korelacija kvadrata matrike faktorjev in matrike izmerjenih spremenljivk - povedano drugače, gre za koeficient korelacije med dejansko in izmerjeno spremenljivko oz. za kvadratni koren iz zanesljivosti (Ferligoj in drugi 1995, 14-15).

- Empirična zanesljivost (Ferligoj in drugi 1995, 14):

$$\rho_{xx} = \text{var}(T)/\text{var}(L).$$

To je definicija zanesljivosti iz klasične testne teorije, in sicer je zanesljivost enaka razmerju med varianco dejanske spremenljivke T in varianco izmerjene spremenljivke L (Ferligoj in drugi 1995, 14). Bistveno razlikovanje med enačbama je torej v tem, da gre pri prvi enačbi za korelacijo med dejansko in izmerjeno spremenljivko, pri drugi pa za razmerje med varianco dejanske in varianco izmerjene spremenljivke. Empirična zanesljivost temelji na predpostavki o nekoreliranosti napak in faktorja, pri čemer sta oba omenjena izračuna enaka, ko so faktorji in napake popolnoma nekorelirani. Zaradi slučaja pa se v empiričnah raziskavah lahko zgodi, da so napake negativno korelirane s faktorjem. Ker v našem primeru tega nismo posebej omejevali in so zato nekatere izračunane vrednosti presegale vrednost 1, smo se odločili, da tovrsten izračun izključimo iz nadaljnje analize.

- Teoretična prava zanesljivost:

$$r_{SS} = 1 - \frac{\sum \sigma_i^2 - \sum \eta_i \sigma_i^2}{\sum \sigma_i^2}$$

(v Sočan 2000, 24).

Slednja formula je pravzaprav enaka formuli, ki smo jo uporabili v naši programski kodi (glej Prilog A).

V imenovalcu zgodnjega ulomka je pravzaprav varianca napak, v imenovalcu formule, ki smo jo uporabili mi, pa je skupna varianca sestavljene spremenljivke, saj imam faktor varianco enako 1.

Prva ocena klasične testne teorije se nanaša na predpostavke empiričnega ugotavljanja zanesljivosti, zadnja pa na predpostavke teoretičnega pojma zanesljivosti merjenja (Ferligoj in drugi 1995, 20; Sočan 2000, 24).

Za vsako od 72 možnih kombinacij varianc in faktorskih uteži smo računali:

- Cronbach α koeficient,
- standardiziran Cronbach α koeficient,
- koeficient Ω na kovariančni matriki (osnova za faktorsko analizo je kovariančna matrika),
- koeficient Ω na korelacijski matriki (osnova za faktorsko analizo je korelacijska matrika),
- oceno zanesljivosti za vzporedni model,
- oceno zanesljivosti za tau-enakovredni model,
- oceno zanesljivosti za kongenerični model.

Izračune smo nato preverili, in sicer smo se žeeli prepričati, ali se izračunana vrednost nahaja na intervalu med 0 in 1. V primeru, da je bila ta vrednost neveljavna (torej ni bila na intervalu med 0 in 1), smo postopek ponovili. Sprva so bile nekatere vrednosti neveljavne - takih vrednosti je bilo manj kot 3 %. Nato smo pregledali izračune in ugotovili, da pri tako velikem številu ponovitev simulacij zaradi slučaja pride do tega, da so nekatere variance ocenjene kot negativne, kar je v realnosti nemogoče. Do tega je

prišlo predvsem takrat, ko so bile korelacije med faktorji in napakami znatno negativne. Ker smo preverili vse rezultate takrat, ko so bile vrednosti neveljavne in nismo zaznali napake, smo se odločili, da z zanko odstranimo neveljavne vrednosti.

8 PREDSTAVITEV REZULTATOV IN INTERPRETACIJA

Pravo zanesljivost smo računali na 2 različna načina, ki sta podrobnejše opisana v prejšnjem poglavju. Razlike pri 1.000 ponovitvah glede na oba različna izračuna prave vrednosti so minimalne (glej Prilogo C). Največja povprečna razlika med izračunama prave zanesljivosti je približno 0.04, kar je pravzaprav pri 1.000 ponovitvah zanemarljivo (glej Prilogi C in D). Do največjih razlik med izračunoma prihaja v primeru nizkih faktorskih uteži (v kombinaciji z enakimi skupnimi variancami, z različnimi variancami (1:3 in 1:10) in z enakimi variancami napak). Uteži bolj vplivajo na oceno zanesljivosti kot variance. Do razlik med izračunoma prihaja predvsem zato, ker so naši generirani podatki slučajni, kar pomeni, da variance niso popolnoma enake med seboj, da korelacije med nepovezanimi spremenljivkami ali napakami niso točno enake 0 itd. Manjše kot so uteži, večje so variance napak, če imamo enako skupne variance. Sicer pa nizke uteži pri enakih variancah napak pomenijo, da napake potem pomenijo večji del variabilnosti. Teoretični izračun zanesljivosti upošteva variance napak, empirična zanesljivost pa, kot že rečeno, temelji na predpostavki, da so napake in faktor nekorelirani, zato pri vseh situacijah, kjer imamo nizke enake faktorske uteži, prihaja do razlik med obema izračunoma.

Do minimalnih razlik pri izračunu prave vrednosti je prišlo zaradi različnega načina izračuna, ki sta podrobnejše opisana v prejšnjem poglavju. Razlike pa se glede na velikost vzorca zelo zmanjšajo. Tako so največje razlike (do maksimalno 0.04) pri vzorcu velikosti 100, pri vzorcu velikosti 1.000 pa je največja razlika med izračunoma prave zanesljivosti manjša od 0.01 (glej Prilogo D). Prav tako so razlike med izračunoma prave zanesljivosti pri velikosti vzorca 500 manjše od 0.01. V situacijah enofaktorskega modela (na katerem smo izvedli simulacije), kjer je ocena zanesljivosti manjša od 0.6, bi bilo morda za večjo zanesljivost zanimivo testirati dvofaktorski model. Ker pa je nizka ocena zanesljivosti posledica majhnih uteži glede na variance, to najverjetneje ne bi izboljšalo zanesljivosti. V vseh merskih situacijah je rezultat pri obeh načinih izračuna

prave vrednosti skoraj enak. V nadaljevanju smo uporabljali izraz prava vrednost (empirična prava zanesljivost).

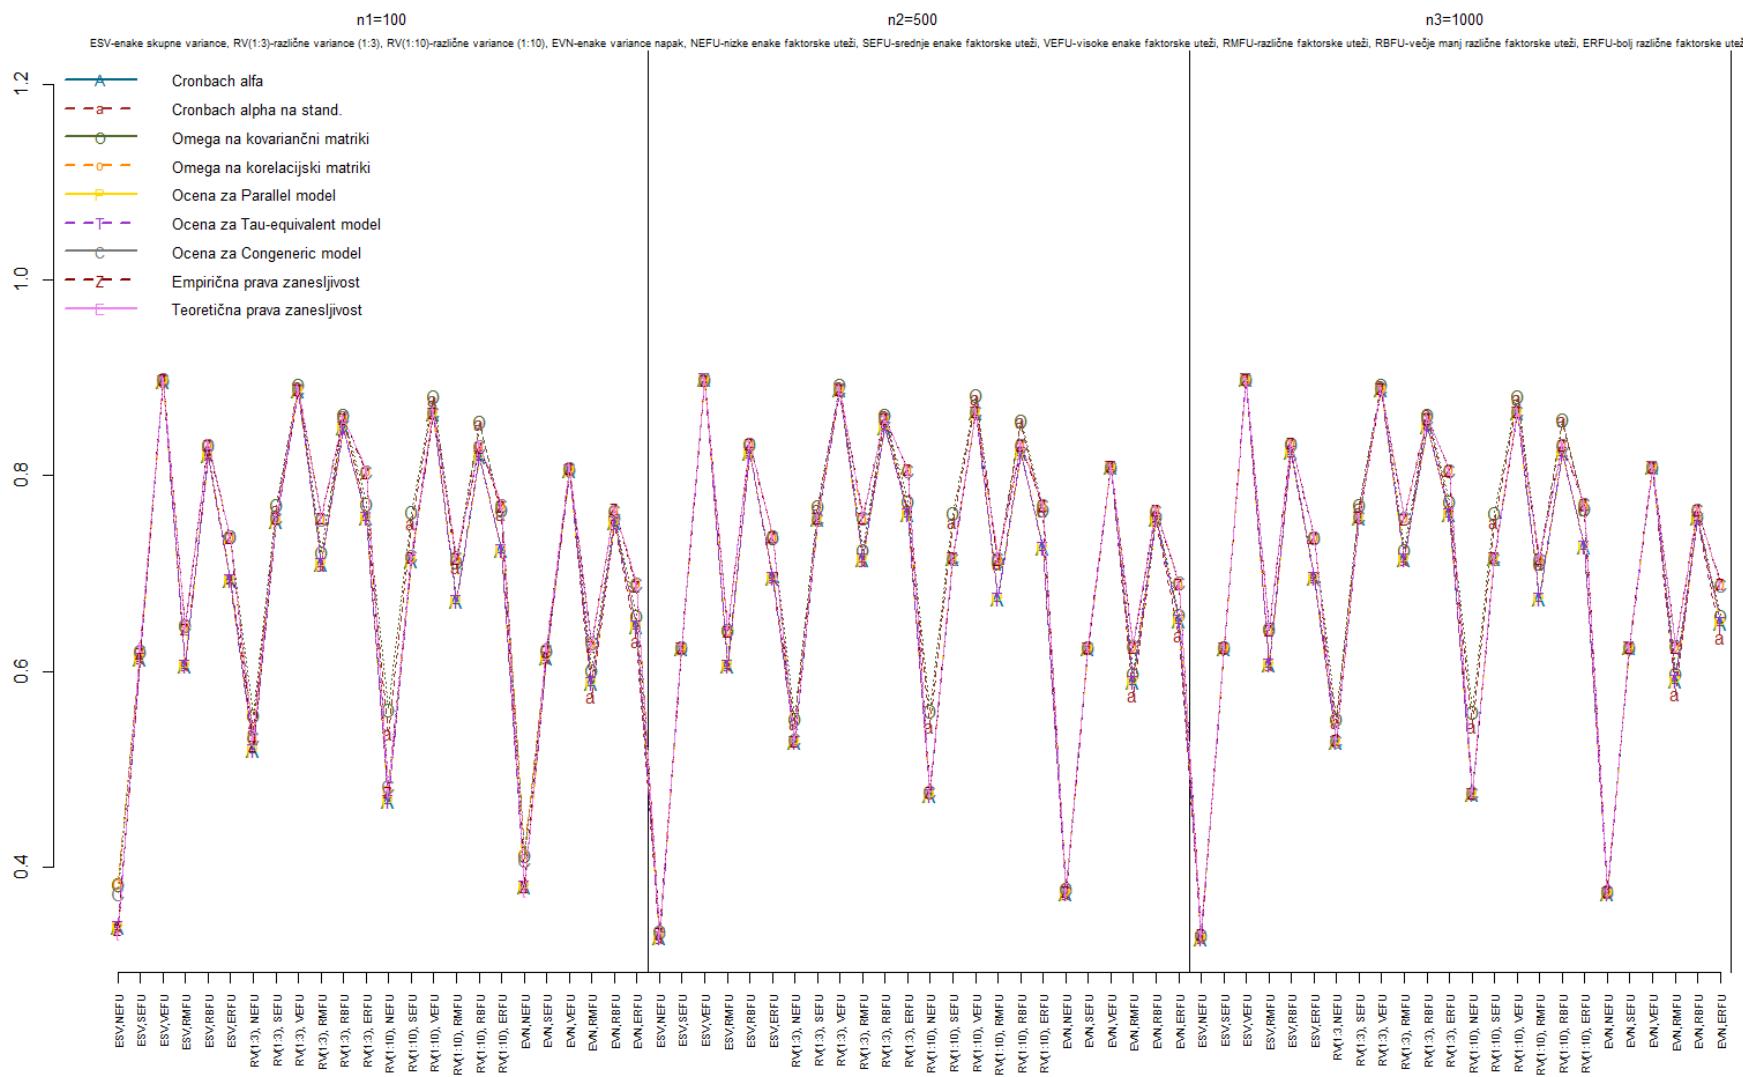
Glede na velikost vzorca so razlike med pravimi vrednostmi v različnih merskih situacijah minimalne oz. povedano drugače, ocene zanesljivosti glede na posamezne merske situacije, so pri vseh treh vzorcih enake. Najvišjo zanesljivost dosežemo, kadar imamo visoke enake faktorske uteži, kjer so enake skupne variance, različne variance (1:3 in 1:10) in enake variance napak (glej Prilogo C). Prava zanesljivost se zmanjša v merski situaciji, kjer imamo nizke enake faktorske uteži in enake skupne variance, različne variance (1:3 in 1:10) in enake variance napak. Razlike v merskih situacijah glede na najvišjo in najnižjo zanesljivost so torej le glede na faktorske uteži. Pri visokih faktorskih utežeh je tudi prava zanesljivost visoka, pri enakih, a nizkih faktorskih utežeh pa prava zanesljivost doseže svoj minimum, saj so pri nizkih utežeh variance napak večje. Velikosti vzorcev (100, 500 in 1.000 enot) pa v tem primeru na vrednosti prave zanesljivosti ne vplivajo. Pri vseh velikostih vzorcev so namreč prave zanesljivosti v istih merskih situacijah najnižje in v istih merskih situacijah najvišje. Najnižja vrednost prave empirične zanesljivosti je 0.083 in najvišja 0.95. Najnižja vrednost teoretične prave zanesljivosti je 0.33 in najvišja 0.899.

Glede na to, da računamo zanesljivost na nestandardiziranih podatkih, je pričakovano, da zanesljivost precej niha (glej Prilogo C). Na zanesljivost torej najbolj vplivajo uteži, vendar je pomembno tudi razmerje med utežmi in variancami. Pri visokih utežeh pričakujemo visoko zanesljivost, saj uteži bolj vplivajo na zanesljivost kot variance. Pri nizkih utežeh pa pričakujemo nižje zanesljivosti ne glede na velikost in/ali enakost varianc, kar je razvidno tudi iz grafa v Prilogi C. Ocena zanesljivosti bo npr. veliko boljša celo v primeru bolj različnih faktorskih uteži ali pa v primeru večjih manj različnih faktorskih uteži (ne glede na druge parametre) kot pa pri nizkih enakih utežeh.

