

TYRIMO IR ĮVERTINIMO
PRIEMONIŲ PATIKIMUMO IR
VALIDUMO NUSTATYMAS



VILMANTĖ PAKALNIŠKIENĖ

TYRIMO IR ĮVERTINIMO PRIEMONIŲ PATIKIMUMO IR VALIDUMO NUSTATYMAS

Metodinė priemonė



VILNIAUS
UNIVERSITETO
LEIDYKLA

VILNIUS / 2012

UDK 001.891

Pa92

Apsvarstė ir rekomendavo išleisti
Vilniaus universiteto Filosofijos fakulteto taryba
(2012 m. kovo 7 d., protokolas Nr. 87)

Redakcinė komisija:

Albinas Bagdonas

Vida Jakutienė

Birutė Pociūtė

Gintautas Valickas

Recenzentai:

prof. dr. Auksė Endriulaitienė

dr. Antanas Kairys

doc. dr. Saulė Raižienė

Leidiny s parengtas įgyvendinant Europos socialinio fondo
remiamą projektą „Pripažįstamos kvalifikacijos neturinčių psichologų
tikslinis perkvalifikavimas pagal Vilniaus universiteto bakalauro
ir magistro psichologijos studijų programas – VUPŠIS“
(2011 m. rugsėjo 29 d. sutartis Nr. VP1-2.3.-ŠMM-04-V-02-001/Pars-13700-2068)

ISBN 978-609-459-096-2

© Vilmantė Pakalniškienė, 2012

© Vilniaus universiteto Bendrosios psichologijos katedra, 2012

© Vilniaus universitetas, 2012

Turiny s

1 s k y r i u s

Patikimumas / 11

1. Vidinis suderintumas / 11
 - 1.1. Aprašymas / 11
 - 1.2. Vidinio suderintumo skaičiavimas / 14
 - 1.3. Užduotis / 17
2. Pakartotinių testavimų patvirtintas patikimumas / 17
 - 2.1. Aprašymas / 17
 - 2.2. Pakartotinių testavimų patvirtinto patikimumo skaičiavimas / 18
 - 2.3. Užduotis / 22
3. Dalijimo pusiau metodu skaičiuotas patikimumas / 22
 - 3.1. Aprašymas ir skaičiavimas / 22
 - 3.2. Dalijimo pusiau metodu nustatyto patikimumo skaičiavimas / 22
 - 3.3. Užduotis / 24
4. Vertintojų sutariamumas / 24
 - 4.1. Aprašymas / 24
 - 4.2. Vertintojų sutariamumo skaičiavimas / 24
 - 4.3. Užduotis / 28
5. Patikimumo aprašymas / 29

2 s k y r i u s

Validumas / 30

1. Konstrukto validumas / 30
2. Kriterinis validumas / 31
3. Turinio validumas / 32
4. Kitos validumo rūšys / 32

5. Validumo skaičiavimas / 33

5.1. Tiriamoji faktorių analizė / 33

- 5.1.1. Tyrimo klausimai faktorių analizei / 34
- 5.1.2. Duomenų tinkamumas tiriamajai faktorių analizei / 34
- 5.1.3. Faktorių išskyrimas ir sukimas / 42
- 5.1.4. Tiriamosios faktorių analizės atlikimas / 44
- 5.1.5. Tiriamosios faktorių analizės rezultatai / 46
- 5.1.6. Tiriamosios faktorių analizės, kai nustatomas norimas faktorių skaičius, atlikimas / 49
- 5.1.7. Tiriamosios faktorių analizės, kai nustatomas norimas faktorių skaičius, rezultatai / 51
- 5.1.8. Tiriamosios faktorių analizės, turint kelių priemonių kintamuosius, atlikimas / 53
- 5.1.9. Tiriamosios faktorių analizės, turint kelių priemonių kintamuosius, rezultatai / 53
- 5.1.10. Tiriamosios faktorių analizės atlikimas atskiroms grupėms / 55
- 5.1.11. Tiriamosios faktorių analizės atskirų grupių rezultatai / 57
- 5.1.12. Faktorių reikšmių išsaugojimas kaip kintamųjų / 57
- 5.1.13. Galimas tiriamosios faktorių analizės aprašymas / 59
- 5.1.14. Užduotis / 60

5.2. Patvirtinamoji faktorių analizė / 61

- 5.2.1. Duomenų tinkamumas patvirtinamajai faktorių analizei / 61
- 5.2.2. Struktūrinių lygčių programos / 62
- 5.2.3. Modelio vaizdavimas / 62
- 5.2.4. Modelio identifikavimas / 65
- 5.2.5. Modelio parametrų įvertinimas / 66
- 5.2.6. Modelio tinkamumas / 67

- 5.2.6. Matavimų kintamųjų skaičius / 69
- 5.2.7. Dviejų modelių lyginimas / 70
- 5.2.8. Modelio modifikavimas / 71
- 5.2.9. Patvirtinamosios faktorių analizės atlikimas, naudojantis AMOS programa / 72
- 5.2.10. Patvirtinamosios faktorių analizės, naudojantis AMOS programa, rezultatai / 81
- 5.2.11. Modelio, naudojantis AMOS programa, modifikavimas / 84
- 5.2.12. Modelio, naudojantis AMOS programa, modifikavimo rezultatai / 88
- 5.2.13. Modelio, naudojantis AMOS programa, papildymas / 90
- 5.2.14. Modelio, naudojantis AMOS programa, papildymo rezultatai / 93
- 5.2.15. Modelio, naudojantis AMOS programa, lyginimas tarp grupių / 95
- 5.2.16. Modelio, naudojantis AMOS programa, lyginimo tarp grupių rezultatai / 100
- 5.2.17. Patvirtinamosios faktorių analizės atlikimas, naudojantis „Mplus“ programa / 105
- 5.2.18. Patvirtinamosios faktorių analizės, naudojantis „Mplus“ programa, rezultatai / 116
- 5.2.19. Modelio, naudojantis „Mplus“ programa, modifikavimas / 121
- 5.2.20. Modelio, naudojantis „Mplus“ programa, modifikavimo rezultatai / 122
- 5.2.21. Modelio, naudojantis „Mplus“ programa, papildymas / 123
- 5.2.22. Modelio, naudojantis „Mplus“ programa, papildymo rezultatai / 125
- 5.2.23. Modelio, naudojantis „Mplus“ programa, lyginimas tarp grupių / 131
- 5.2.24. Modelio, naudojantis „Mplus“ programa, lyginimo tarp grupių rezultatai / 132
- 5.2.25. Galimas patvirtinamosios faktorių analizės aprašymas / 138
- 5.2.26. Užduotis / 141

Literatūra / 142

„Visi modeliai yra klaidingi,
bet kai kurie yra naudingi.“

G. E. P. BOX, 1976

Rašant kursinius ar mokslinius darbus, jei buvo atliekamas tyrimas, visada yra aprašomos tyrimo metu naudotos matavimo priemonės. Aprašant šias priemones yra svarbu pateikti informaciją apie jų patikimumą (angl. *reliability*), labai dažnai ir validumą (angl. *validity*). Taip skaitytojui parodoma, kad galima pasitikėti gautais tyrimo rezultatais, nes naudojamos patikimos ir validžios priemonės. Priemonių patikimumas ir validumas dažnai ir nurodomas metodikų aprašymo dalyje. Jei darbo tikslas būtų kurti, standartizuoti ar adaptuoti priemonę, tai patikimumas ir validumas galėtų būti nagrinėjami ir aprašomi pateikiant tyrimo rezultatus. Patikimumas ir validumas yra du atskiri, tačiau susiję vienas su kitu rodikliai.