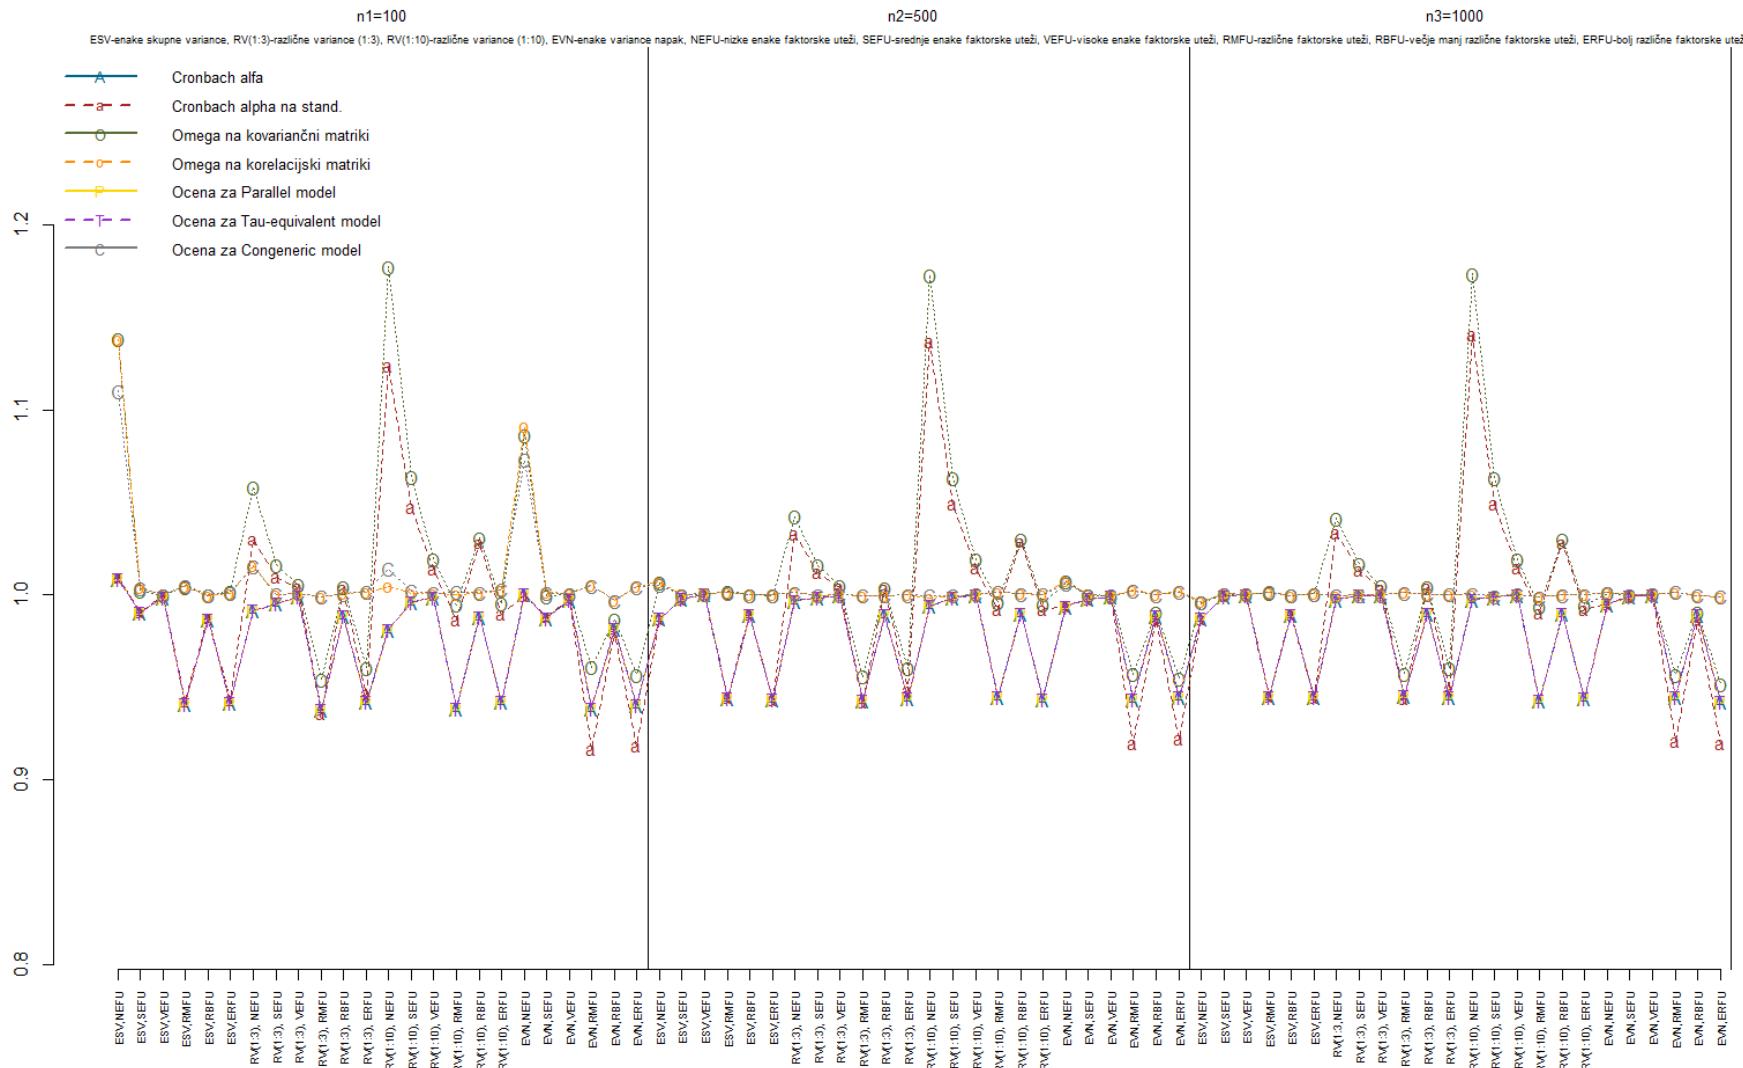
Na Sliki 8.2 so prikazana razmerja med posameznimi koeficienti in ocene zanesljivosti oz. relativna vrednost koeficientov glede na pravo zanesljivost. Relativna vrednost je količnik med dejansko vrednostjo oz. dejansko oceno zanesljivosti posameznega koeficiente in pravo vrednostjo oz. pravo zanesljivostjo, in je morda lažja za primerjavo med posameznimi koeficienti.

Vzorec sprememb pri koeficientih glede na tri velikosti vzorcev je enak kot na sliki za pravo zanesljivost. V določenih situacijah so določeni koeficienti boljši kot drugi, glede na mersko situacijo in tudi glede na velikost vzorca.

Slika 8.1: Povprečne vrednosti koeficientov in ocen zanesljivosti



Slika 8.2: Relativne vrednosti koeficientov glede na pravo vrednost



Na Sliki 8.1 in Sliki 8.2 so prikazane posamezne ocene zanesljivosti, ki so jih podali vsi zajeti koeficienti in merski modeli. Kot smo pričakovali, gre v vseh merskih situacijah koeficientov in ocen zanesljivosti za enake vzorce ocen zanesljivosti glede na velikosti vzorcev. Z drugimi besedami, koeficinetti in ocene zanesljivosti v večini primerov merijo dobro oz. slabo ne glede na velikost vzorca.

Sicer pa je smiselnost najprej za vse situacije opredeliti, s katerim modelom merjenja so skladne. Če imamo v merski situaciji enake variance napak in enake faktorske uteži, je taka situacija skladna z vzporednim modelom, ki to pogojuje in je zato tudi najstrožji model. S tau-enakovrednim modelom so skladne situacije, kjer imamo enake faktorske uteži. Kongenerični model, ki je najbolj splošen, pa se ujema s situacijami, kjer so faktorske uteži različne, dovoljene pa so tudi različne variance napak (Osburn 2000, 345). Glede koeficientov α in Ω gre dodati, da je koeficient α skladen z »essentially« tau-enakovrednim modelom oz. iz njega po definiciji izhaja, saj koeficient α izenači zanesljivost, če gre za popolno »essentially« tau-enakovrednost (Miller 1995, 265), sicer pa je koeficient α skladen tudi s tau-enakovrednim modelom, ki se od »essentially« tau-enakovrednega modela razlikuje le za konstanto, ki pa glede na naše simuliranje podatkov ne vpliva; enako velja za standardiziran koeficient α . Oba koeficiente Ω pa sta bolj splošna oz. manj zahtevna kot koeficient α , saj je ocenjevanje zanesljivosti s koeficientom Ω , ki upošteva različne faktorske uteži, skladno s kongeneričnim modelom.

Če natančneje pogledamo Sliko 8.1, vidimo, da se ocene zanesljivosti nekaterih koeficientov oz. merskih modelov precej prekrivajo. To pomeni, da so pri določenih merskih pogojih vse ocene zanesljivosti dobre ali pa slabe, oz. da koeficienti približno enako dobro ali slabo ocenjujejo zanesljivost. Vendar pa razlike med nekaterimi koeficienti in modeli vseeno obstajajo in so podrobnejše analizirane v nadaljevanju. S Slike 8.1 je tudi razvidno, v katerih merskih pogojih je določen koeficient oz. ocena zanesljivosti dobra in v katerih slaba. Da določen koeficient dobro ocenjuje zanesljivost, morajo biti njegove ocene blizu prave vrednosti. Če ocene koeficiente od prave vrednosti močno odstopajo, ta koeficient ni dober ocenjevalec zanesljivosti v določeni merski situaciji, pri čemer je vrednost koeficiente, ki presega pravo vrednost, večji problem, saj lahko raziskovalca zavede in kaže na bolj zanesljive ali celo zelo zanesljive rezultate, kot

v resnici so. Če pa je vrednost koeficienta manjša od prave vrednosti, lahko rečemo, da koeficient slabo oceni zanesljivost.

Tudi iz Slike 8.2 lahko razberemo, da se v mnogih primerih oz. situacijah določene točke prekrivajo, kar pomeni, da so ocene zanesljivosti določenih koeficientov ali modelov med seboj skoraj enake ali pa zelo blizu. V prav vseh merskih situacijah se prekrivajo točke Cronbach α koeficiente in tau-enakovrednega ter vzporednega modela, kar pomeni, da so ti koeficienti v vseh situacijah podali enake ocene zanesljivosti in so torej občutljivi na enake vhodne parametre naših simulacij oz. na kršenje enakih predpostavk. Prav tako se skoraj povsod prekrivajo ocene kongeneričnega modela in koeficiente Ω na korelacijski matriki, ki je, kot že rečeno, skladen s kongeneričnim modelom. Oceni zanesljivosti koeficiente Ω na korelacijski matriki in kongeneričnega modela se malce razlikujeta (za manj kot 0.05 v absolutnih vrednosti) pri vzorcu velikosti 100 enot v primeru nizkih enakih uteži v kombinaciji z enakimi skupnimi variancami in z enakimi variancami napak, kjer je ocena koeficiente Ω nekoliko višja od ocene kongeneričnega modela. Ocena kongeneričnega modela pa je nekoliko višja le v primeru nizkih enakih uteži in različnih varianc (pri razlikah varianc v razmerju 1:3). Razlike med ocenama zanesljivosti teh dveh koeficientov pa so značilne le za najmanjši od treh vzorcev, pri večjih vzorcih ocene očitno bolj skonvergirajo in so med seboj enake.

Vpliv enakih uteži na dobro oceno zanesljivosti (ne glede na način ocenjevanja oz. koeficient) lahko pojasnimo s tem, da so v primeru enakih uteži izpolnjene predpostavke tau-enakovrednega modela, zato v teh primerih zanesljivost dobro ocenjujejo tudi koeficienti, ki niso skladni s kongeneričnim modelom, ki ne zahteva enakih uteži. S tau-enakovrednim modelom je skladen koeficient α . Pri enakih faktorskih utežeh bomo torej s koeficientom α in s tau-enakovrednim modelom vedno dobili dobre ocene zanesljivosti, kar je vidno tudi na Sliki 8.1, kjer se točke teh dveh ocenjevalcev zanesljivosti v vsaki situaciji prekrivajo s točkami obeh pravih zanesljivosti. Kot smo videli že pri pravi zanesljivosti, je le-ta večja, če so uteži visoke, kar pomeni, da jih faktor dobro opisuje.

Če najprej natančneje pogledamo Sliko 8.2, lahko vidimo, da najbolj izstopata standardiziran koeficient α in Ω na kovariančni matriki. Najbolj izstopata v primerih,

kadar imamo nizke enake faktorske uteži in enake skupne variance, nizke enake faktorske uteži in različne variance (1:10) ter nizke enake faktorske uteži in enake variance napak; v teh merskih situacijah presegata realno mejo ocene zanesljivosti, ki je enaka 1. Pri naštetih primerih omenjena koeficienta v primerjavi z ostalimi situacijami in koeficienti izstopata, vendar pa razlike niso ekstremno velike, kar bi sicer lahko zaključili glede na Sliko 8.2, saj ta dva koeficiente dosegata precej višje relativne vrednosti, vendar pa na Sliki 8.1 vidimo, da razlike glede na pravo vrednost niso tako ekstremno večje (za slabih 0.2). Pri nizkih enakih faktorskih utežeh ter različnih variancah (1:10) standardiziran koeficient α relativno glede na pravo vrednost precej presega mejo 1, kar lahko pojasnimo s tem, da imajo standardizirane spremenljivke enako težko pri sestavljeni spremenljivki, pri nestandardiziranih spremenljivkah pa imajo večjo težo pri sestavljeni spremenljivki tiste z večjo napako.

Koeficient Ω na kovariančni matriki, ki zanesljivost ocenjuje na matriki, ki ima na diagonali komunalitete, ki »predstavljajo delež variance, ki jo lahko pojasnimo s skupnimi faktorji« (Košmelj in drugi 2001, 58), dosega visoke vrednosti (relativno glede na pravo vrednost) pri nizkih enakih faktorskih utežeh in različnih variancah ter enakih variancah napak zato, ker pri manjših utežeh na napake pade večji del variabilnosti. Ta koeficient pa je skladen s kongeneričnim modelom, ki ne postavlja nobenih zahtev o enakosti uteži in/ali napak. V primerih, kjer je ta koeficient Ω večji od prave zanesljivosti, je problem lahko tudi v tem, da smo merili zanesljivost tako, kot da bi bila prava vrednost sestavljene spremenljivke ena izmed napak spremenljivke, napake pa prispevajo največ variabilnosti. Glede na to, da sta koeficient α in koeficient Ω spodnji meji zanesljivosti, kot pravita Greene in Carmines (1980, 169), bi pričakovali, da ta dva koeficiente ne bosta nikoli dosegala večjih vrednosti od prave zanesljivosti.

Glede na različne velikosti vzorcev se pri vzorcih velikosti 500 in 1.000 enot in nizkih enakih faktorskih utežeh ter enakih skupnih variancah standardiziran koeficient α in Ω na kovariančni matriki približata vrednosti prave zanesljivosti. To pomeni, da sta z večanjem vzorca standardiziran koeficient α in Ω na kovariančni matriki boljša.

V določenih merskih situacijah koeficienti Cronbach α , standardiziran Cronbach α ter oceni zanesljivosti tau-enakovrednega in vzporednega modela nekoliko podcenjujejo

pravo zanesljivost oz. dosegajo nižje vrednosti od prave zanesljivosti. Načeloma je ocena zanesljivosti omenjenih koeficientov oz. modelov nižja od prave vrednosti v situacijah, kjer so uteži različne ne glede na velikost vzorca. Če so uteži različne, ne glede na to, kako različne so, na omenjene koeficiente oz. modele vpliva enakost varianc oz. enakost varianc napak. Cronbach α , standardiziran Cronbach α ter oceni zanesljivosti tau-enakovrednega in vzporednega modela, ne glede na velikost vzorca, dosegajo nižje vrednosti v situacijah, kjer so različne (ali bolj različne) faktorske uteži ne glede na variance napak. Ta odstopanja ocen oz. koeficientov od prave zanesljivosti so manjša od 0.1. Podcenjevanje zanesljivosti načeloma ni problematično, kot je npr. precenjevanje zanesljivosti, saj slednje v realnosti pomeni, da se neka lestvica kaže za bolj stabilen merski instrument, kot v resnici je, saj indikatorji znotraj lestvice niso tako dobro usklajeni, kot bi lahko sklepali glede na oceno zanesljivosti. Glede na zgoraj opisana podcenjevanja gre torej za podcenjevanje le v primerih, ko so faktorske uteži različne ali zelo različne, kar pomeni, da gre za najbolj splošen kongenerični model, ki dovoljuje različne faktorske uteži.

Zaključimo lahko, da omenjena koeficiente in merska modela podcenjujejo zanesljivost, kadarkoli imamo različne faktorske uteži ne glede na velikost vzorca, saj sta oba koeficiente α skladna s tau-enakovrednim modelom (pogoj so enake uteži), vzporedni model pa zahteva še enake variance napak.

Da so rezultati tau-enakovrednega modela skoraj povsem enaki ocenam Cronbach α koeficiente, je povsem pričakovano in razumljivo, saj koeficient α izhaja iz tau-enakovrednega modela. Nekoliko presenetljivo pa je, da so rezultati vzporednega modela skoraj enaki rezultatom tau-enakovrednega modela, saj vzporedni model velja za bolj strogega in poleg enakih faktorskih uteži predpostavlja tudi enake variance napak. Pričakovali bi torej slabše ocene zanesljivosti vzporednega modela pri različnih variancah napak, saj je kršena ena izmed predpostavk tega modela. Zanimivo pa je še, da omenjena modela v situacijah, ko imamo različne faktorske uteži, podata boljšo oceno zanesljivosti v primeru bolj raličnih faktorskih uteži, pri manj različnih ter ekstremno različnih utežeh pa je ocena nekoliko slabša oz. bolj odmaknjena od prave vrednosti.

Pričakovano je tudi, da so ocene kongeneričnega modela skoraj povsem enake pravi vrednosti (in se minimalno razlikujejo), saj je to najbolj splošen model z najmanj strogimi predpostavkami (uteži in variance napak so lahko različne). Prav tako tudi koeficient Ω na korelacijski matriki v ocenah popolnoma sledi pravi zanesljivosti in tudi kongeneričnemu modelu, kar smo tudi pričakovali, saj je koeficient Ω skladen s tem modelom. Koeficient Ω na korelacijski matriki v nobeni situaciji zanesljivosti ne oceni veliko slabše (v smislu, da njegove ocene v nobeni situaciji niso zelo oddaljene od prave vrednosti, nekje pa vrednosti tega koeficiente Ω presegajo pravo vrednost (pri nizkih enakih faktorskih utežeh in enaki skupni varianci ter pri nizkih enakih utežeh in enaki varianci napak), kar je velika pomanjkljivost. To pomeni, da koeficient Ω na korelacijski matriki v teh dveh primerih poda višjo oceno zanesljivosti, kot je v resnici, zato ga pri takih realnih situacijah raje ne bi izbrali za ocenjevanje zanesljivosti, saj bi se rezultati kazali za bolj zanesljive, kot v resnici so. Enaka situacija je tudi pri oceni kongeneričnega modela, ki prav tako preceni pravo zanesljivost v istih situacijah, vendar pa so ta izstopanja nekoliko manjša. To je sicer pri ocenjevanju zanesljivosti lahko zavajajoče, saj lahko zanesljivost bolje ocenimo kot v resnici je, vendar pa so te razlike dokaj majhne, saj so manjše od 0.15. To pa se z večanjem vzorca tako pri koeficientu Ω na korelacijski matriki kot tudi oceni pri kongeneričnem modelu na vzorcih s 500 in 1.000 enotami izniči. To pomeni, da pri manjših vzorcih (npr. 100 enot) koeficient Ω na korelacijski matriki in ocena zanesljivosti s kongeneričnim modelom lahko precenita zanesljivost, pri večjih vzorcih (nor. 500 ali 1.000 enot) pa zanesljivost dobro ocenjujeta. Zelo dobre ocene kongeneričnega modela in koeficiente Ω na korelacijski matriki si lahko razlagamo s tem, da Ω upošteva različne uteži na faktorju, zato poda v situacijah, kjer so uteži različne, boljšo oceno kot Cronbach α .

Cronbach α izenači pravo zanesljivost, če so faktorske uteži na skupnem faktorju enake (Miller 1995, 265). To trditev lahko potrdimo, saj je α skoraj enaka pravi zanesljivosti, kjer so uteži enake. Nižja je tako Cronbach α , kot tudi standarizirana Cronbach α v primerih, kjer imamo manj različne faktorske uteži in bolj različne faktorske uteži ter enake skupne variance, različne variance (1:3 in 1:10) in enake variance napak. Te vrednosti sicer izstopajo, vendar pa so razlike med koeficientoma in pravo zanesljivostjo manjše od 0.1. Nekoliko bolj vidne razlike med Cronbach α in Cronbach α na

standardiziranih podatkih se pojavijo v situaciji nizkih enakih faktorskih uteži v kombinaciji z različnimi variancami (tako pri razmerju 1:3 kot tudi pri 1:10) in v situaciji bolj različnih faktorskih uteži, kar je posledica standardiziranih vrednosti. Iz literature (Shevlin in drugi 2000) je znano, da na vrednost koeficienta α poleg števila indikatorjev v merski lestvici vpliva tudi velikost vzorca (večanje vzorca naj bi večalo vrednosti α , saj naj bi vrednosti bolj skonvergirale). V našem primeru tega ne moremo trditi, saj se vrednost α pri 1.000 ponovitvah in treh različno velikih vzorcih (100, 500 in 1.000 enot) obnaša enako ne glede na velikost vzorca.

Če primerjamo ocene koeficientov α (Cronbach α in Cronbach α na standardiziranih vrednostih) in Ω na korelacijski matriki (velikokrat tudi na kovariančni matriki), lahko potrdimo, da Ω na korelacijski matriki bolje oceni zanesljivost oz. da je Ω na korelacijski matriki v vseh primerih na velikih vzorcih (s 500 in 1.000 enotami) bližje pravi zanesljivosti, saj so predpostavke za dobro ocenjevanje zanesljivosti tega koeficienta bolj splošne, predpostavke tau-enakovrednega modela in s tem tudi predpostavke koeficienta α pa so kršene pri različnih faktorskih utežeh, zato je ocena zanesljivosti slabša, vrednost pa bolj odmaknjena od prave zanesljivosti.

Iz ugotovitev sledi, da je ne glede na velikost vzorca, ki je večji od 100 enot, v raziskovanju za ocenjevanje zanesljivosti merjenja najbolje uporabiti koeficient Ω na korelacijski matriki ali ocene zanesljivosti po kongeneričnem modelu, saj se je izkazalo, da sta ti dve oceni najbližje pravi vrednosti. V primeru, kadar so uteži enake, lahko uporabimo tudi koeficient α ali oceni zanesljivosti po vzporednem in tau-enakovrednem modelu. Velja načelo, da sledimo prileganju modelom od najbolj splošnega do najstrožjega. Če so razlike med dvema modeloma oz. med dvema ocenama zanesljivosti velike, vzamemo oceno bolj splošnega od modelov oz. oceno, ki jo poda koeficient z manj strogimi predpostavkami.

Koeficient Ω na kovariančni matriki in standardizirani koeficient α pa bosta precenila zanesljivost oz. podala boljšo oceno zanesljivosti, kot je v resnici, to pa je praktično zavajajoča in nepravilna ocena zanesljivosti. Ker pa te razlike niso pretirano velike, saj je največje odstopanje od prave vrednosti relativno do vrednosti 0.05, bi načeloma tudi ta dva koeficiente lahko uporabili v primeru, da upoštevamo možnost predobrre ocene. Ker

pa se ta precenitev zanesljivosti ne zmanjša niti z večanjem vzorca, je za ocenjevanje zanesljivosti bolj priporočljivo uporabiti koeficient Ω na kovariančni matriki oz. oceno zanesljivosti s kongeneričnim modelom.

Na koncu lahko sklenemo, da nekateri koeficienti in modeli res sovpadajo, kar sledi že iz teorije. Najbolj splošne predpostavke ima koeficient Ω na kovariančni matriki, ki je v skladu s kongeneričnim modelom. Koeficient α je v skladu s tau-enakovrednim modelom. Prav tako pa je hkrati v skladu tudi z vzporednim modelom ocenjevanja zanesljivosti. Tudi standardiziran koeficient α je skladen s tau-enakovrednim modelom in vzporednim modelom, vendar se v nekaterih točkah njihove ocene ne ujemajo, kar je posledica standardiziranja podatkov pri tem koeficientu α . Na tem mestu pa se poraja vprašanje, ali sta standardiziran koeficient α in koeficient Ω na korelacijski matriki sploh primerljiva z ostalimi koeficienti in ocenami zanesljivosti. Za primerljivost morajo biti vse ocene izračunane na istih podatkih, vendar so ti podatki v primeru standardiziranega koeficiente α pred računanjem ocene zanesljivosti standardizirani, kar za primerjavo ni optimalno. Enak problem in pomisliki veljajo tudi za koeficient Ω na korelacijski matriki.

9 ZAKLJUČEK

Rezultati merjenja v družboslovju morajo biti zanesljivi, kar pomeni, da pri večkratkem merjenju dobimo približno enake rezultate. Kot je v družboslovnju pogost pojav, so nekatere lestvice, ki so se že večkrat izkazale za zanesljive, velikokrat uporabljene. Obstaja torej veliko preverjenih merskih instrumentov, ki naj bi ob vsaki uporabi podali zanesljive rezultate in zato veljajo za stabilne merske instrumente. Ravno zato se raziskovalci pogosto odločijo za uporabo takih merskih lestvic, saj naj bi tako bolj zaupali v pravilnost rezultatov, ki naj bi zelo dobro odražali realno stanje merjenega koncepta.

Obstajajo več načinov ocenjevanja zanesljivosti merjenja, raziskovalci pa najpogosteje uporabijo Cronbach α koeficient; drugih koeficientov in metod za ocenjevanje zanesljivosti, ki bi bile morda v določeni situaciji bolj primerne, pa ne preverijo. Cilj magistrske naloge je primerjati in raziskati različne načine ocenjevanja zanesljivosti pri različnih merskih pogojih oz. situacijah. Zanesljivost smo ocenjevali s koeficienti Cronbach α , standardiziranim Cronbach α , koeficientom Ω na kovariančni in na korelacijski matriki ter s tremi SEM modeli za ocenjevanje zanesljivosti (vzporedni, tau-enakovredni in kongenerični model). Preverjanje in ocenjevanje je bilo izvedeno z Monte Carlo simulacijami v programu R; s tem smo lahko nadzirali in določali vhodne parametre oz. merske pogoje, hkrati pa smo v vsakem koraku poznali pravo populacijsko vrednost, kar je velika prednost v raziskovanju. Te vrednosti v realnem raziskovanju ponavadi ne poznamo, zato lahko zanesljivost merjenja le ocenimo. Kadar pa imamo »merilec« zanesljivosti, ki je v večini primerov dober, lahko lažje ocenimo realno zanesljivost, naša ocena zanesljivosti pa bo blizu pravi vrednosti. S simulacijami smo generirali tudi podatke, in sicer normalno porazdeljene zvezne spremenljivke, postopek generiranja podatkov in računanja ocen pa je bil ponovljen 1.000-krat. Zanesljivost smo najprej računali na tri različne načine, ker pa se zaradi slučaja v empiričnih raziskavah lahko zgodi, da so napake negativno korelirane s faktorjem, v našem primeru pa tega nismo posebej omejevali, smo se odločili, da bomo upoštevali le dva načina izračuna. Vrednosti prave zanesljivosti in teoretične zanesljivosti so povsod skoraj enake, zato so se postopki v nadaljevanju nanašali le na en način izračuna, in sicer gre za empirično zanesljivost po formuli $\rho_{xx} = \text{cor}(F, L)^2$.

Nekatere ključne ugotovitve so bile pričakovane. Koeficient Ω na korelacijski matriki je podal boljšo oceno zanesljivosti kot koeficient α (tudi kot standardiziran koeficient α) prav v vseh situacijah, kjer je bila velikost vzorca 500 in 1.000 enot. Povedano drugače: vrednosti koeficiente Ω so bile v vseh situacijah bližje pravi vrednosti kot vrednosti koeficiente α . Pri manjših vzorcih (100 enot) pa je ta koeficient Ω v nekaterih situacijah podal višjo oceno od prave vrednosti, kar pomeni, da zanesljivost precenil. To pa pomeni, da lahko koeficient Ω na korelacijski matriki pri majhnih vzorcih zavaja z višjo oceno zanesljivosti. Zelo podobne ali skoraj enake ocene zanesljivosti kot koeficient Ω na korelacijski matriki je podal kongenerični model, saj ima najmanj omejitev oz. zahtev glede na druge SEM modele (tudi sicer je koeficient Ω skladen s kongeneričnim modelom). V nasprotju s pričakovanji pa je vzporedni model podal enake ali približno enake ocene zanesljivosti kot tau-enakovredni model, čeprav so predpostavke vzporednega modela bolj stroge, saj zahteva enake faktorske uteži in enake variance napak. Koeficient α se v nekaterih primerih ni izkazal za zelo dobrega ocenjevalca zanesljivosti, kot bi morda sklepali iz njegove množične uporabe. Ocene koeficiente α so izredno podobne ocenam vzporednega in tau-enakovrednega modela – ocene sledijo istemu trendu (in se v redkih točkah razlikujejo) in bolj nihajo v primerjavi s koeficientom Ω .

Faktorske uteži, ki smo jih v modeliranju določili že vnaprej, bolj vplivajo na oceno zanesljivosti kot variance in variance napak. Če so uteži enake, so enake tudi variance napak, pri neenakih visokih utežeh pa so variance napak manjše, in obratno. V realnih situacijah se torej izhaja iz teh predpostavk in se glede na te odločamo, kako bomo ocenjevali zanesljivost na konkretnem primeru.

Metoda simulacij omogoča vključitev velikega števila parametrov in izračun mnogih koeficientov, statistik, cenilk in prileganja določenemu modelu. Simulacije, ki smo jih izvedli, bi lahko razširili z vključitvijo še kakšnega modela, upoštevali bi lahko enakosti ali različnosti aditivnih in multiplikativnih konstant v tau-enakovrednih SEM modelih, simulirali bi lahko tudi na manjših vzorcih (npr. 50 enot), vključili bi lahko več faktorjev in računali na standardiziranih podatkih. Prav tako bi merjenje pri različnih natančnostih in izhajali bi lahko iz različnih tipov spremenljivk, npr. iz 5-stopenjske

lestvice, kar bi pomenilo razširitev tega osnovnega modela simulacij, ki je bil izveden za potrebe magistrske naloge.

Simulacije torej dopuščajo in omogočajo skoraj neskončne možnosti za raziskovanje. V tej nalogi pa smo se osredotočili le na nekatere vidike raziskovanja ocenjevanja zanesljivosti, ki so se nam zdeli najbolj temeljni in zanimivi.

10 LITERATURA

- Armor, David J. 1974. Theta Reliability and Factor Scaling. *Sociological Methodology* 5: 17-50. Dostopno prek: <http://www.jstor.org/stable/270831> (31. julij 2012).
- Bentler, Peter M. in Ke-Hai Yuan. 1999. Structural Equation Modeling with Small Samples: Test Statistics. *Multivariate Behavioral Research* 34 (2): 181-197. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=568e03c5-6aaf-4d50-a2de-876702c501ae%40sessionmgr113&vid=2&hid=127> (22. julij 2012).
- Bonett, Douglas D. 2002. Sample Size Requirements for Testing and Estimating Coefficient Alpha. *Journal of Educational and Behavioral Statistics* 27 (4): 335-340. Dostopno prek: <http://www.jstor.org.nukweb.nuk.uni-lj.si/stable/pdfplus/3648121.pdf?acceptTC=true> (11. julij 2011).
- Carmines, Edward G. in Richard A. Zeller. 1979. *Reliability and Validity Assessment*. London: Sage Publications.
- Cortina, Jose M. 1993. What IS Coefficient Alpha? An Examination of Theory and Applications. *Journal of Applied Psychology* 78 (1): 98-104. Dostopno prek: http://ovidsp.tx.ovid.com/sp-3.6.0b/ovidweb.cgi?WebLinkFrameset=1&S=KHIGFPLGJLDDHMNLNCPKHCLBJOGMAA00&returnUrl=ovidweb.cgi%3f%26Full%2bText%3dL%257cS.sh.18.19%257c0%257c00004565-199302000-00010%26S%3dKHIGFPLGJLDDHMNLNCPKHCLBJOGMAA00&directlink=http%3a%2f%2fgraphics.tx.ovid.com%2fovftpdfs%2fFPDDNCLBHCNLJL00%2ffs047%2fovft%2flive%2fgv024%2f00004565%2f00004565-199302000-00010.pdf&filename=What+Is+Coefficient+Alpha%3f%3a+An+Examination+of+Theory+and+Applications.&pdf_key=FPDDNCLBHCNLJL00&pdf_index=/fs047/o/vft/live/gv024/00004565/00004565-199302000-00010 (5. avgust 2011).
- Cronbach, Lee J. in Richard J. Shavelson. 2004. My Current Thoughts on Coefficient Alpha and Successor Procedures. *Educational and Psychological Measurement* 64 (3): 391-418. Dostopno prek: <http://epm.sagepub.com/content/64/3/391> (21. julij 2011).
- De Vaus, D.A. 2004. Surveys in social research. London; New York: Routledge.
- Duhachek, Adam in Dawn Iacobucci. 2004. Alpha's Standard Error (ASE): An Accurate and Precise Confidence Interval Estimate. *Journal of Applied Psychology* 89 (5): 792-808. Dostopno prek: <http://ehis.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=568e03c5-6aaf-4d50-a2de-876702c501ae%40sessionmgr113&vid=2&hid=127>

lj.si/eds/pdfviewer/pdfviewer?sid=de13ffe5-a979-4283-bc50-a3f03e836f55%40sessionmgr115&vid=2&hid=109 (31. julij 2012).