Patikimumas

Patikimumas dažniausiai įvardijamas kaip priemonių kokybės kriterijus – matavimų tikslumas, stabilumas (Meidus, 2004). Priemonės patikimumas taip pat pasako, koks jos pastovumas. Literatūroje pateikiama įvairių patikimumo rūšių, tačiau gana retai jos visos pristatomos tame pačiame moksliniame darbe. Dažniausiai psichologijos moksliniuose darbuose aprašomi vidinis suderintumas (angl. *internal consistency*), pakartotinių testavimų patvirtintas patikimumas (angl. *test-retest reliability*), dalijimo pusiau metodu skaičiuotas patikimumas (angl. *split-half reliability*) ir vertintojų sutariamumas (angl. *inter-rated reliability*). Labai dažnai moksliniuose darbuose pateikiamas tik naudotų priemonių vidinis suderintumas. Rečiau, bet kartais reikia pateikti ir kitus skaičiavimus. Tai priklauso nuo naudojamų priemonių, tyrimo atlikimo ir darbo tikslų.

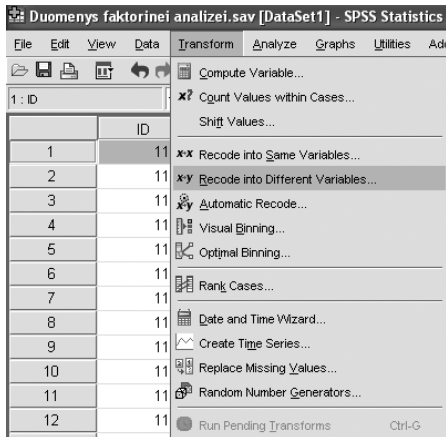
1. Vidinis suderintumas

1.1. Aprašymas

Vidinis suderintumas turi būti pristatomas, kai iš kelių kintamųjų žadama sudaryti vieną naują rodiklį, kintamąjį, pavyzdžiui, skaičiuojamas 10 pasitikėjimo savimi skalės klausimų vidutinis balas, kuris vėliau ir bus naudojamas analizuojant, o atskiri klausimai nenaudojami. Pristatomas skalių, klausimynų, subtestų, subskalių ar kintamųjų grupių, bet ne vieno kintamojo vidinis suderintumas. Esant vienam kintamajam vidinio suderintumo neįmanoma apskaičiuoti, nes šis suderintumas paremtas koreliacijomis tarp kintamųjų. Vidinis suderintumas pristatomas kaip Cronbacho alfa (angl. *Cronbach's alpha*) koeficientas. Cronbacho alfa išreiškiama skaičiumi. Dažnai rašoma: Cronbacho α = skaičius. Vidinis suderintumas turėtų būti nuo 0 iki 1. Jei Cronbacho alfa siekia 0,60, tai tinka tyrimams. Tačiau dažnai norima, kad Cronbacho alfa būtų 0,70 ar daugiau, kad skalę ar klausimų grupę būtų galima laikyti suderinta (Aiken, 2002). Sutariama, kad Cronbacho alfa tinkamumas priklauso ir nuo to, kokie sprendimai bus daromi ta priemone. Pavyzdžiui, jei ji bus naudojama

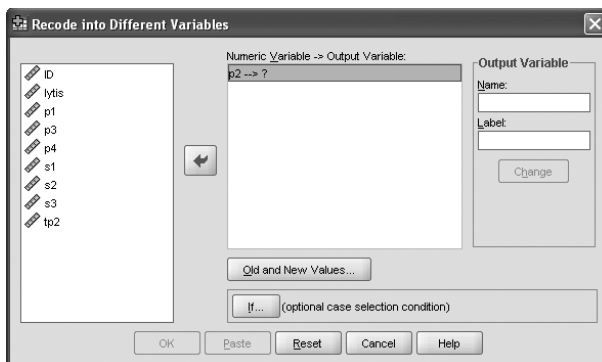
diagnostiniais tikslais, tai vidinis suderintumas turėtų būti geras. Moksliniuose darbuose gerai, kai Chronbacho alfa yra didesnė nei 0,70.

Vidinis suderintumas gali būti ir nuo 0 iki -1, tačiau tokios Chronbacho alfos negalima skelbti ir būtina peržiūrėti naudojamą priemonę. Jei vidinis suderintumas neigiamas arba labai mažas teigiamas dydis, gali būti, kad klausimai nesuderinti tarpusavyje arba vieni klausimai yra apie vienus aspektus, o kiti apie kitus ir jų nevertetų sudėti kartu. Taip pat gali būti, kad kai kurie kintamieji liko neperkoduoti, t. y. neapversti atsakymo variantai, kitaip tariant, vienu metu buvo įtraukti skirtingų polių arba susiję neigiamais ryšiais klausimai (jų koreliacijos koeficientas neigiamas). Norint šiuos klausimus analizuoti kartu, kai kurie jų turi būti apversti, perkoduoti (angl. *recoded*), tai yra jų atsakymo variantai turi būti atvirkštiniai, kad koreliacijos tarp kintamųjų būtų teigiamos. Dažnai naudojant kitų sudarytas skales ar klausimynus, būna nurodyta, kurie klausimai turėtų būti perkoduoti. Perkodavimas atliekamas SPSS programa (*Transform – Recode into different variables*) (1 pav.). Paspaudus



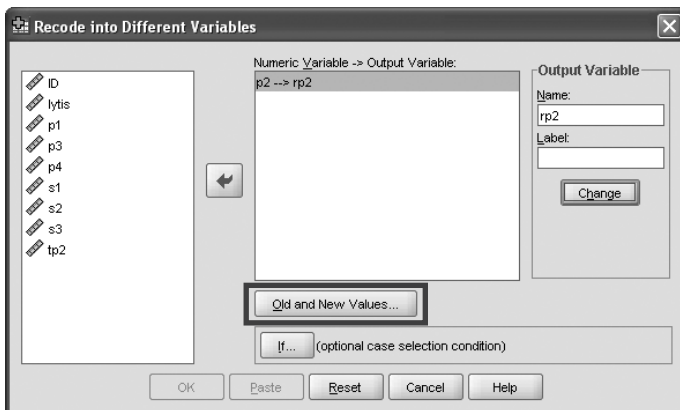
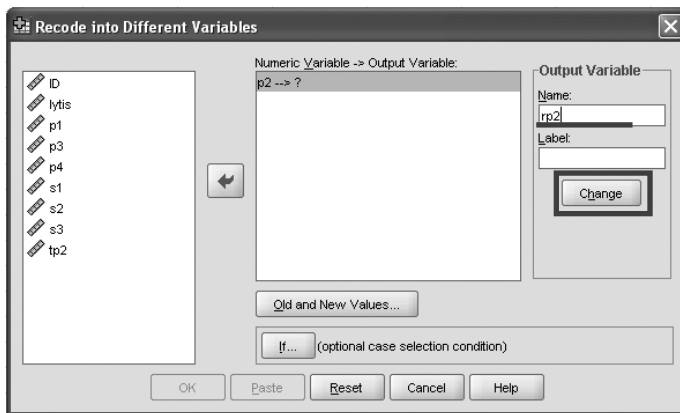
šią nuorodą, atsidaro lentelė, kurioje nurodome, kuri kintamąjį perkoduosime (pvz., p2). Jį ir perkeliame į kintamojo langelį (angl. *numeric variable*). Tuomet prie kintamojo atsiranda klaustukas.