- Ferligoj, Anuška, Karmen Leskovšek in Tina Kogovšek. 1995. *Zanesljivost in veljavnost merjenja*. Ljubljana: Fakulteta za družbene vede.
- Fox, John. 2006. Structural Equation Modeling With the sem Package in R. *Structural equation modeling* 13 (3): 465-486. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=abfd9fd2-b228-4e8d-b0df-443d16e82ef8%40sessionmgr104&vid=2&hid=108> (4. julij 2012).
- Fox, John. 2012. *Package »polycor«*. Dostopno prek: <http://cran.r-project.org/web/packages/polycor/polycor.pdf> (18. avgust 2012).
- Fox, John, Zhenghua Nie in Jarrett Byrnes. 2012. *Package »sem«*. Dostopno prek: <http://cran.r-project.org/web/packages/sem/index.html> (5. september 2010).
- Graham, James M. 2006. Congeneric and (Essentially) Tau-Equivalent Estimates of Score Reliability: What They Are and How to Use Them. *Educational and Psychological Measurement* 66 (6): 930-944. Dostopno prek: <http://epm.sagepub.com/content/66/6/930> (5. julij 2012).
- Greene, Vernon L. in Edward G. Carmines. 1980. Assessing the Reliability of Linear Composites. *Sociological Methodology* 11: 160-175. Dostopno prek: <http://www.jstor.org/pss/270862> (6. julij 2012).
- Hafner Fink, Mitja. 2004. Odnos javnosti do znanosti in tehnologije: kakovost merjenja tega odnosa v okviru javnomnenjske ankete (primer raziskave Slovensko javno mnenje). *Družboslovne razprave* 20 (46-47): 61-80. Dostopno prek: <http://dk.fdv.uni-lj.si/dr/dr46-47Hafner-Fink.PDF> (6. julij 2012).
- Kaplan, David. 2000. *Structural Equation Modeling: Foundations and Extensions*. Thousand Oaks, London, New Delhi: Sage Publications.
- Kline, Rex B. 1998. *Principles and Practice of Structural Equation Modeling*. New York: A Division of Guilford Publications.
- Kogovšek, Tina. 2005. Zanesljivost in veljavnost v kvalitativnem in kvantitativnem raziskovanju. *Teorija in praksa* 42 (1): 256-278. Dostopno prek: http://dk.fdv.uni-lj.si/db/pdfs/tip20051_Kogovsek.pdf (5. julij 2012).
- Košmelj, Blaženka, Franc Arh, Alojzija Doberšek Urbanc, Anuška Ferligoj in Matjaž Omladič. 2001. *Statistični terminološki slovar*. Ljubljana: Statistično društvo Slovenije: Statistični urad Republike Slovenije.

- Leontitsis, Alexandros in Jenny Pagge. 2007. A simulation approach on Cronbach's alpha statistical significance. *Mathematics and Computers in Simulation* 73 (5): 336-340. Dostopno prek: <http://www.sciencedirect.com.nukweb.nuk.uni-lj.si/science/article/pii/S0378475406002059> (15. avgust 2012).
- Lissitz, Robert W. in Samuel B. Green. 1975. Effect of the Number of Scale Points on Reliability: A Monte Carlo Approach. *Journal of Applied Psychology* 60 (1): 10-13. Dostopno prek: http://ovidsp.uk.ovid.com.nukweb.nuk.uni-lj.si/sp-3.4.2a/ovidweb.cgi?WebLinkFrameset=1&S=NMGDPDDCDDHFDKGIFNBLEHBGLIGNAA00&returnUrl=ovidweb.cgi%3fMain%2bSearch%2bPage%3d1%26S%3dNMGDPDDCDDHFDKGIFNBLEHBGLIGNAA00&directlink=http%3a%2f%2fgraphics.uk.ovid.com%2fovftpdbs%2fPDHFFNBGEHGIDD00%2ffs046%2fovft%2flive%2fgv023%2f00004565%2f00004565-197502000-00002.pdf&filename=Effect+of+the+number+of+scale+points+on+reliability%3a+A+Monte+Carlo+approach.&navigation_links=NavLinks.S.sh.15.1&link_from=S.sh.15%7c1&pdf_key=PDHFFNBGEHGIDD00&pdf_index=/fs046/ovft/live/gv023/00004565/00004565-197502000-00002&link_set=S.sh.15|1|sl_10|resultSet|S.sh.15.16|0 (15. julij 2012).
- Lucke, Joseph F. 2005. The α and the ω of Congeneric Test Theory: An Extension of Reliability and Internal Consistency to Heterogeneous Tests. *Applied Psychological Measurement* 29 (1): 65-81. Dostopno prek: <http://apm.sagepub.com/content/29/1/65> (10. julij 2012).
- Miller, Michael B. 1995. Coefficient alpha: A basic introduction from the perspectives of classical test theory and structural equation modeling. *Structural Equation Modeling* 2 (3): 255-273. Dostopno prek: http://mres.gmu.edu/readings/PSYC557/Miller_coefficient_alpha.pdf (6. julij 2012).
- Neuman, William Lawrence. 2011. *Social Research Methods: Qualitative and Quantitative Approaches*. Boston: Allyn and Bacon.
- Novomestky, Frederick. 2012. Package »matrixcalc«. Dostopno prek: <http://cran.r-project.org/web/packages/matrixcalc/matrixcalc.pdf> (18. avgust 2012).
- Osburn, H.G. 2000. Coefficient Alpha and Related Internal Consistency Reliability Coefficients. *Psychological Methods* 5 (3): 343-355. Dostopno prek: <http://ovidsp.uk.ovid.com.nukweb.nuk.uni-lj.si/sp-3.4.2a/ovidweb.cgi?WebLinkFrameset=1&S=KEBLPDKPGFHBKCDFNBLNGAGMJDCAA00&returnUrl=ovidweb.cgi%3f%26Full%2bText%3dL%257cS.sh.15.16%>

257c0%257c00060744-200009000-00003%26S%3dKEBLPDKPGFHFBKDFNLNGAGMJDCAA00&directlink=http%3a%2f%2fgraphics.uk.ovid.com%2fovftpdfs%2fPDHFFNAGNGCDGF00%2ffs047%2fovft%2flive%2fgv024%2f00060744%2f00060744-200009000-00003.pdf&filename=Coefficient+Alpha+and+Related+Internal+Consistency+Reliability+Coefficients.&pdf_key=PDHFFNAGNGCDGF00&pdf_index=/fs047/ovft/live/gv024/00060744/00060744-200009000-00003 (1. julij 2012).

- Paxton, Pamela, Patrick J. Curran, Kenneth A. Bollen, Jim Kirby in Feinian Chen. 2001. Monte Carlo Experiments: Design and Implementation. *Structural Equation Modeling* 8 (2): 287-312. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=3a188b08-135a-4a3e-8403-55dc2efca51f%40sessionmgr115&vid=2&hid=106> (4. julij 2012).
- Peterson, Robert A. 1994. A Meta-Analysis of Cronbach's Coefficient Alpha. *The Journal of Consumer Research* 21 (2): 381-391. Dostopno prek: <http://jstor.org/stable/248928> (5. julij 2012).
- Podgornik, Rok, Marijan Zafred in Anja Pajtler. 2004. A Study of k-means Method where Starting Conditions are Changed: A Simulation Study. *Metodološki zvezki* 1 (1): 75-97. Dostopno prek: <http://mrvar.fdv.uni-lj.si/pub/mz/mz1.1/podgor.pdf> (6. julij 2012).
- R Core Team. 2012. *Package »foreign«*. Dostopno prek: <http://cran.r-project.org/web/packages/foreign/foreign.pdf> (18. avgust 2012).
- Raykov, Tenko. 1997. Scale Reliability, Cronbach's Coefficient Alpha, and Violations of Essential Tau-Equivalence with Fixed Congeneric Components. *Multivariate Behavioral Research* 32 (4): 329-353. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=8a16c070-bb42-4430-ae81-85167485e4bc%40sessionmgr12&vid=2&hid=25> (20. julij 2012).
- Raykov, Tenko in Patrick E. Shrout. 2002. Reliability of Scales With General Structure: Point and Interval Estimation Using a Structural Equation Modeling Approach. *Structural Equation Modeling* 9 (2): 195-212. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=e5ac2ce8-6b10-4ff7-90b4-f9ecdc82893f%40sessionmgr12&vid=2&hid=14> (19. julij 2012).
- Revelle William. 2012. *Package »psych«*. Dostopno prek: <http://cran.r-project.org/web/packages/psych/psych.pdf> (18. avgust 2012).

- Revelle, William in Richard E. Zinbarg. 2008. Coefficients alpha, beta, omega and the glb: comments on Sijtsma. *Psychometrika* 74 (1): 145-154. Dostopno prek: <http://personality-project.org/revelle/publications/revelle.zinbarg.08.pdf> (15. julij 2012).
- R-project. Dostopno preko: <http://www.r-project.org/> (2. September 2012).
- Schmitt, Neal. 1996. Uses and Abuses of Coefficient Alpha. *Psychological Assessment* 8 (4): 350-353. Dostopno prek: http://ovidsp.uk.ovid.com.nukweb.nuk.uni-lj.si/sp-3.4.2a/ovidweb.cgi?WebLinkFrameset=1&S=KEBLPDKPGFHBKCDFNBLNGAGMJDCAA00&returnUrl=ovidweb.cgi%3f%26Full%2bText%3dL%257cS.sh.20.21%257c0%257c00012030-199612000-00003%26S%3dKEBLPDKPGFHBKCDFNBLNGAGMJDCAA00&directlink=http%3a%2f%2fgraphics.uk.ovid.com%2fovftpdbs%2fPDHFFNAGNGCDGF00%2ffs047%2fovft%2flive%2fgv024%2f00012030%2f00012030-199612000-00003.pdf&filename=Uses+and+Abuses+of+Coefficient+Alpha.&pdf_key=PDHFFNAGNGCDGF00&pdf_index=/fs047/ovft/live/gv024/00012030/00012030-199612000-00003 (19. oktober 2012).
- Shevlin M., J.N.V. Miles, M.N.O. Davies in S. Walker. 1998. Coefficient Alpha: a useful indicator of reliability? *Personality and Individual Differences* 28 (2000): 229-237. Dostopno prek: <http://www.jeremymiles.co.uk/mestuff/publications/p6.pdf> (5. julij 2012).
- Sočan, Gregor. 2000. Assessment of Reliability when Test Items are not Essentially τ -Equivalent. *Metodološki zvezki* 15: 23-35. Ljubljana: FDV. Dostopno prek: <http://mrvar.fdv.uni-lj.si/pub/mz/mz15/socan.pdf> (11. julij 2012).
- Splichal, Slavko. 1990. *Analiza besedil: statistična obravnava jezikovnih podatkov v družboslovnih raziskavah*. Ljubljana: FDV.
- Stephenson, Michael T. in Robert Lance Holbert. 2003. A Monte Carlo Simulation of Observable Versus Latent Variable Structural Equation Modeling Techniques. *Communication Research* 30 (3): 332-354. Dostopno prek: <http://www.tamu.edu/faculty/mstephenson/CR-final.pdf> (10. julij 2012).
- Streiner, David L. 2003. Starting at the Beginning: An Introduction to Coefficient Alpha and Internal Consistency. *Journal of Personality Assessment* 80 (1): 99-103. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=01073fa7-5eba-4150-9fd1-602490c62e9f%40sessionmgr112&vid=2&hid=113> (16. julij 2012).

- Stoelting, Ricka. 2002. *Structural Equation Modeling/Path Analysis*. Dostopno preko: <http://userwww.sfsu.edu/~efc/classes/biol710/path/SEMwebpage.htm> (5. september 2012).
- Ullman, Jodie B. 2006. Structural Equation Modeling: Review the Basics nad Moving Forward. *Journal of Personality Assessment* 87 (1): 35-50. Dostopno prek: <http://web.ebscohost.com.nukweb.nuk.uni-lj.si/ehost/pdfviewer/pdfviewer?sid=0be71931-602e-4dcf-b68e-e2e35c0f2826%40sessionmgr104&vid=2&hid=106> (22. julij 2012).
- Yang, Yanyun in Samuel B. Green. 2011. Coefficient Alpha: A Reliability Coefficient for the 21st Century?. *Journal of Psycheducational Assessment* 29 (4): 377-392. Dostopno prek: <http://jpa.sagepub.com/content/29/4/377> (10. julij 2012).
- Zinbarg, Righard E., Willian Revelle, Iftah Yovel in Wen Li. 2005. Cronbach's Alpha, Revelle's β , and Mcdonald's Omega: their relations with each other and two alternative conceptualizations of reliability. *Psychometrika* 70 (1): 123-133. Dostopno prek: <http://www.springerlink.com.nukweb.nuk.uni-lj.si/content/w6x4469365315020/> (13. julij 2012).
- Žiberna, Aleš. 2012. Funkcije: myOmega, SigmaWhole, objectiveULS. Ljubljana, 19. januar.

PRILOGA A: Programska koda, uporabljena v magistrski nalogi

```
#####
##### R version 2.15.1 (2012-06-22) -- "Roasted Marshmallows"
## Copyright (C) 2012 The R Foundation for Statistical Computing
## ISBN 3-900051-07-0
## Platform: i386-pc-mingw32/i386 (32-bit)
#####
#####

#####
##PACKAGES:
install.packages("sem")
install.packages("psych")
install.packages("GPArotation")
install.packages("polycor")
#####
#####

#####
##LIBRARY:
library(foreign)
library(psych)
library(GPArotation)
library(matrixcalc)
library(MASS)
library(sem)
#####
#####

#####
##FUNKCIJE:
myOmega<-function(covMat){
  faRes<-factanal(covmat=covMat,factors=1)
  h2<- 1 - faRes$uniquenesses
  N<-dim(covMat) [1]
  omega<- 1 - (sum(diag(covMat))-sum(diag(covMat)*h2))/sum(covMat)
  return(omega)
}

objectiveULS<- function (gradient = FALSE)
{
  result <- list(objective = function(par, model.description) {
    with(model.description, {
      A <- P <- matrix(0, m, m)
      val <- ifelse(fixed, ram[, 5], par[sel.free])
      A[arrows.1] <- val[one.head]
      P[arrows.2t] <- P[arrows.2] <- val[!one.head]
```

```

        I.Ainv <- solve(diag(m) - A)
        C <- J %*% I.Ainv %*% P %*% t(I.Ainv) %*% t(J)
        SS <- (S - C)
        f <- 0.5 * sum(SS^2)
        attributes(f) <- list(C = C, A = A, P = P)
        f
    })
}
class(result) <- "semObjective"
result
}

SigmaWhole<-function(model){
# na podlagi funkcije fcores (natncneje fscores.sem) iz paketka sem,
# razlicica 0.9-21 John Fox (jfox@mcmaster.ca)
  m <- model$m
  P <- model$P
  A <- model$A
  var.names <- model$var.names
  observed <- var.names %in% rownames(model$C)
  if (all(observed))
    stop("there are no latent variables")
  IAinv <- solve(diag(m) - A)
  Sigma <- IAinv %*% P %*% t(IAinv)
  return(Sigma)
}
#####
#####
##MODEL1:
##Congeneric model
modelHx15Con<-specifyModel()
T -> x1, NA, 1
T -> x2, a2, NA
T -> x3, a3, NA
T -> x4, a4, NA
T -> x5, a5, NA
X <- x1, NA, 1
X <- x2, NA, 1
X <- x3, NA, 1
X <- x4, NA, 1
X <- x5, NA, 1
x1 <-> x1, var1, NA
x2 <-> x2, var2, NA
x3 <-> x3, var3, NA
x4 <-> x4, var4, NA
x5 <-> x5, var5, NA
X <-> X, NA, 0
T <-> T, Tvar, NA

##Tau-equivalent model
modelHx15TauEq<-specifyModel()
T -> x1, NA, 1
T -> x2, NA, 1
T -> x3, NA, 1
T -> x4, NA, 1

```

```

T -> x5, NA, 1
X <- x1, NA, 1
X <- x2, NA, 1
X <- x3, NA, 1
X <- x4, NA, 1
X <- x5, NA, 1
x1 <-> x1, var1, NA
x2 <-> x2, var2, NA
x3 <-> x3, var3, NA
x4 <-> x4, var4, NA
x5 <-> x5, var5, NA
X <-> X, NA, 0
T <-> T, Tvar, NA

##Parallel model
modelHx15Par<-specifyModel()
T -> x1, NA, 1
T -> x2, NA, 1
T -> x3, NA, 1
T -> x4, NA, 1
T -> x5, NA, 1
X <- x1, NA, 1
X <- x2, NA, 1
X <- x3, NA, 1
X <- x4, NA, 1
X <- x5, NA, 1
x1 <-> x1, var1, NA
x2 <-> x2, var1, NA
x3 <-> x3, var1, NA
x4 <-> x4, var1, NA
x5 <-> x5, var1, NA
X <-> X, NA, 0
T <-> T, Tvar, NA
#####
#####

#####
#####
##PODATKI:
ponovitve<-1000

stevecNEG<-0

rawAlpha15Pon<-matrix(NA, ncol=ponovitve, nrow=72)
stdAlpha15Pon<-matrix(NA, ncol=ponovitve, nrow=72)
cov2covOmega15Pon<-matrix(NA, ncol=ponovitve, nrow=72)
covHOmega15Pon<-matrix(NA, ncol=ponovitve, nrow=72)
ocParPon<-matrix(NA, ncol=ponovitve, nrow=72)
ocTauPon<-matrix(NA, ncol=ponovitve, nrow=72)
ocConPon<-matrix(NA, ncol=ponovitve, nrow=72)
pravaZanesljivostPon<-matrix(NA, ncol=ponovitve, nrow=72)
pravaZanesljivostTeorPon<-matrix(NA, ncol=ponovitve, nrow=72)
skupna3D<-array(NA, dim=c(72, 9, ponovitve))

for (p in 1:ponovitve) {

```

```

#####
##### ##GENERIRANJE PODATKOV

#FAKTORSKE UTEŽI:
A1<-c(0.3,0.3,0.3,0.3,0.3) #enake nizke uteži
A2<-c(0.5,0.5,0.5,0.5,0.5) #enake srednje uteži
A3<-c(0.8,0.8,0.8,0.8,0.8) #enake visoke uteži
A4<-c(0+(1:5)/6) #razlicne-manj uteži
A5<-c(0.4+(1:5)/10) #razlicne-bolj uteži
A6<-c(seq(5,25, by=5)/26) #bolj različne uteži

#velikosti vzorcev (mali, srednji, veliki)
n1<-100
n2<-500
n3<-1000

##MODELIRANJE
matrike<-c(
  A1,A2,A3,A4,A5,A6,
  A1,A2,A3,A4,A5,A6
)
matrike<-matrix(matrike)
matrike<-matrix(matrike,ncol=(length(matrike)/5))

rezultati<-matrix(NA,ncol=9,nrow=(length(matrike)/5))

dolzinaMatrik<-(length(matrike)/5)
for (i in 1:dolzinaMatrik) {

  A<-matrix(matrike[,i],ncol=1)

  Psi1<-diag(1-diag(A%*%t(A))) #enake skupne variance
  Psi2<-diag(c(0.2,0.3,0.4,0.5,0.6))#različne variance 1:3
  Psi3<-diag(0.09+0.81/4*(0:4))#zelo različne variance 1:10
  Psi4<-diag(1-diag(A2%*%t(A2))) #enake variance napak
  nF<-dim(A)[2]
  nX<-dim(A)[1]

  if (i==1 | i==2 | i==3 | i==4 | i==5 | i==6 | i==7 | i==8 | i==9 | i==10 | i==11 | i==12 | i==13 | i==14 | i==15 | i==16 | i==17 | i==18 | i==19 | i==20 | i==21 | i==22 | i==23 | i==24 | i==25 | i==26 | i==27 | i==28 | i==29 | i==30 | i==31 | i==32 | i==33 | i==34 | i==35 | i==36 | i==37 | i==38 | i==39 | i==40 | i==41 | i==42 | i==43 | i==44 | i==45 | i==46 | i==47 | i==48 | i==49 | i==50 | i==51 | i==52 | i==53 | i==54) {Psi<-Psi1}
}

```

```

        else {
            if ( i==7      | i==8      | i==9      | i==10     | i==11     |
i==12      | i==31     | i==32     | i==33     | i==34     | i==35     |
i==36      | i==55     | i==56     | i==57     | i==58     | i==59     |
i==60) {Psi<-Psi2}
                else {
                    if (i==13    | i==14    | i==15    | i==16    | i==17
| i==18    | i==37    | i==38    | i==39    | i==40    | i==41
| i==42    | i==61    | i==62    | i==63    | i==64    | i==65
| i==66) {Psi<-Psi3}
                        else {
                            if ( i==19    | i==20    | i==21    | i==22
i==23    | i==24    | i==43    | i==44    | i==45    | i==46
i==47    | i==48    | i==67    | i==68    | i==69    | i==70
i==71    | i==72) {Psi<-Psi4}
                        }
                    }
                }
            }

if (i<25){n<-n1}
else {
if (24<i&i<49){n<-n2}
else {n<-n3}
}

```

```

R<-diag(nF)

vrednostiNeg<-TRUE
while(vrednostiNeg) {
vrednostiNeg<-FALSE

ponovi<-TRUE
while(ponovi) {
ponovi<-FALSE

F<-mvrnorm(n=n, mu=rep(0, nF), Sigma=R)

E<-mvrnorm(n=n, mu=rep(0, nX), Sigma=Psi)
X<-F%*%t(A)+E
L<-apply(X, 1, mean)
colnames(X)<-paste("x", 1:5, sep="")
colnames(E)<-paste("e", 1:5, sep="")
dat<-as.data.frame(X)
dat

pravaZanesljivost<-cor(F, L)^2
T<-apply(F%*%t(A), 1, mean)
pravaZanesljivostTeor<-1
sum(diag(Psi))/(sum(A)^2+sum(diag(Psi)))

covH<-cov(dat)

#Ocena zanesljivosti za Congeneric model

```

```

opt<-c(optimizerNlm=optimizerNlm, optimizerOptim=optimizerOptim,
optimizerNlminb=optimizerNlminb)
tmpTry<-try({
  for(iOpt in names(opt)){
    semHx15Con<- sem(modelHx15Con, data=dat,
objective=objectiveULS, optimizer=opt[[iOpt]], maxiter=10000)
    if(semHx15Con$convergence)break
  };semHx15Con}
)

if(class(tmpTry)=="try-error") {
  print("Napaka pri Kongeneričnem modelu")
  ponovi<-TRUE
  next
}else{
  semHx15Con<-tmpTry
  if(!semHx15Con$convergence){
    print ("Ni skonvergiral pri Kongeneričnem modelu.")
    ponovi<-TRUE
    next
  }
}

ocCon<- (cov2cor(SigmaWhole(semHx15Con)) ["X", "T"] ^2)      #ocena
zanesljivosti po modelu za Congeneric

#Ocena zanesljivosti za Tau-equivalent model

tmpTry<-try({
  for(iOpt in names(opt)){
    semHx15TauEq<- sem(modelHx15TauEq, data=dat,
objective=objectiveULS, optimizer=opt[[iOpt]], maxiter=10000)
    if(semHx15TauEq$convergence) break
  };semHx15TauEq}
)

if(class(tmpTry)=="try-error") {
  print ("Napaka pri Tau-equivalent modelu.")
  ponovi<-TRUE
  next
}else{
  semHx15TauEq<-tmpTry
  if(!semHx15TauEq$convergence){
    print ("Ni skonvergiral pri Tau-equivalentnem modelu.")

  ponovi<-TRUE
  next
}
}

summary(semHx15TauEq)

```

```

ocTau<- (cov2cor(SigmaWhole(semHx15TauEq)) ["X", "T"] ^2)

#Ocena zanslejivosti za Parallel model

tmpTry<-try({for(iOpt in names(opt)){
    semHx15Par<- sem(modelHx15Par, data=dat,
objective=objectiveULS, optimizer=opt[[iOpt]], maxiter=10000)
    if(semHx15Par$convergence) break
  };semHx15Par})

}

if(class(tmpTry)=="try-error") {
  print ("Napaka pri Parallelnem modelu.")
ponovi<-TRUE
next

}else{
  semHx15Par<-tmpTry
  if(!semHx15Par$convergence){
    print ("Ni skonvergiral pri Parallelnem modelu.")
  ponovi<-TRUE
  next
}
}

ocPar<- (cov2cor(SigmaWhole(semHx15Par)) ["X", "T"] ^2)

myOmega(cov2cor(covH[1:5,1:5]))
myOmega(covH[1:5,1:5])
alpha(covH[1:5,1:5])

#izpis za tabelo:
rawAlpha15<-alpha(covH[1:5,1:5])$total$raw_alpha
stdAlpha15<-alpha(covH[1:5,1:5])$total$std.alpha
cov2covOmega15<-myOmega(cov2cor(covH[1:5,1:5]))
covHOmega15<-myOmega(covH[1:5,1:5])
#####
#####
##TABELE REZULTATOV:

koeficienti<-
c(rawAlpha15, stdAlpha15, cov2covOmega15, covHOmega15, ocPar, ocTau, ocCon, pravaZanesljivost, pravaZanesljivostTeor)
koeficienti
}

if (rawAlpha15<0 | rawAlpha15>1 | !is.finite(rawAlpha15) |
cov2covOmega15<0 | cov2covOmega15>1 | !is.finite(cov2covOmega15) |
stdAlpha15<0 | stdAlpha15>1 | !is.finite(stdAlpha15) |
covHOmega15<0 | covHOmega15>1 | !is.finite(covHOmega15) |
ocPar<0 | ocPar>1 | !is.finite(ocPar) |
ocTau<0 | ocTau>1 | !is.finite(ocTau) |

```

```

ocCon<0 | ocCon>1 | !is.finite(ocCon) |
pravaZanesljivost<0
pravaZanesljivost>1 | !is.finite(pravaZanesljivost) |
pravaZanesljivostTeor<0 | pravaZanesljivostTeor>1
!is.finite(pravaZanesljivostTeor)
){
  print ("Vrednos ni OK")
  stevecNEG<-stevecNEG+1
  vrednostiNeg<-TRUE
  next
}

rezultati[i,]<-koeficienti
#cat ("n:",n,"\\n","i:",i,"\\n","Psi:",Psi,"\\n")
}

colnames(rezultati)<-c("Cronbach alfa","Cronbach alpha na stand.", "Omega na cov2cov", "Omega na covH", "Ocena za Parallel model", "Ocena za Tau-equivalent model", "Ocena za Congeneric model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost")
rezultati
write.table(rezultati,file="rezultati.xls", append = FALSE, row.names = TRUE, col.names =NA, sep = "\\t",dec=",") #shranimo rezultate

rawAlpha15Pon[,p]<-rezultati[,1]
stdAlpha15Pon[,p]<-rezultati[,2]
cov2covOmega15Pon[,p]<-rezultati[,3]
covHOmega15Pon[,p]<-rezultati[,4]
ocParPon[,p]<-rezultati[,5]
ocTauPon[,p]<-rezultati[,6]
ocConPon[,p]<-rezultati[,7]
pravaZanesljivostPon[,p]<-rezultati[,8]
pravaZanesljivostTeorPon[,p]<-rezultati[,9]
skupna3D[ , ,p]<-rezultati
cat("Ponovitev ",p,"od", ponovitve, "končana!\\n")
}

#####
##### POVPREČNE VREDNOSTI, STANDARDNI ODKLON IN RAZMERJE MED KOEFICIENTI IN PRAVO ZANESLIVOSTJO

#Povprečja na vseh izračunanih vrednostih
koeficientiPonMean<-
matrix(c(rowMeans(rawAlpha15Pon), rowMeans(stdAlpha15Pon), rowMeans(cov2covOmega15Pon), rowMeans(covHOmega15Pon), rowMeans(ocParPon), rowMeans(ocTauPon), rowMeans(ocConPon), rowMeans(pravaZanesljivostPon)), ncol=9)
koeficientiPonMean
#Standardni odkloni na vseh izračunanih vrednostih