Prie išvesties kintamojo (angl. *output variable*) reikia nurodyti naujojo kintamojo vardą (pvz., rp2) ir paspausti mygtuką „Keisti“ (angl. *change*) (2 pav.). Kintamojo langelyje matome, kad p2 pakeičiamas į rp2. Taip duomenų



rinkmenoje išlaikysime abu šios kintamuosius, vieną tokį, koks buvo, o kitą – perkoduotą. Visuomet geriau duomenų rinkmenoje išsaugoti abu kintamuosius – neperkoduotą ir perkoduotą. Tuomet spaudžiamas mygtukas „Senos ir naujos reikšmės“ (angl. *old and new values*) (2 pav.).

1 pav. Kintamųjų perkodavimo funkcija

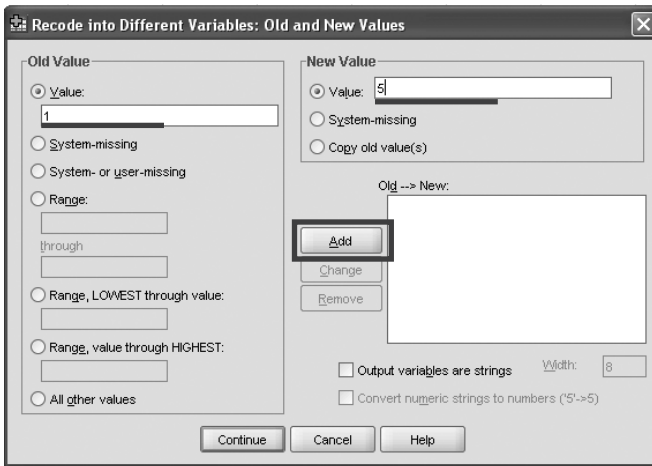


2 pav. Kintamųjų reikšmių pakeitimas

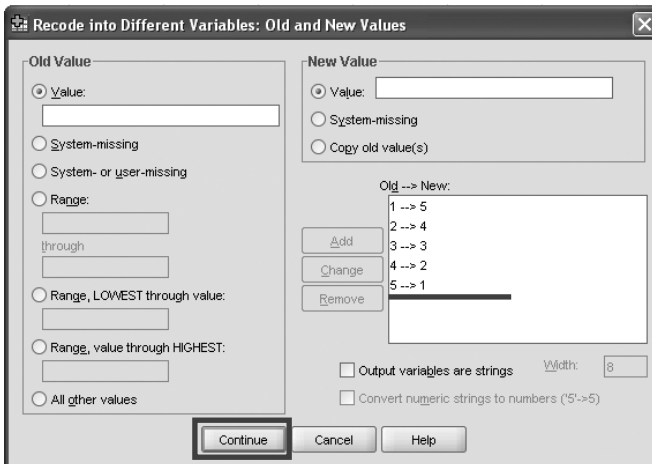
Atsidarius naujai lentelei, prie senų reikšmių (angl. *old value*) reikšmių lange lyje nurodome vieną iš kintamojo reikšmių, tarkime, 1 (3 pav.). O naujų reikšmių pusėje (angl. *new value*) įrašome naują reikšmę, kurią norime suteikti. Jei kintamojo matavimų skalė yra nuo 1 iki 5, vadinasi, vienetas turi atitikti penketą. Tokiu atveju įrašome 5 naujų reikšmių pusėje ir spaudžiame mygtuką „Pridėti“ (angl. *add*).

Taip padaroma su visomis likusiomis reikšmėmis (dvejetas turi būti perkoduotas į ketvertą, trejetas į trejetą, ketvertas į dvejetą, o penketas į vienetą) (4 pav.). Turi būti perkoduotos visos kintamojo reikšmės. Tuomet spaudžiamas mygtukas „Tęsti“ (angl. *continue*) ir pagrindiniame lange OK. Duomenų rinkmenoje paskutiniame stulpelyje bus įrašytas naujas perkoduotas kintamasis.

Kintamuosius perkoduoti būtina (jei tik taip reikia daryti), nes kartais jų neperkoduavę galime gauti net ir neigiamą Cronbacho alfa, o to tikrai negalima skelbti. Tad svarbu nusimanyti apie savo kintamuosius ir žinoti, ar nereikia jų perkoduoti.



3 pav. Senos ir naujos kintamojo reikšmės įrašymas

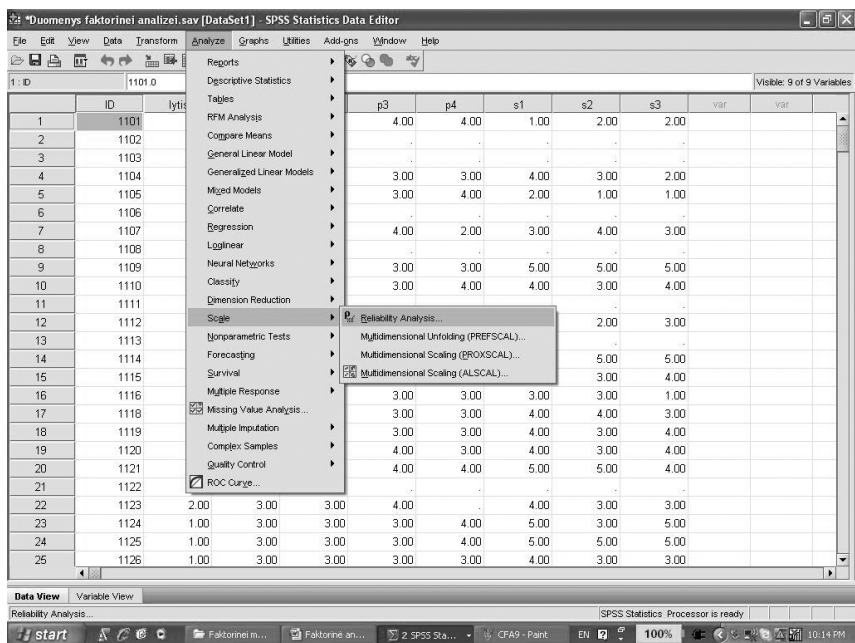


4 pav. Visų senų ir naujų kintamojo reikšmių perkodavimas

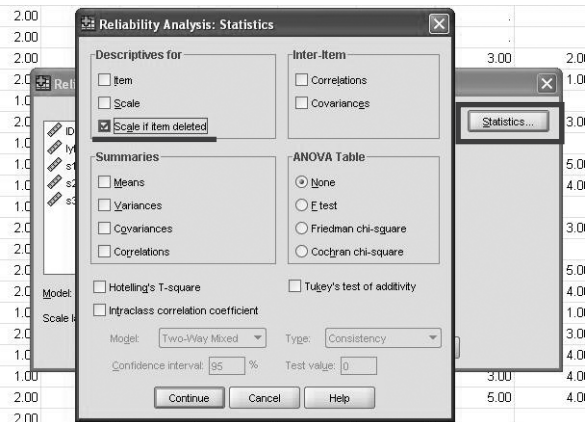
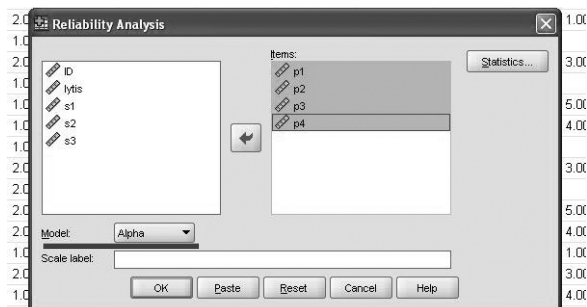
1.2. Vidinio suderintumo skaičiavimas

Vidinio suderintumo skaičiavimas yra SPSS programos dalis (*Analyze – Scale – Reliability analysis*) (5 pav.).