```

```

koeficientiPonSd<-
matrix(c(apply(rawAlpha15Pon,1,sd),apply(stdAlpha15Pon,1,sd),apply(cov2c
ovOmega15Pon,1,sd),apply(covHOmega15Pon,1,sd),apply(ocParPon,1,sd),apply
(ocTauPon,1,sd),apply(ocConPon,1,sd),apply(pravaZanesljivostPon,1,sd),ap
ply(pravaZanesljivostTeorPon,1,sd)),ncol=9)
koeficientiPonSd
#Rezultati/prava vrednost (razmerje) na vseh izračunanih vrednostih
koeficientiVSpravaVrednost<-
matrix(c((rowMeans(rawAlpha15Pon)/rowMeans(pravaZanesljivostPon)),(rowMe
ans(stdAlpha15Pon)/rowMeans(pravaZanesljivostPon)),(rowMeans(cov2covOmeg
a15Pon)/rowMeans(pravaZanesljivostPon)),(rowMeans(covHOmega15Pon)/rowMea
ns(pravaZanesljivostPon)),(rowMeans(ocParPon)/rowMeans(pravaZanesljivost
Pon)),(rowMeans(ocTauPon)/rowMeans(pravaZanesljivostPon)),(rowMeans(ocCo
nPon)/rowMeans(pravaZanesljivostPon)),(rowMeans(pravaZanesljivostPon)/ro
wMeans(pravaZanesljivostPon)),(rowMeans(pravaZanesljivostTeorPon)/rowMea
ns(pravaZanesljivostTeorPon))),ncol=9)
koeficientiVSpravaVrednost

colnames(koeficientiPonMean)<-c("Cronbach alfa","Cronbach alpha na
stand.", "Omega na cov2cov", "Omega na covH", "Ocena za Parallel model",
"Ocena za Tau-equivalent model", "Ocena za Congeneric
model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost")
rownames(koeficientiPonMean)<-c(
  "n1: enake skupne variance in nizke enake faktorske uteži",
  "n1: enake skupne variance in srednje enake faktorske uteži",
  "n1: enake skupne variance in visoke enake faktorske uteži",
  "n1: enake skupne variance in različne faktorske uteži",
  "n1: enake skupne variance in večje manj različne faktorske uteži",
  "n1: enake skupne variance in bolj različne faktorske uteži",
  "n1: različne variance (1:3) in nizke enake faktorske uteži",
  "n1: različne variance (1:3) in srednje enake faktorske uteži",
  "n1: različne variance (1:3) in visoke enake faktorske uteži",
  "n1: različne variance (1:3) in različne faktorske uteži",
  "n1: različne variance (1:3) in večje manj različne faktorske uteži",
  "n1: različne variance (1:3) in bolj različne faktorske uteži",
  "n1: različne variance (1:10) in nizke enake faktorske uteži",
  "n1: različne variance (1:10) in srednje enake faktorske uteži",
  "n1: različne variance (1:10) in visoke enake faktorske uteži",
  "n1: različne variance (1:10) in različne faktorske uteži",
  "n1: različne variance (1:10) in večje manj različne faktorske uteži",
  "n1: različne variance (1:10) in bolj različne faktorske uteži",
  "n1: enake variance napak in nizke enake faktorske uteži",
  "n1: enake variance napak in srednje enake faktorske uteži",
  "n1: enake variance napak in visoke enake faktorske uteži",
  "n1: enake variance napak in različne faktorske uteži",
  "n1: enake variance napak in večje manj različne faktorske uteži",
  "n1: enake variance napak in bolj različne faktorske uteži",
  "n2: enake skupne variance in nizke enake faktorske uteži",
  "n2: enake skupne variance in srednje enake faktorske uteži",
  "n2: enake skupne variance in visoke enake faktorske uteži",
  "n2: enake skupne variance in različne faktorske uteži",
  "n2: enake skupne variance in večje manj različne faktorske uteži",
  "n2: enake skupne variance in bolj različne faktorske uteži",
  "n2: različne variance (1:3) in nizke enake faktorske uteži",
  "n2: različne variance (1:3) in srednje enake faktorske uteži",
  "n2: različne variance (1:3) in visoke enake faktorske uteži",
  "n2: različne variance (1:3) in različne faktorske uteži",
  "n2: različne variance (1:3) in večje manj različne faktorske uteži",
  "n2: različne variance (1:3) in bolj različne faktorske uteži",
  "n2: različne variance (1:3) in nizke enake faktorske uteži",
  "n2: različne variance (1:3) in srednje enake faktorske uteži",
  "n2: različne variance (1:3) in visoke enake faktorske uteži",
  "n2: različne variance (1:3) in različne faktorske uteži",
  "n2: različne variance (1:3) in večje manj različne faktorske uteži",
  "n2: različne variance (1:3) in bolj različne faktorske uteži"
)

```

```

"n2: različne variance (1:3) in bolj različne faktorske uteži",
"n2: različne variance (1:10) in nizke enake faktorske uteži",
"n2: različne variance (1:10) in srednje enake faktorske uteži",
"n2: različne variance (1:10) in visoke enake faktorske uteži",
"n2: različne variance (1:10) in različne faktorske uteži",
"n2: različne variance (1:10) in večje manj različne faktorske uteži",
"n2: različne variance (1:10) in bolj različne faktorske uteži",
"n2: enake variance napak in nizke enake faktorske uteži",
"n2: enake variance napak in srednje enake faktorske uteži",
"n2: enake variance napak in visoke enake faktorske uteži",
"n2: enake variance napak in različne faktorske uteži",
"n2: enake variance napak in večje manj različne faktorske uteži",
"n2: enake variance napak in bolj različne faktorske uteži",
"n3: enake skupne variance in nizke enake faktorske uteži",
"n3: enake skupne variance in srednje enake faktorske uteži",
"n3: enake skupne variance in visoke enake faktorske uteži",
"n3: enake skupne variance in različne faktorske uteži",
"n3: enake skupne variance in večje manj različne faktorske uteži",
"n3: enake skupne variance in bolj različne faktorske uteži",
"n3: različne variance (1:3) in nizke enake faktorske uteži",
"n3: različne variance (1:3) in srednje enake faktorske uteži",
"n3: različne variance (1:3) in visoke enake faktorske uteži",
"n3: različne variance (1:3) in različne faktorske uteži",
"n3: različne variance (1:3) in večje manj različne faktorske uteži",
"n3: različne variance (1:3) in bolj različne faktorske uteži",
"n3: različne variance (1:10) in nizke enake faktorske uteži",
"n3: različne variance (1:10) in srednje enake faktorske uteži",
"n3: različne variance (1:10) in visoke enake faktorske uteži",
"n3: različne variance (1:10) in različne faktorske uteži",
"n3: različne variance (1:10) in večje manj različne faktorske uteži",
"n3: različne variance (1:10) in bolj različne faktorske uteži",
"n3: enake variance napak in nizke enake faktorske uteži",
"n3: enake variance napak in srednje enake faktorske uteži",
"n3: enake variance napak in visoke enake faktorske uteži",
"n3: enake variance napak in različne faktorske uteži",
"n3: enake variance napak in večje manj različne faktorske uteži",
"n3: enake variance napak in bolj različne faktorske uteži"
    )
koeficientiPonMean

```

```

colnames(koeficientiPonSd)<-c("Cronbach alfa","Cronbach alpha na stand.", "Omega na cov2cov", "Omega na covH", "Ocena za Parallel model", "Ocena za Tau-equivalent model", "Ocena za Congeneric model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost")
rownames(koeficientiPonSd)<-c(
  "n1: enake skupne variance in nizke enake faktorske uteži",
  "n1: enake skupne variance in srednje enake faktorske uteži",
  "n1: enake skupne variance in visoke enake faktorske uteži",
  "n1: enake skupne variance in različne faktorske uteži",
  "n1: enake skupne variance in večje manj različne faktorske uteži",
  "n1: enake skupne variance in bolj različne faktorske uteži",
  "n1: različne variance (1:3) in nizke enake faktorske uteži",
  "n1: različne variance (1:3) in srednje enake faktorske uteži",
  "n1: različne variance (1:3) in visoke enake faktorske uteži",
  "n1: različne variance (1:3) in različne faktorske uteži",
  "n1: različne variance (1:3) in večje manj različne faktorske uteži",
  "n1: različne variance (1:3) in bolj različne faktorske uteži",
  "n1: različne variance (1:10) in nizke enake faktorske uteži",

```


koeficientiPonSd

```
colnames(koeficientiVSpravaVrednost)<-c("Cronbach alfa", "Cronbach alpha
na stand.", "Omega na cov2cov", "Omega na covH", "Ocena za Parallel model",
"Ocena za Tau-equivalent model", "Ocena za Congeneric
model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost")
rownames(koeficientiVSpravaVrednost)<-c(
  "n1: enake skupne variance in nizke enake faktorske uteži",
  "n1: enake skupne variance in srednje enake faktorske uteži",
  "n1: enake skupne variance in visoke enake faktorske uteži",
  "n1: enake skupne variance in različne faktorske uteži",
  "n1: enake skupne variance in večje manj različne faktorske uteži",
  "n1: enake skupne variance in bolj različne faktorske uteži",
  "n1: različne variance (1:3) in nizke enake faktorske uteži",
  "n1: različne variance (1:3) in srednje enake faktorske uteži",
  "n1: različne variance (1:3) in visoke enake faktorske uteži",
  "n1: različne variance (1:3) in različne faktorske uteži",
  "n1: različne variance (1:3) in večje manj različne faktorske uteži",
  "n1: različne variance (1:3) in bolj različne faktorske uteži",
  "n1: različne variance (1:10) in nizke enake faktorske uteži",
  "n1: različne variance (1:10) in srednje enake faktorske uteži",
  "n1: različne variance (1:10) in visoke enake faktorske uteži",
  "n1: različne variance (1:10) in različne faktorske uteži",
  "n1: različne variance (1:10) in večje manj različne faktorske uteži",
  "n1: različne variance (1:10) in bolj različne faktorske uteži",
  "n1: enake variance napak in nizke enake faktorske uteži",
  "n1: enake variance napak in srednje enake faktorske uteži",
  "n1: enake variance napak in visoke enake faktorske uteži",
  "n1: enake variance napak in različne faktorske uteži",
  "n1: enake variance napak in večje manj različne faktorske uteži",
  "n1: enake variance napak in bolj različne faktorske uteži",
  "n2: enake skupne variance in nizke enake faktorske uteži",
  "n2: enake skupne variance in srednje enake faktorske uteži",
  "n2: enake skupne variance in visoke enake faktorske uteži",
  "n2: enake skupne variance in različne faktorske uteži",
  "n2: enake skupne variance in večje manj različne faktorske uteži",
  "n2: enake skupne variance in bolj različne faktorske uteži",
  "n2: različne variance (1:3) in nizke enake faktorske uteži",
  "n2: različne variance (1:3) in srednje enake faktorske uteži",
  "n2: različne variance (1:3) in visoke enake faktorske uteži",
  "n2: različne variance (1:3) in različne faktorske uteži",
  "n2: različne variance (1:3) in večje manj različne faktorske uteži",
  "n2: različne variance (1:3) in bolj različne faktorske uteži",
  "n2: različne variance (1:10) in nizke enake faktorske uteži",
  "n2: različne variance (1:10) in srednje enake faktorske uteži",
  "n2: različne variance (1:10) in visoke enake faktorske uteži",
  "n2: različne variance (1:10) in različne faktorske uteži",
  "n2: različne variance (1:10) in večje manj različne faktorske uteži",
  "n2: različne variance (1:10) in bolj različne faktorske uteži",
  "n2: enake variance napak in nizke enake faktorske uteži",
  "n2: enake variance napak in srednje enake faktorske uteži",
  "n2: enake variance napak in visoke enake faktorske uteži",
  "n2: enake variance napak in različne faktorske uteži",
  "n2: enake variance napak in večje manj različne faktorske uteži",
  "n2: enake variance napak in bolj različne faktorske uteži",
  "n3: enake skupne variance in nizke enake faktorske uteži",
  "n3: enake skupne variance in srednje enake faktorske uteži",
```

```

"n3: enake skupne variance in visoke enake faktorske uteži",
"n3: enake skupne variance in različne faktorske uteži",
"n3: enake skupne variance in večje manj različne faktorske uteži",
"n3: enake skupne variance in bolj različne faktorske uteži",
"n3: različne variance (1:3) in nizke enake faktorske uteži",
"n3: različne variance (1:3) in srednje enake faktorske uteži",
"n3: različne variance (1:3) in visoke enake faktorske uteži",
"n3: različne variance (1:3) in različne faktorske uteži",
"n3: različne variance (1:3) in večje manj različne faktorske uteži",
"n3: različne variance (1:3) in bolj različne faktorske uteži",
"n3: različne variance (1:10) in nizke enake faktorske uteži",
"n3: različne variance (1:10) in srednje enake faktorske uteži",
"n3: različne variance (1:10) in visoke enake faktorske uteži",
"n3: različne variance (1:10) in različne faktorske uteži",
"n3: različne variance (1:10) in večje manj različne faktorske uteži",
"n3: različne variance (1:10) in bolj različne faktorske uteži",
"n3: enake variance napak in nizke enake faktorske uteži",
"n3: enake variance napak in srednje enake faktorske uteži",
"n3: enake variance napak in visoke enake faktorske uteži",
"n3: enake variance napak in različne faktorske uteži",
"n3: enake variance napak in večje manj različne faktorske uteži",
"n3: enake variance napak in bolj različne faktorske uteži")
koeficientiVSpravaVrednost

```

```

colnames(skupna3D)<-c("Cronbach      alfa", "Cronbach      alpha    na
stand.", "Omega na cov2cov", "Omega na covH", "Ocena za Parallel model",
"Ocena za Tau-equivalent model", "Ocena za Congeneric
model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost")
rownames(skupna3D)<-c(
  "n1: enake skupne variance in nizke enake faktorske uteži",
  "n1: enake skupne variance in srednje enake faktorske uteži",
  "n1: enake skupne variance in visoke enake faktorske uteži",
  "n1: enake skupne variance in različne faktorske uteži",
  "n1: enake skupne variance in večje manj različne faktorske uteži",
  "n1: enake skupne variance in bolj različne faktorske uteži",
  "n1: različne variance (1:3) in nizke enake faktorske uteži",
  "n1: različne variance (1:3) in srednje enake faktorske uteži",
  "n1: različne variance (1:3) in visoke enake faktorske uteži",
  "n1: različne variance (1:3) in različne faktorske uteži",
  "n1: različne variance (1:3) in večje manj različne faktorske uteži",
  "n1: različne variance (1:3) in bolj različne faktorske uteži",
  "n1: različne variance (1:10) in nizke enake faktorske uteži",
  "n1: različne variance (1:10) in srednje enake faktorske uteži",
  "n1: različne variance (1:10) in visoke enake faktorske uteži",
  "n1: različne variance (1:10) in različne faktorske uteži",
  "n1: različne variance (1:10) in večje manj različne faktorske uteži",
  "n1: različne variance (1:10) in bolj različne faktorske uteži",
  "n1: enake variance napak in nizke enake faktorske uteži",
  "n1: enake variance napak in srednje enake faktorske uteži",
  "n1: enake variance napak in visoke enake faktorske uteži",
  "n1: enake variance napak in različne faktorske uteži",
  "n1: enake variance napak in večje manj različne faktorske uteži",
  "n1: enake variance napak in bolj različne faktorske uteži",
  "n2: enake skupne variance in nizke enake faktorske uteži",
  "n2: enake skupne variance in srednje enake faktorske uteži",
  "n2: enake skupne variance in visoke enake faktorske uteži",
  "n2: enake skupne variance in različne faktorske uteži",
  "n2: enake skupne variance in večje manj različne faktorske uteži",
  "n2: enake skupne variance in bolj različne faktorske uteži",

```

```

"n2: različne variance (1:3) in nizke enake faktorske uteži",
"n2: različne variance (1:3) in srednje enake faktorske uteži",
"n2: različne variance (1:3) in visoke enake faktorske uteži",
"n2: različne variance (1:3) in različne faktorske uteži",
"n2: različne variance (1:3) in večje manj različne faktorske uteži",
"n2: različne variance (1:3) in bolj različne faktorske uteži",
"n2: različne variance (1:10) in nizke enake faktorske uteži",
"n2: različne variance (1:10) in srednje enake faktorske uteži",
"n2: različne variance (1:10) in visoke enake faktorske uteži",
"n2: različne variance (1:10) in različne faktorske uteži",
"n2: različne variance (1:10) in večje manj različne faktorske uteži",
"n2: različne variance (1:10) in bolj različne faktorske uteži",
"n2: enake variance napak in nizke enake faktorske uteži",
"n2: enake variance napak in srednje enake faktorske uteži",
"n2: enake variance napak in visoke enake faktorske uteži",
"n2: enake variance napak in različne faktorske uteži",
"n2: enake variance napak in večje manj različne faktorske uteži",
"n2: enake variance napak in bolj različne faktorske uteži",
"n3: enake skupne variance in nizke enake faktorske uteži",
"n3: enake skupne variance in srednje enake faktorske uteži",
"n3: enake skupne variance in visoke enake faktorske uteži",
"n3: enake skupne variance in različne faktorske uteži",
"n3: enake skupne variance in večje manj različne faktorske uteži",
"n3: enake skupne variance in bolj različne faktorske uteži",
"n3: različne variance (1:3) in nizke enake faktorske uteži",
"n3: različne variance (1:3) in srednje enake faktorske uteži",
"n3: različne variance (1:3) in visoke enake faktorske uteži",
"n3: različne variance (1:3) in različne faktorske uteži",
"n3: različne variance (1:3) in večje manj različne faktorske uteži",
"n3: različne variance (1:3) in bolj različne faktorske uteži",
"n3: različne variance (1:10) in nizke enake faktorske uteži",
"n3: različne variance (1:10) in srednje enake faktorske uteži",
"n3: različne variance (1:10) in visoke enake faktorske uteži",
"n3: različne variance (1:10) in različne faktorske uteži",
"n3: različne variance (1:10) in večje manj različne faktorske uteži",
"n3: različne variance (1:10) in bolj različne faktorske uteži",
"n3: enake variance napak in nizke enake faktorske uteži",
"n3: enake variance napak in srednje enake faktorske uteži",
"n3: enake variance napak in visoke enake faktorske uteži",
"n3: enake variance napak in različne faktorske uteži",
"n3: enake variance napak in večje manj različne faktorske uteži",
"n3: enake variance napak in bolj različne faktorske uteži")
#skupna3D

write.table(koeficientiPonMean,file="koeficientiPonMean.xls", append =
FALSE,row.names = TRUE,
           col.names =NA, sep = "\t",dec=",") #shranimo rezultate

write.table(koeficientiPonSd,file="koeficientiPonSd.xls",      append =
FALSE,row.names = TRUE,
           col.names =NA, sep = "\t",dec=",") #shranimo rezultate

write.table(koeficientiPonMeanSdSkupaj,file="koeficientiPonMeanSdSkupaj .
xls", append = FALSE,row.names = TRUE,
           col.names =NA, sep = "\t",dec=",") #shranimo rezultate