Paspaudus nuorodą atsidaro patikimumo analizės lentelė. Į kintamųjų (angl. *items*) langelį reikia sukelti visus kintamuosius, kurie bus naudojami tai analizei ir kuriuos ketinama sujungti į vieną kintamąjį (6 pav.). Tarkim, norime patikrinti, ar kintamieji p1, p2, p3 ir p4 (tai yra pasitikėjimo savimi klausimai) yra tarpusavyje suderinti, nes juos būtų galima sujungti į vieną pasitikėjimo savimi skalę.



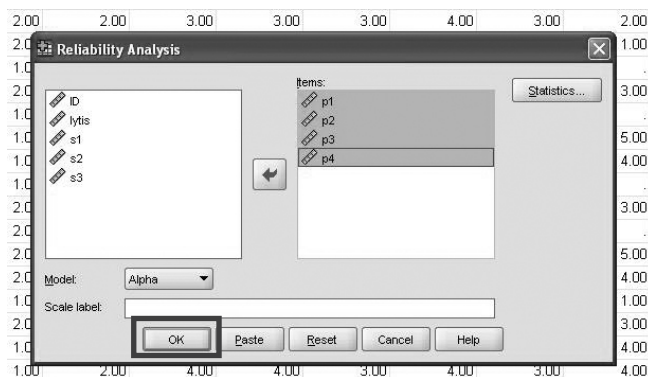
5 pav. Vidinio suderintumo skaičiavimo funkcija



6 pav. Vidinio suderintumo skaičiavimas

Įprastai jau programoje būna nurodyta, kad bus skaičiuojama Cronbacho alfa (mygtukas *model*). Paspaudus mygtuką „Statistika“ (angl. *statistics*), atsidaro naujas langas, kuriame varnele reikėtų pažymėti skalės, jei kintamasis ištrintas, funkciją (angl. *scale if item deleted*). Tai leistų įvertinti atskirus klausimus ir galimą jų problemiškuumą. Pasirinkus spaudžiama nuoroda „Tęsti“.

Tada spaudžiamas mygtukas OK (7 pav.) ir duomenų išvesties lange (angl. *output*), kuriame pateikti atliktos analizės rezultatai, galima juos nagrinėti.



7 pav. Vidinio suderintumo skaičiavimo užbaigimas

Pirmiausia duomenų išvesties lange pateikiama, kiek tiriamųjų duomenų buvo įtraukta į analizę (angl. *valid*), kiek jų turi praleistas bent vieno iš šių kintamųjų reikšmes ir neįtraukti į analizę (angl. *excluded*) ir kiek iš viso yra tiriamųjų rinkmenose (angl. *total*) (8 pav.). Tada kitoje lentelėje yra pateikiama Cronbacho alfa (šiam pavyzdyje Cronbacho $\alpha = 0,712$). Cronbacho alfa apskaičiuoti buvo naudojami keturių kintamųjų duomenys, kurie nurodomi stulpelyje „Kintamųjų skaičius“ (angl. *N of items*). Cronbacho alfa yra didesnė nei 0,70; tad galima teigti, kad šią keturių klausimų grupę, iš kurios žadama sudaryti pasitikėjimo savimi skalę, galima laikyti suderinta.

Case Processing Summary				Reliability Statistics	
Cases	Valid	322	87.7	Cronbach's Alpha	N of Items
	Excluded ^a	45	12.3	.712	4
	Total	367	100.0		

a. Listwise deletion based on all variables in the procedure.

8 pav. Cronbacho alfa koeficientas duomenų išvesties lange

Item-Total Statistics				
	Scale Mean if Item Deleted	Scale Variance if Item Deleted	Corrected Item-Total Correlation	Cronbach's Alpha if Item Deleted
p1	9.4161	2.169	.442	.686
p2	9.2826	2.166	.523	.637
p3	9.1894	2.092	.499	.650
p4	9.1366	2.118	.537	.627

9 pav. Bendros kintamųjų statistikos lentelė

Bendros kintamųjų statistikos (angl. *item-total statistics*) lentelė rodo, kaip gali pasikeisti Cronbacho alfa pašalinus iš analizės vieną ar kitą kintamąjį (9 pav.). Tarkime, neįtraukus p1 kintamojo, likusių trijų kintamųjų (p2–p4) vidinis suderintumas sumažėtų iki 0,686. Tai matyti iš paskutinio stulpelio – Cronbacho alfa, jei kintamasis pašalintas (angl. *Cronbach's alpha if item deleted*). Kiti stulpeliai rodo skalės vidurkio, dispersijos ar koreliacijų pakitimus, jei tas kintamasis nebūtų įtrauktas į analizę. Nagrinėjamu atveju Cronbacho alfa sumažėtų, iš analizės pašalinus bet kurį kintamąjį. Tad to daryti nėra prasmės. Bet jei Cronbacho alfa smarkiai padidėtų (pvz., nuo 0,60 iki 0,80), tuomet galima svarstyti tam tikro kintamojo neįtraukimą sujungiant kintamuosius. Tačiau visuomet reikia pagalvoti, ar įmanoma pagrįsti kintamojo neįtraukimą teoriškai, ypač turint verstas ir kitų autorių sudarytas skales ar priemones. Vidinį suderintumą savo darbuose visada galime palyginti su kitų autorių (jei kas nors jau naudojo tą priemonę) pristatomu suderintumu, tačiau nereikėtų pateikti vien kitų autorių rezultatų ir nepristatyti savo tyrimo imtyje gauto vidinio suderintumo. Visuomet svarbu darbuose pristatyti vidinį suderintumą, apskaičiuotą naudojant surinktus duomenis. Jei atliekami eksperimentai, stebėjimai, kokybiniai tyrimai ir nesujungiami kintamieji, tai vidinis suderintumas paprastai nėra pristatomas.

1.3. Užduotis

Visų užduočių duomenų rinkmena, jos aprašymas ir atsakymai yra pateikti Vilmantės Pakalniškienės puslapyje (www.fsf.vu.lt, prie Bendrosios psichologijos katedros). Koks yra kintamųjų, kurie sudarytų prieraišumo prie mamos skalę ir prieraišumo prie tėčio skalę, Chronbacho alfa?

2. Pakartotinių testavimų patvirtintas patikimumas

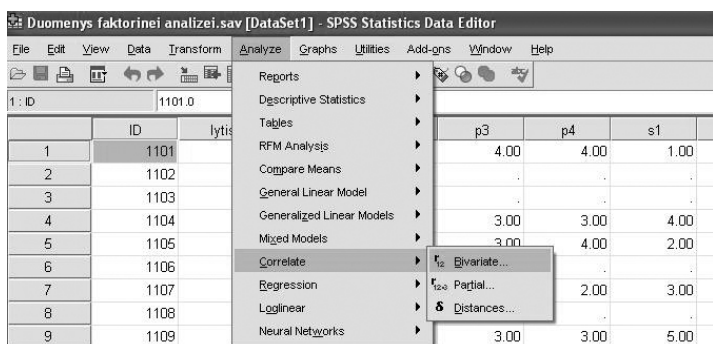
2.1. Aprašymas

Pakartotinių testavimų patvirtintas patikimumas skaičiuojamas tada, kai tai pačiai imčiai, tiems patiems tiriamiesiems ta pati priemonė ar klausimai pateikiami bent du kartus skirtingu laiku. Tarkime, pasitikėjimo savimi skalę savo tiriamųjų

paprašėme užpildyti mokslo metų pradžioje ir praėjus trims mėnesiams. Daroma prielaida, kad tarp skirtingų matavimų neturėtų būti matuojamo konstrukto pasikeitimų. Tai tarsi konstrukto stabilumo matavimas laikui bėgant. Savaiame suprantama, kad ilgas laiko tarpas tarp matavimų (pvz., 10 metų) gali konstruktus pakeisti ir tokiu atveju nebus galima rasti jų ryšio. Tačiau jei laiko tarpas tarp matavimų yra trumpas, ryšys gali būti labai stiprus.

2.2. Pakartotinių testavimų patvirtinto patikimumo skaičiavimas

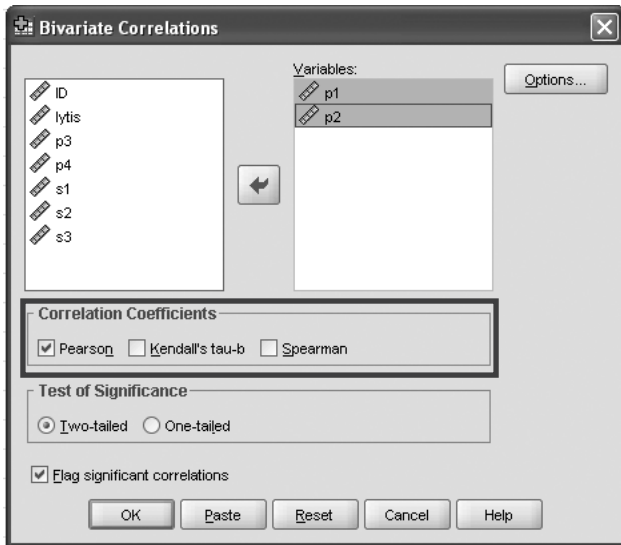
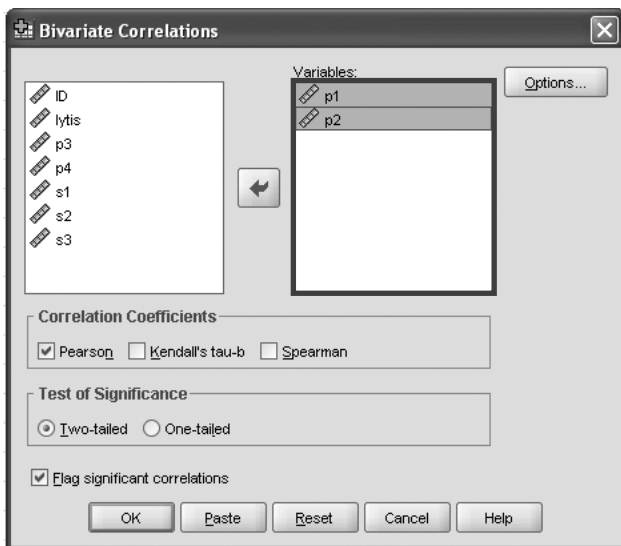
Labai dažnai pristatant šį patikimumą skaičiuojamas vidinis suderintumas pirmu ir antru matavimu ir jie lyginami tarpusavyje. Taip pat skaičiuojamos ir koreliacijos tarp dviejų matavimų. Koreliacijas galima apskaičiuoti naudojant SPSS programą (*Analyze – Correlate – Bivariate*) (10 pav.).



10 pav. Koreliacijų skaičiavimo funkcija

Paspaudus nuorodą, atsidaro naujas langas. Į kintamųjų langelį sukeliame tuos kintamuosius (natūralu, kad jie turi būti dviejų skirtingų matavimų), tarp kurių koreliaciją norime apskaičiuoti (11 pav.). Tarkime, kintamasis p1 būtų pirmu matavimu, o p2 – antru matavimu naudotas tas pats klausimas ir norime įvertinti ryšį tarp jų.

Iš koreliacijos koeficientų (angl. *correlation coefficients*) reikia pasirinkti Pirsono (*Pearson*) arba Spirmeno (*Spearman*) koreliacijos koeficientą (11 pav.). Vieno ar kito koreliacijos koeficiento pasirinkimas priklauso nuo turimų kintamųjų. Jei kintamieji normaliai pasiskirstę, taikome Pirsono koreliaciją, jei duomenys nėra normaliai pasiskirstę, yra ranginiai ar jų mažai (mažiau nei 20 stebėjimų) – Spirmeno koreliaciją. Pasirinkę koeficientą ir paspaudę OK, SPSS programos duomenų išvesties lange matome koreliacijos tarp tikrinamų kintamųjų (tarp p1 ir p2) lentelę (12 pav.). Koreliacijos koeficientai gali būti nuo -1 iki 1 . Kuo arčiau vieneto, tuo didesnis yra



11 pav. Koreliacijos tarp dviejų skirtingų matavimų skaičiavimas

koreliacijos koeficientas. Jei koeficientas yra teigiamas, vadinasi, kintamieji susiję teigiamu ryšiu, tai yra, didėjant vieno kintamojo reikšmėms, didėja ir kito kintamojo reikšmės. Jei kintamieji susiję neigiamu ryšiu (koreliacijos koeficiento reikšmė neigiama), didėjant vienam kintamajam, kitas kintamasis mažėja. Koreliacinės lentelės įstrižainėje visuomet yra vienetai, nes pats kintamasis yra tapatus sau (pvz., p1 tapatus p1), tai ir koreliacijos koeficientas bus vienetas. Koreliacijos koeficientai yra

→ Correlations				→ Correlations			
[DataSet1] D:\Faktorine\Duomenys faktorinei				[DataSet1] D:\Faktorine\Duomenys faktorinei			
Correlations				Correlations			
		p1	p2			p1	p2
p1	Pearson Correlation	1	.351**	p1	Pearson Correlation	1	.351**
	Sig. (2-tailed)		.000		Sig. (2-tailed)		.000
	N	331	327		N	331	327
p2	Pearson Correlation	.351**	1	p2	Pearson Correlation	.351**	1
	Sig. (2-tailed)	.000			Sig. (2-tailed)	.000	
	N	327	327		N	327	327