```

```

write.table(koeficientiVSpravaVrednost,file="koeficientiVSpravaVrednost.xls",
            append = FALSE, row.names = TRUE,
            col.names =NA, sep = "\t",dec=",") #shranimo rezultate

write.table(skupna3D,file="skupna3D.xls", append = FALSE, row.names =
TRUE,
            col.names =NA, sep = "\t",dec=",") #shranimo rezultate

#####
#####
#####
#####
#####
##GRAFIČNI PRIKAZ REZULTATOV:

##POVPREČNE VREDNOSTI:
windows()
minMeans<-min(koeficientiPonMean)
maxMeans<-(max(koeficientiPonMean)+0.3)
plot(rowMeans(rawAlpha15Pon),
      type="o",
      pch="A",lty=1,col="deepskyblue4", frame = FALSE,ylim=c(minMeans,maxMeans),xlab="",ylab="", xaxt="n")
abline(h=13, v=24.5, col = "black")
abline(h=13, v=48.5, col = "black")
abline(h=13, v=72.5, col = "black")
axis(side=3, at=c(12.75,36.25,60.25), srt=45,lty = 1, lwd = 0.5,tick =
FALSE, cex.axis=0.8,lab=c("n1=100","n2=500","n3=1000"))
title(main="Povprečne vrednosti koeficientov pri 1000 ponovitvah\n",
outer=FALSE, col.main="black", font.main=4,)
mtext("ESV-enake skupne variance, RV(1:3)-različne variance (1:3),
RV(1:10)-različne variance (1:10), EVN-enake variance napak, NEFU-nizke
enake faktorske uteži, SEFU-srednje enake faktorske uteži, VEFU-visoke
enake faktorske uteži, RMFU-različne faktorske uteži, RBFU-večje manj
različne faktorske uteži, ERFU-bolj različne faktorske
uteži",side=3,cex=0.6)
lines(rowMeans(stdAlpha15Pon), type="o", pch="a", lty=2, col="brown")
lines(rowMeans(cov2covOmega15Pon), type="o", pch="O", lty=3,
col="darkolivegreen")
lines(rowMeans(covHOMega15Pon), type="o", pch="o", lty=4,
col="darkorange")
lines(rowMeans(ocParPon), type="o", pch="P", lty=5, col="gold")
lines(rowMeans(ocTauPon), type="o", pch="T", lty=6, col="darkorchid3")
lines(rowMeans(ocConPon), type="o", pch="C", lty=3, col="gray48")
lines(rowMeans(pravaZanesljivostPon), type="o", pch="Z", lty=4,
cex=0.8,col="darkred")
lines(rowMeans(pravaZanesljivostTeorPon), type="o", pch="t", lty=6,
cex=0.8,col="violet")
legend("topleft", c("Cronbach alfa","Cronbach alpha na stand.", "Omega
na kovariančni matriki","Omega na korelacijski matriki","Ocena za
Parallel model",
"Ocena za Tau-equivalent model", "Ocena za Congeneric
model","Empirična prava zanesljivost","Teoretična prava zanesljivost"),
cex=0.8,
col=c("deepskyblue4","brown","darkolivegreen","darkorange","gold","darkorchid3",
"gray48","darkred","violet"),
pch=c("A","a","O","o","P","T","C","Z","E","t"), lty=1:2,lwd=2, bty="n")
axis(side=1, at=1:72, cex.axis=0.6,

```

```

lab=c(
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3,NEFU",
"RV(1:3, SEFU",
"RV(1:3, VEFU",
"RV(1:3, RMFU",

```

```

"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU"
),las=2)

png(file="koeficientiPonMean.png",width=400,height=350,res=72)
dev.off()
pdf(file="koeficientiPonMean.pdf")

dev.off(2)
graphics.off()

##STANDARDNI ODKLONI:
windows()
minSd<-min(koeficientiPonSd)
maxSd<- (max(koeficientiPonSd)+0.05)
plot(apply(rawAlpha15Pon,1,sd),
      type="o",
      pch="A",lty=1,col="deepskyblue4",
      frame=FALSE,ylim=c(minSd,maxSd),xlab="",ylab="", xaxt="n")
abline(h=13, v=24.5, col = "black")
abline(h=13, v=48.5, col = "black")
abline(h=13, v=72.5, col = "black")
axis(side=3, at=c(12.75,36.25,60.25), srt=45,lty = 1, lwd = 0.5,tick =
FALSE, cex.axis=0.8,lab=c("n1=100","n2=500","n3=1000"))
title(main="Standardni odkloni koeficientov pri 1000 ponovitvah\n",
outer=FALSE, col.main="black", font.main=4,)
mtext("ESV-enake skupne variance, RV(1:3)-različne variance (1:3),
RV(1:10)-različne variance (1:10), EVN-enake variance napak, NEFU-nizke
enake faktorske uteži, SEFU-srednje enake faktorske uteži, VEFU-visoke
enake faktorske uteži, RMFU-različne faktorske uteži, RBFU-večje manj
različne faktorske uteži, ERFU-bolj različne faktorske
uteži",side=3,cex=0.6)
lines(apply(stdAlpha15Pon,1,sd), type="o", pch="a", lty=2, col="brown")
lines(apply(cov2covOmega15Pon,1,sd), type="o", pch="O", lty=3,
col="darkolivegreen")
lines(apply(covHOmega15Pon,1,sd), type="o", pch="o", lty=4,
col="darkorange")
lines(apply(ocParPon,1,sd), type="o", pch="P", lty=5, col="gold")
lines(apply(ocTauPon,1,sd), type="o", pch="T", lty=6,
col="darkorchid3")
lines(apply(ocConPon,1,sd), type="o", pch="C", lty=3, col="gray48")
lines(apply(pravaZanesljivostPon,1,sd), type="o", pch="Z", lty=4,
cex=0.8,col="darkred")
lines(rowMeans(pravaZanesljivostTeorPon), type="o", pch="t", lty=6,
cex=0.8,col="violet")

```

```

legend("topleft", c("Cronbach alfa", "Cronbach alpha na stand.", "Omega
na kovariančni matriki", "Omega na korelacijski matriki", "Ocena za
Parallel model",
      "Ocena za Tau-equivalent model", "Ocena za Congeneric
model", "Empirična prava zanesljivost", "Teoretična prava zanesljivost"),
cex=0.8,
col=c("deepskyblue4", "brown", "darkolivegreen", "darkorange", "gold", "darko
rchid3", "gray48", "darkred", "violet"),
pch=c("A", "a", "O", "o", "P", "T", "C", "Z", "E", "t"), lty=1:2, lwd=2, bty="n")
axis(side=1, at=1:72, cex.axis=0.6,
lab=c(
  "ESV,NEFU",
  "ESV,SEFU",
  "ESV,VEFU",
  "ESV,RMFU",
  "ESV,RBFU",
  "ESV,ERFU",
  "RV(1:3) NEFU",
  "RV(1:3) SEFU",
  "RV(1:3) VEFU",
  "RV(1:3) RMFU",
  "RV(1:3) RBFU",
  "RV(1:3) ERFU",
  "RV(1:10) NEFU",
  "RV(1:10) SEFU",
  "RV(1:10) VEFU",
  "RV(1:10) RMFU",
  "RV(1:10) RBFU",
  "RV(1:10) ERFU",
  "EVN,NEFU",
  "EVN,SEFU",
  "EVN,VEFU",
  "EVN,RMFU",
  "EVN,RBFU",
  "EVN,ERFU",
  "ESV,NEFU",
  "ESV,SEFU",
  "ESV,VEFU",
  "ESV,RMFU",
  "ESV,RBFU",
  "ESV,ERFU",
  "RV(1:3) NEFU",
  "RV(1:3) SEFU",
  "RV(1:3) VEFU",
  "RV(1:3) RMFU",
  "RV(1:3) RBFU",
  "RV(1:3) ERFU",
  "RV(1:10) NEFU",
  "RV(1:10) SEFU",
  "RV(1:10) VEFU",
  "RV(1:10) RMFU",
  "RV(1:10) RBFU",
  "RV(1:10) ERFU",
  "EVN,NEFU",
  "EVN,SEFU",
  "EVN,VEFU",
  "EVN,RMFU",
  "EVN,RBFU",

```

```

"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3) NEFU",
"RV(1:3) SEFU",
"RV(1:3) VEFU",
"RV(1:3) RMFU",
"RV(1:3) RBFU",
"RV(1:3) ERFU",
"RV(1:10) NEFU",
"RV(1:10) SEFU",
"RV(1:10) VEFU",
"RV(1:10) RMFU",
"RV(1:10) RBFU",
"RV(1:10) ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU"), las=2)

png(file="koeficientiPonSd.png")
pdf(file="koeficientiPonSd.pdf")

dev.off(2)
graphics.off()

##RAZMERJE MED KOEFICIENTI IN PRAVO VREDNOSTJO:
windows()
minKPZ<- (min(koeficientiSpravaVrednost)-0.1)
maxKPZ<- (max(koeficientiSpravaVrednost)+0.1)
plot(koeficientiSpravaVrednost[,1], type="o",
      pch="A", lty=1,col="deepskyblue4", frame
      FALSE, ylim=c(minKPZ,maxKPZ), xlab="", ylab="", xaxt="n")
abline(h=13, v=24.5, col = "black")
abline(h=13, v=48.5, col = "black")
abline(h=13, v=72.5, col = "black")
axis(side=3, at=c(12.75,36.25,60.25), srt=45,lty = 1, lwd = 0.5,tick =
FALSE, cex.axis=0.8,lab=c("n1=100","n2=500","n3=1000"))
title(main="Razmerje med koeficienti in pravo zanesljivostjo pri 1000
ponovitvah\n", outer=FALSE, col.main="black", font.main=4,)
mtext("ESV-enake skupne variance, RV(1:3)-različne variance (1:3),
RV(1:10)-različne variance (1:10), EVN-enake variance napak, NEFU-nizke
enake faktorske uteži, SEFU-srednje enake faktorske uteži, VEFU-visoke
enake faktorske uteži, RMFU-različne faktorske uteži, RBFU-večje manj
različne faktorske uteži, ERFU-bolj različne faktorske
uteži",side=3,cex=0.6)
lines(koeficientiSpravaVrednost[,2], type="o", pch="a", lty=2,
col="brown")
lines(koeficientiSpravaVrednost[,3], type="o", pch="O", lty=3,
col="darkolivegreen")
lines(koeficientiSpravaVrednost[,4], type="o", pch="o", lty=4,
col="darkorange")

```

```

    lines(koeficientiVSpravaVrednost[,5],      type="o",      pch="P",      lty=5,
col="gold")
    lines(koeficientiVSpravaVrednost[,6],      type="o",      pch="T",      lty=6,
col="darkorchid3")
    lines(koeficientiVSpravaVrednost[,7],      type="o",      pch="C",      lty=3,
col="gray48")

  legend("topleft", c("Cronbach alfa","Cronbach alpha na stand.", "Omega
na kovariančni matriki", "Omega na korelacijski matriki", "Ocena za
Parallel model",
  "Ocena za Tau-equivalent model", "Ocena za Congeneric model"),
cex=0.8,

col=c("deepskyblue4", "brown", "darkolivegreen", "darkorange", "gold", "darko
rchid3", "gray48"),   pch=c("A", "a", "O", "o", "P", "T", "C"),   lty=1:2, lwd=2,
bty="n")
  axis(side=1, at=1:72, cex.axis=0.6,
  lab=c(
  "ESV,NEFU",
  "ESV,SEFU",
  "ESV,VEFU",
  "ESV,RMFU",
  "ESV,RBFU",
  "ESV,ERFU",
  "RV(1:3), NEFU",
  "RV(1:3), SEFU",
  "RV(1:3), VEFU",
  "RV(1:3), RMFU",
  "RV(1:3), RBFU",
  "RV(1:3), ERFU",
  "RV(1:10), NEFU",
  "RV(1:10), SEFU",
  "RV(1:10), VEFU",
  "RV(1:10), RMFU",
  "RV(1:10), RBFU",
  "RV(1:10), ERFU",
  "EVN,NEFU",
  "EVN,SEFU",
  "EVN,VEFU",
  "EVN,RMFU",
  "EVN,RBFU",
  "EVN,ERFU",
  "ESV,NEFU",
  "ESV,SEFU",
  "ESV,VEFU",
  "ESV,RMFU",
  "ESV,RBFU",
  "ESV,ERFU",
  "RV(1:3), NEFU",
  "RV(1:3), SEFU",
  "RV(1:3), VEFU",
  "RV(1:3), RMFU",
  "RV(1:3), RBFU",
  "RV(1:3), ERFU",
  "RV(1:10), NEFU",
  "RV(1:10), SEFU",
  "RV(1:10), VEFU",
  "RV(1:10), RMFU",
  "RV(1:10), RBFU",
  "RV(1:10), ERFU",
  )
)

```

```

"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3),NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU"

),las=2)

png(file="koeficientiVSpravaVrednost.png")
pdf(file="koeficientiVSpravaVrednost.pdf")

dev.off(2)
graphics.off()

##PRAVE ZANESLJIVOSTI:
windows()
minMeans<-min(koeficientiPonMean)
maxMeans<- (max(koeficientiPonMean)+0.3)
plot(pravaZanesljivostPon, type="o", pch=15,lty=1,
col="darkred", frame = FALSE,ylim=c(minMeans,maxMeans),xlab="",ylab="",
xaxt="n")
abline(h=13, v=24.5, col = "black")
abline(h=13, v=48.5, col = "black")
abline(h=13, v=72.5, col = "black")
axis(side=3, at=c(12.75,36.25,60.25), srt=45,lty = 1, lwd = 0.5,tick =
FALSE, cex.axis=0.8,lab=c("n1=100","n2=500","n3=1000"))
title(main="Prave zanesljivosti izračunane na različne načine 1000
ponovitvah\n", outer=FALSE, col.main="black", font.main=4,)
mtext("ESV-enake skupne variance, RV(1:3)-različne variance (1:3),
RV(1:10)-različne variance (1:10), EVN-enake variance napak, NEFU-nizke
enake faktorske uteži, SEFU-srednje enake faktorske uteži, VEFU-visoke
enake faktorske uteži, RMFU-različne faktorske uteži, RBFU-večje manj

```

```

različne faktorske uteži, ERFU-bolj različne faktorske
uteži", side=3, cex=0.6)
lines(rowMeans(pravaZanesljivostTeorPon), type="o", pch=17, lty=3,
cex=0.8, col="violet")
legend("topleft", c("Emprična prava zanesljivost", "Teoretična prava
zanesljivost"), cex=0.8,
col=c("darkred", "violet"), pch=c(15, 16, 17), lty=1:2, lwd=2, bty="n")
axis(side=1, at=1:72, cex.axis=0.6,
lab=c(
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",