** Correlation is significant at the 0.01 level (2-tailed).

12 pav. Koreliacijos tarp dviejų skirtingų matavimų rezultatai

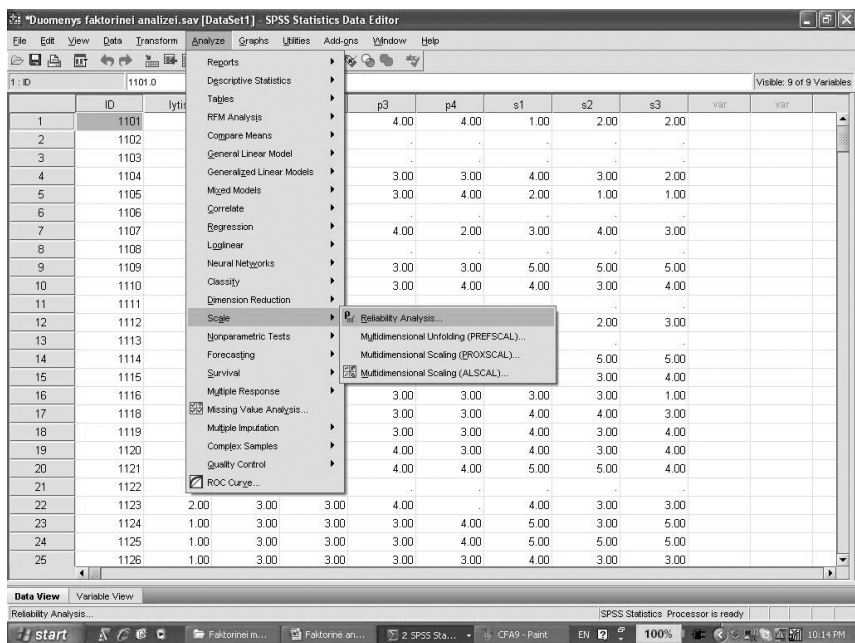
pirmoje kiekvieno langelio eilutėje (pvz., pažymėtas koreliacijos koeficientas tarp p1 ir p2 yra 0,351). Antra langelio eilutė parodo p reikšmę (reikšmingumo lygmenį). Jei p reikšmė yra $< 0,05$, tai šių kintamųjų koreliacijos koeficientas yra statistiškai reikšmingas, nors pats jis gali būti ir nedidelis.

Paskutinė langelio eilutė (N) rodo, kelių tiriamųjų duomenys buvo įtraukti į šio koreliacijos koeficiento skaičiavimą. Šiame pavyzdyje yra panaudoti 327 tiriamųjų duomenys. Koreliacija tarp pirmo ir antro matavimo kintamųjų yra statistiškai reikšminga, nors vidutinė. Vadinasi, konstruktas tik iš dalies išlieka stabilus. Kalbant apie konstrukto stabilumą laikui bėgant, norėtusi tvirtesnių korelacijų, bent jau daugiau kaip 0,60–0,70 (Pallant, 2003).

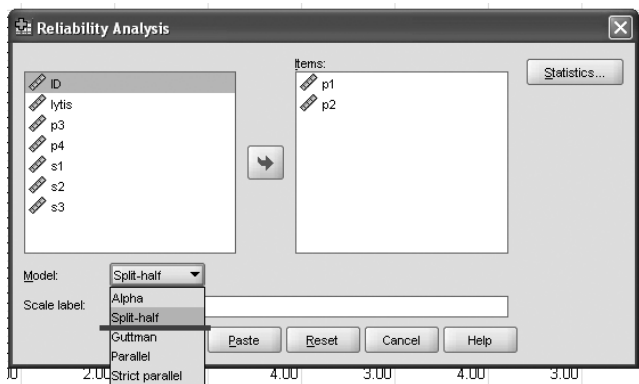
Kartais skaičiuojant pakartotinių testavimų patvirtintą patikimumą pristatomas Spirmeno ir Brauno koeficientas (*Spearman–Brown*). Šis koeficientas dažnai nurodomas pristatant lygiagrečių formų patikimumą. Spirmeno ir Brauno koeficiento skaičiavimas yra SPSS programos dalis (*Analyze – Scale – Reliability analysis*) (13 pav.).

Paspaudus nuorodą atsidaro patikimumo analizės lentelė. Į kintamųjų langelį sukeliama visi kintamieji, kurie bus naudojami tai analizei. Tarkim, norime patikrinti konstrukto stabilumą, kuris buvo vertintas p1 ir p2 kintamaisiais dviem skirtingais matavimais. Standartiškai jau programoje būna nurodyta, kad bus skaičiuojama Cronbacho alfa (mygtukas *model*), bet reikia taikyti padalijimo pusiau metodą (angl. *split half*) (14 pav.).

Tada spaudžiame mygtuką OK ir duomenų išvesties lange galime nagrinėti rezultatus. Spirmeno ir Brauno koeficientas yra lentelės apačioje. Matome, kad pirma ir antra dalis (šiuo atveju pirmas ir antras matavimai) turi po vieną kintamąjį (jie yra



13 pav. Spirmeno ir Brauno koeficiento skaičiavimas



14 pav. Dalijimo pusiau metodo pasirinkimas

nurodyti lentelės apačioje). Literatūroje rašoma, kad Spirmeno ir Brauno koeficiento dydis 0,80 rodo adekvatų priemonės konstrukto stabilumą, o 0,90 – gerą testo konstrukto stabilumą (Kaplan and Saccuzzo, 2001). Kartais tinka ir reikšmė 0,60, ypač kai taikomi dar kuriami metodai (Brace et al., 2006). Pateiktame pavyzdyje koeficientas yra nedidelis – 0,520 (15 pav.). Tai rodo, kad konstruktas nėra stabilus. 15 pav. taip pat pateikiama koreliacija tarp kintamųjų, gauta skaičiuojant ($r = 0,351$).

Reliability Statistics			
Cronbach's Alpha	Part 1	Value	1.000
		N of Items	1 ^a
	Part 2	Value	1.000
		N of Items	1 ^b
		Total N of Items	2
	Correlation Between Forms	.351	
Spearman-Brown Coefficient		Equal Length	.520
		Unequal Length	.520
		Guttman Split-Half Coefficient	.518

a. The items are: p1
b. The items are: p2

15 pav. Spirmeno ir Brauno koeficientas duomenų išvesties lange

2.3. Užduotis

Tyrimo metu vaikai du kartus (mokslo metų pradžioje ir mokslo metų pabaigoje) atsakė į kelis klausimus apie naudojimosi internetu namuose taisyklės. Įvertinkite, koks pakartotinių testavimų patvirtintas patikimumas (tai1 ir tai2 kintamųjų)?

3. Dalijimo pusiau metodu skaičiuotas patikimumas

3.1. Aprašymas ir skaičiavimas

Dalijimo pusiau metodu skaičiuotas patikimumas kartais dar vadinamas lygiagrečių formų patikimumu. Dažnai tikrinamos labai panašios kintamųjų, klausimų grupės, kurios matuoja tą patį konstruktą ir yra paimitos iš panašaus ar to paties klausimyno arba vienas testas turi dvi lygiagrečias formas.

3.2. Dalijimo pusiau metodu nustatyto patikimumo skaičiavimas

Tuomet yra skaičiuojami keli koeficientai: kiekvienos dalies Cronbacho alfa koeficientai, Spirmeno ir Brauno arba Gatmano koeficientas (angl. *Guttman split-half coefficient*) ir koreliacijos tarp dalių. Spirmeno ir Brauno arba Gatmano koeficientų skaičiavimas yra SPSS programos dalis (14 pav.). Paspaudus nuorodą atsidaro patikimumo analizės lentelė. Į kintamųjų langelį reikia sukelti visus kintamuosius, kurie bus naudojami tai analizei (p1–p4). O tada, paspaudę mygtuką OK, galite nagrinėti rezultatus duomenų išvesties lange.

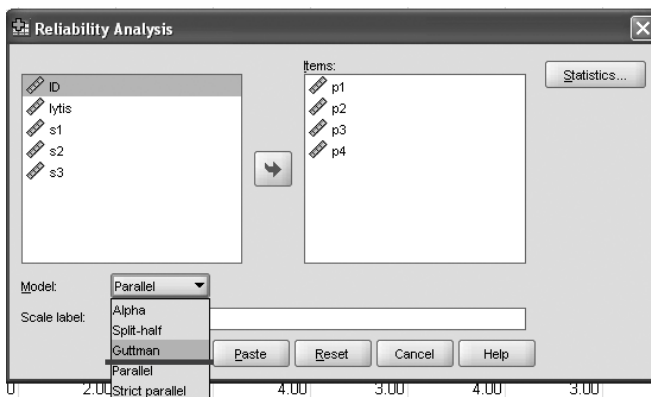
Reliability Statistics			
Cronbach's Alpha	Part 1	Value	.521
		N of Items	2 ^a
	Part 2	Value	.594
		N of Items	2 ^b
		Total N of Items	4
Spearman-Brown Coefficient	Correlation Between Forms		.548
	Equal Length		.708
	Unequal Length		.708
	Guttman Split-Half Coefficient		.708

a. The items are: p1, p2.
b. The items are: p3, p4.

16 pav. Kintamųjų p1–p4 Spirmeno ir Brauno koeficientas duomenų išvesties lange

Spirmeno ir Brauno koeficientas yra lentelės apačioje. Taip pat matyti, kad pirma ir antra dalis turi jau po du kintamuosius (jie yra nurodyti apačioje) (16 pav.). Pateiktame pavyzdyje Spirmeno ir Brauno koeficientas yra 0,708. Tad koeficiento dydis rodo, kad visa skalė nėra bloga, tačiau šiek tiek trūksta iki labai gero patikimumo. Jei Spirmeno ir Brauno koeficientas yra didelis, tai visa skalė, testas yra patikimi ir tada galima manyti, kad atskiros formos ar dalys yra susijusios ir todėl galima būtų naudoti vieną iš jų arba abi, bet skirtingais matavimais. Čia taip pat pateikiama ir koreliacija tarp atskirų dalių kintamųjų.

Gatmano koeficiento skaičiavimas yra SPSS programos dalis (*Analyze – Scale – Reliability analysis*). Šis koeficientas nereikalauja tapačių dispersijų tarp dviejų formų ar dalių. Tai tarsi Spirmeno ir Brauno koeficiento modifikacija. Paspaudus nuorodą „Patikimumo analizė“, atsidaro lentelė. Į jos kintamųjų langelį reikia sukelti kintamuosius, kurie bus naudojami analizei (p1–p4) (17 pav.).



17 pav. Gatmano koeficiento pasirinkimo funkcija

Renkantis modelį reikia spausti „Gatmano koeficientas“ (17 pav.), mygtuką OK ir nagrinėti rezultatus duomenų išvesties lange (18 pav.). Pateikiami šeši koeficientai. Ketvirtas iš jų ir yra Gatmano koeficientas. Jo interpretacija yra tokia pat kaip Spirmeno ir Brauno koeficiento. Šiame pavyzdyje gautas patikimumas rodo, kad visa skalė nėra bloga, tačiau šiek tiek trūksta iki labai gero patikimumo.

Lambda	1	.534
	2	.714
	3	.712
	4	.708
	5	.695
	6	.657
N of Items		4

18 pav. Gatmano koeficientas duomenų išvesties lange

3.3. Užduotis

Tyrimo metu vaikai atsakė į klausimus apie naudojimosi internetu namuose taisykles. Vaikai skundėsi, kad klausimai panašūs ir jų galėtų būti mažiau. Ar galima 10 klausimų apie taisykles padalyti į dvi dalis ir vieno matavimo metu naudoti tik vieną jų?

4. Vertintojų sutariamumas

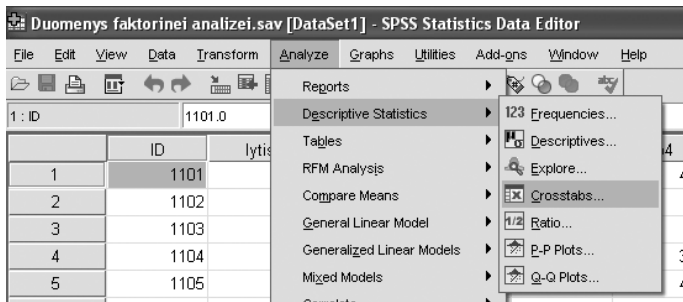
4.1. Aprašymas

Vertintojų sutariamumas – tai dviejų ar daugiau asmenų sutariamumas. Tarkime, du asmenys atlieka tyrimą vaikų darželyje ir prašo vaikų įvertinti siužetą, kurį parodė. Abu asmenys vertina vaikų pasisakymus pagal tam tikrą skalę, nematydami vienas kito vertinimų. Baigus tyrimą svarbu žinoti, kaip abu asmenys vertino ir koks jų sutariamumas. Jei vienas asmuo pirmo vaiko pasisakymą vertina kaip neigiamą, o kitas – kaip teigiamą, tai asmenys nesutaria. Sutariamumui vertinti yra svarbus išankstinis tyrėjų apmokymas ar aiškių vertinimo kriterijų sudarymas.

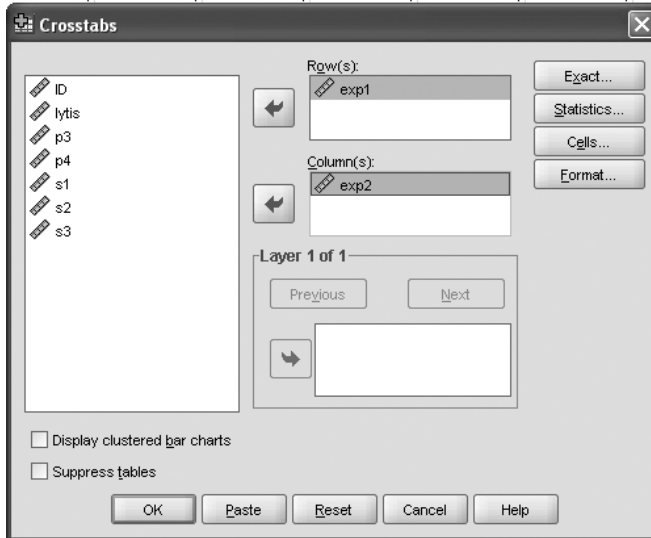
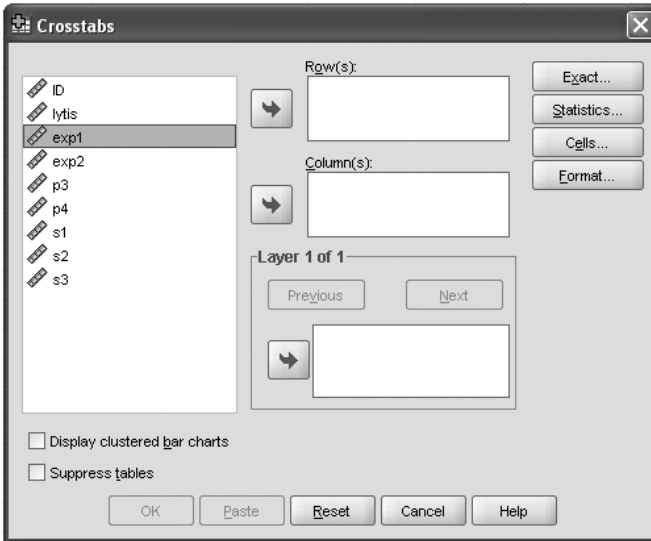
4.2. Vertintojų sutariamumo skaičiavimas

Dviejų vertintojų sutariamumui nustatyti skaičiuojamas Koheno kapos matas (angl. *Cohen's kappa*). Koheno kapa gali būti nuo 0 iki 1. Kuo ji didesnė, tuo didesnis patikimumas. Kapai artėjant prie nulio, tyrėjų sutariamumas mažėja. Koheno kapą galima rasti naudojant SPSS programą (*Analyze – Descriptive statistics – Crosstabs*) (19 pav.).