```

```

    "ESV, VEFU",
    "ESV, RMFU",
    "ESV, RBFU",
    "ESV, ERFU",
    "RV(1:3, NEFU",
    "RV(1:3), SEFU",
    "RV(1:3), VEFU",
    "RV(1:3), RMFU",
    "RV(1:3), RBFU",
    "RV(1:3), ERFU",
    "RV(1:10), NEFU",
    "RV(1:10), SEFU",
    "RV(1:10), VEFU",
    "RV(1:10), RMFU",
    "RV(1:10), RBFU",
    "RV(1:10), ERFU",
    "EVN, NEFU",
    "EVN, SEFU",
    "EVN, VEFU",
    "EVN, RMFU",
    "EVN, RBFU",
    "EVN, ERFU"

) , las=2)

png(file="praveZanesljivosti.png")
pdf(file="praveZanesljivosti.pdf")

dev.off(2)
graphics.off()

##RAZMERJE MED PRAVIMA ZANESLJIVOSTIMA:
windows()
razmerjeZanesljivosti<-
(pravaZanesljivostTeorPon) / (pravaZanesljivostPon)
minMeans<-0.95
maxMeans<-1.05
plot(rowMeans(razmerjeZanesljivosti), type="o", pch=15,lty=1, col="red",
frame = FALSE,ylim=c(minMeans,maxMeans),xlab="",ylab="", xaxt="n")
abline(h=13, v=24.5, col = "black")
abline(h=13, v=48.5, col = "black")
abline(h=13, v=72.5, col = "black")
abline(h=1, col = "black")
axis(side=3, at=c(12.75,36.25,60.25), srt=45,lty = 1, lwd = 0.5,tick =
FALSE, cex.axis=0.8,lab=c("n1=100","n2=500","n3=1000"))
title(main="Razmerje med izracunom pravih zanesljivosti pri 1000
ponovitvah\n", outer=FALSE, col.main="black", font.main=4,)
mtext("ESV-enake skupne variance, RV(1:3)-razlicne variance (1:3),
RV(1:10)-razlicne variance (1:10), EVN-enake variance napak, NEFU-nizke
enake faktorske utezi, SEFU-srednje enake faktorske utezi, VEFU-visoke
enake faktorske utezi, RMFU-razlicne faktorske utezi, RBFU-vecje manj
razlicne faktorske utezi, ERFU-bolj razlicne faktorske
utezi",side=3,cex=0.6)
legend("topleft", c("Teoretična prava zanesljivost/Empirična prava
zanesljivost"), cex=0.8,
col=c("red"), pch=c(15,16,17), lty=1:2,lwd=2, bty="n")
axis(side=1, at=1:72, cex.axis=0.6,
lab=c(

```

"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3), NEFU",
"RV(1:3), SEFU",
"RV(1:3), VEFU",
"RV(1:3), RMFU",
"RV(1:3), RBFU",
"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU",
"ESV,NEFU",
"ESV,SEFU",
"ESV,VEFU",
"ESV,RMFU",
"ESV,RBFU",
"ESV,ERFU",
"RV(1:3,NEFU",
"RV(1:3, SEFU",
"RV(1:3, VEFU",
"RV(1:3, RMFU",
"RV(1:3, RBFU",

```

"RV(1:3), ERFU",
"RV(1:10), NEFU",
"RV(1:10), SEFU",
"RV(1:10), VEFU",
"RV(1:10), RMFU",
"RV(1:10), RBFU",
"RV(1:10), ERFU",
"EVN,NEFU",
"EVN,SEFU",
"EVN,VEFU",
"EVN,RMFU",
"EVN,RBFU",
"EVN,ERFU"
),las=2)

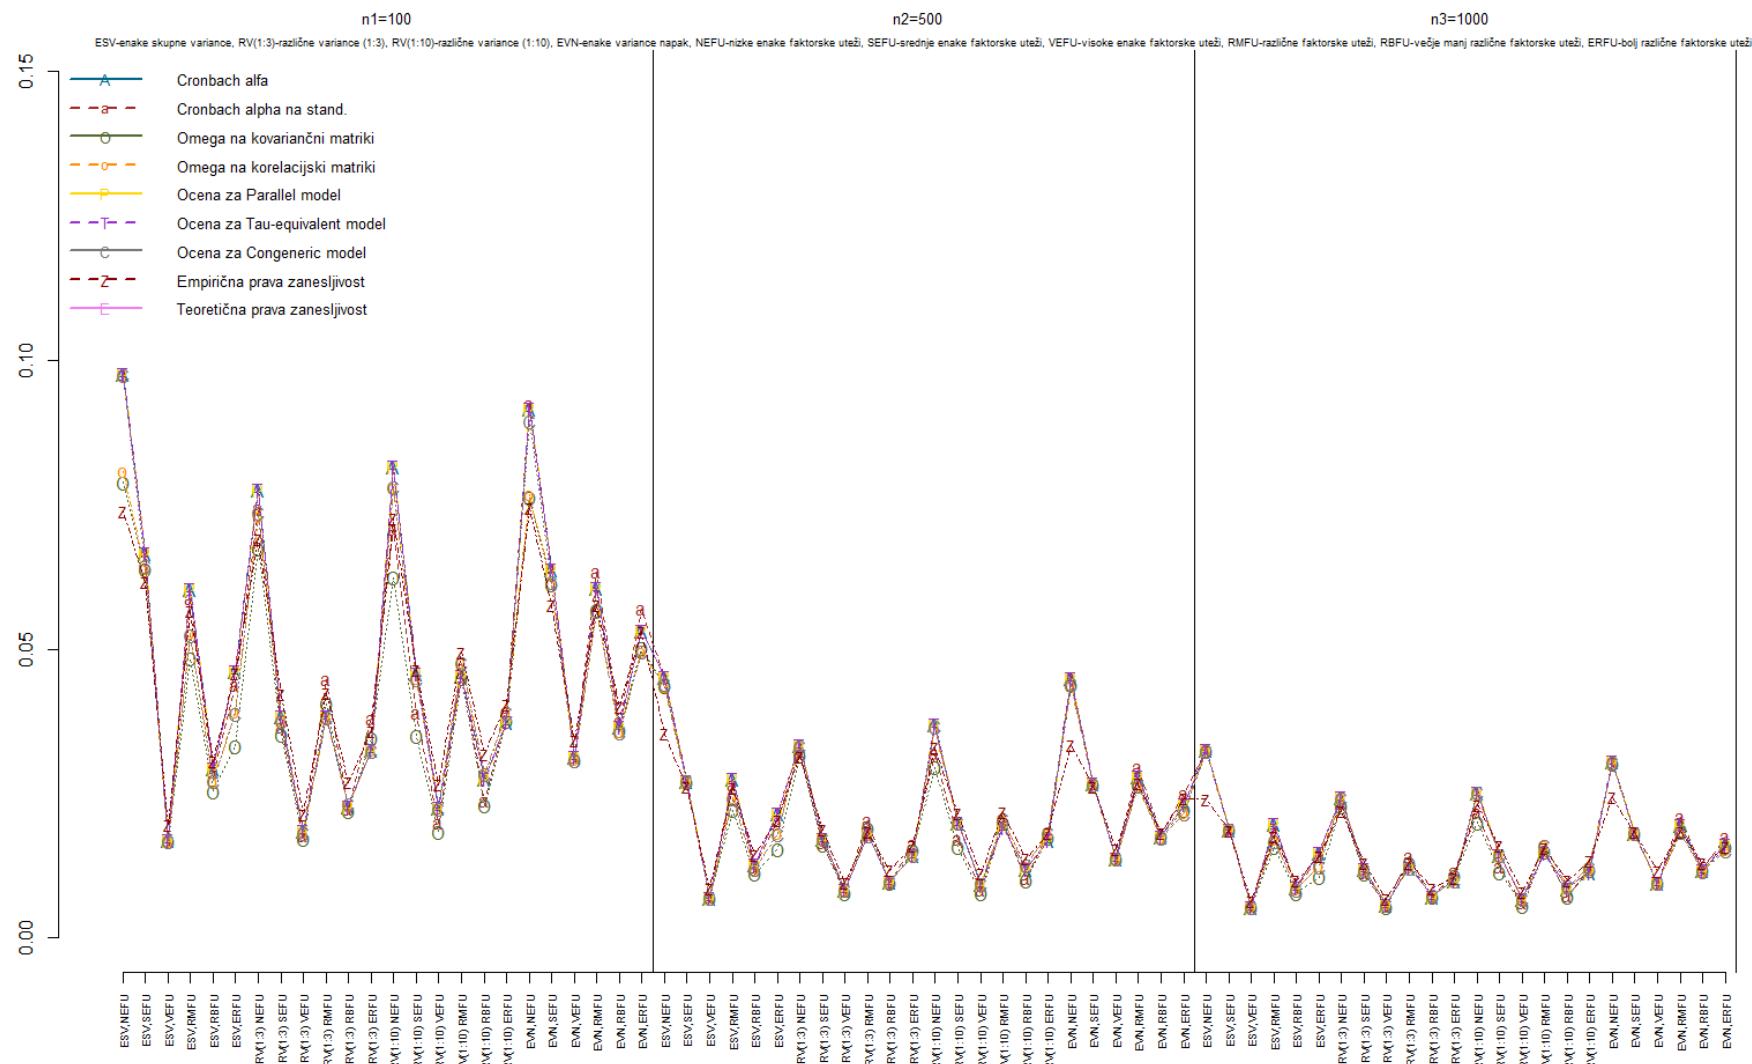
png(file="razmerjeMedZanesljivostima.png")
pdf(file="razmerjeMedZanesljivostima.pdf")

dev.off(2)
graphics.off()

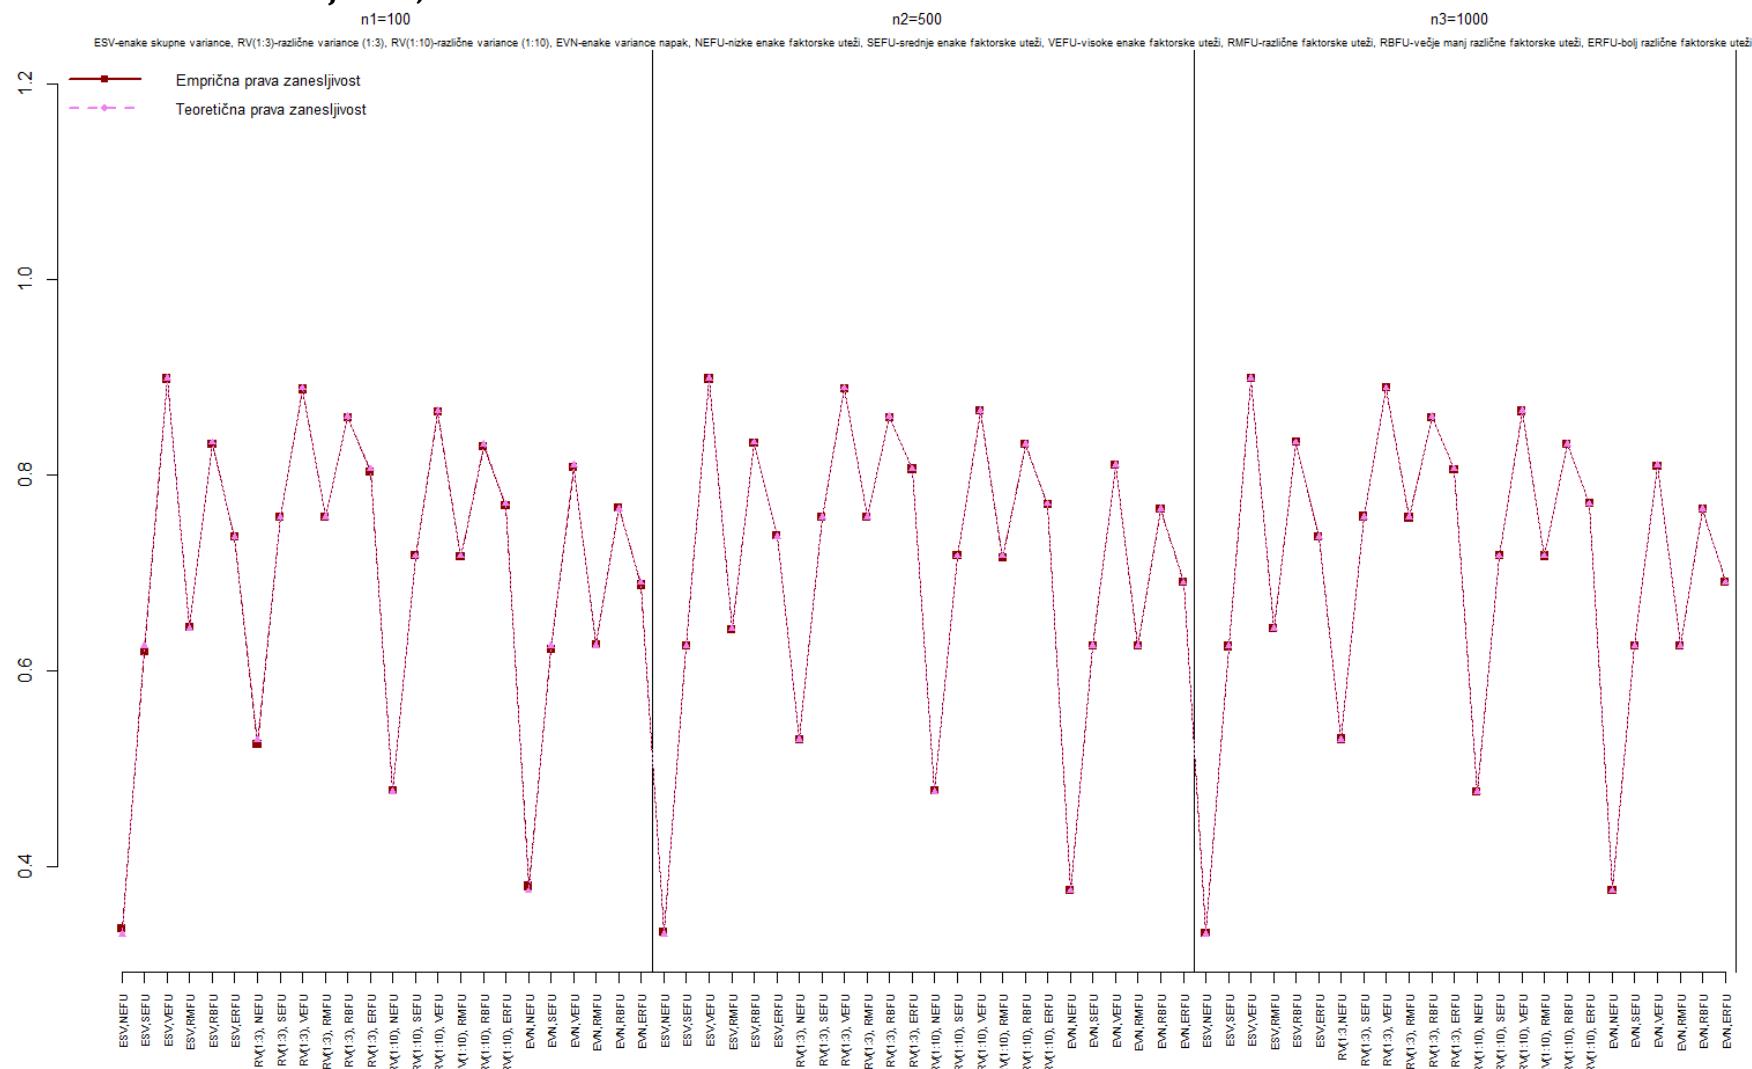
#####
#####
##SAVE WORKSPACE:

savehistory(file="historiyComand.Rhistory")
save.image()
save.image(file ="historiyComand.RData")
#####
#####
#####
```

PRILOGA B: Standardni odkloni ocen zanesljivosti



PRILOGA C: Prave zanesljivosti, izračunane na dva različna načina



PRILOGA Č: Razmerje med izračunoma prave zanesljivosti pri 1000 ponovitvah