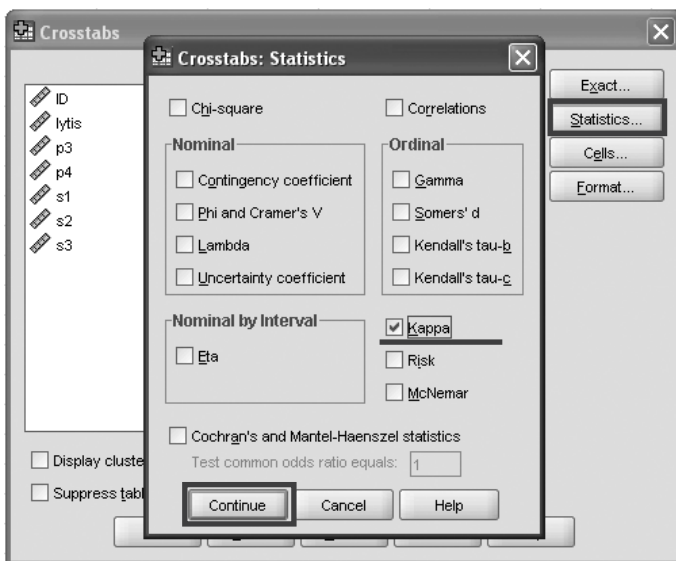
Atsidarius naujai lentelei, į eilučių (angl. *row(s)*) ir stulpelių (angl. *column(s)*) langelius įkeliami pirmo ir antro vertintojo duomenys (kintamieji) (20 pav.).



19 pav. Koheno kapos funkcija



20 pav. Vertintųjų duomenų nurodymas



21 pav. Koheno kapos koeficiento pažymėjimas

Paspaudus mygtuką „Statistika“, atsidaro nauja lentelė, kurioje reikia pažymėti kapos koeficientą ir spausti mygtuką „Tęsti“ (21 pav.), o pagrindiniame lange – mygtuką OK.

Duomenų išvesties lange lentelėje pristatomas vertintojų sutarimas. Iš jos matyti, kad yra atvejų, kai abu vertintojai sutaria (22 pav.). Pavyzdžiui, ir vienas, ir kitas 150 atvejų vertina trejetu. Tačiau net 41 atveju pirmas vertintojas vertino trejetu, o antras – ketvertu.

Count		exp2				Total
		1.00	2.00	3.00	4.00	
exp1	1.00	3	3	2	0	8
	2.00	1	16	35	7	59
	3.00	0	17	150	41	208
	4.00	0	2	33	17	52
Total		4	38	220	65	327

22 pav. Vertintojų sutariamumas duomenų išvesties lange

Iš kitos lentelės matyti, koks yra sutarimo koeficientas (23 pav.). Šiame pavyzdyje sutarimo koeficientas tik 0,169. Kapa rodo, kiek abu vertintojai sutaria tarpusavyje, bet nenurodo jokių priežasčių, dėl ko jie nesutaria. Autoriai pristato skirtingas

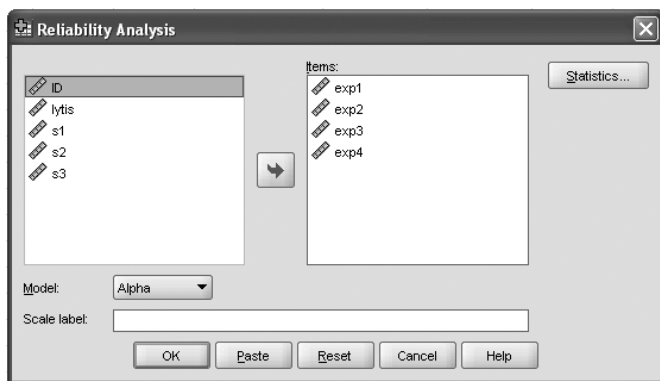
Symmetric Measures					
		Value	Asymp. Std. Error ^a	Approx. T ^b	Approx. Sig.
Measure of Agreement	Kappa	.169	.047	4.341	.000
N of Valid Cases		327			

a. Not assuming the null hypothesis.
b. Using the asymptotic standard error assuming the null hypothesis.

23 pav. Koheno kapos koeficientas duomenų išvesties lange

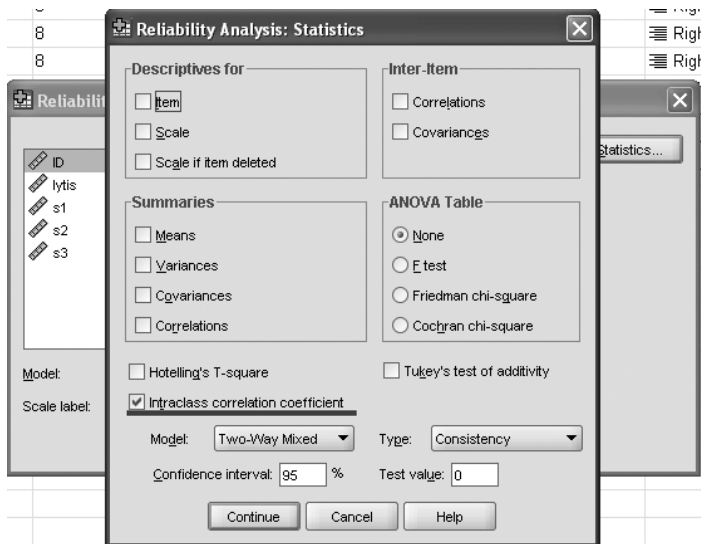
šio koeficiento gaires. Jei kapa yra 0,40–0,60, tai sutarimas vidutinis, jei 0,61–0,80 – pakankamas, o jei 0,81–1,00 – beveik idealus (Landis and Koch, 1977). Bet vėl viskas priklauso nuo to, koks tyrimas ir kas vertinama. Šiame pavyzdyje nėra jokio vertintojų sutarimo.

Jei vertintojų ne vienas (trys ar daugiau), dažnai yra skaičiuojamas Fleiso kapos koeficientas (angl. *Fleiss' kappa*), tačiau, naudojant SPSS programą, norint gauti šį koeficientą, reikėtų rašyti sintaksę arba pasinaudoti internete esančiais skaičiuotuvais. Jei duomenys intervaliniai ir norime pažiūrėti, koks vertintojų (dviejų ir daugiau) sutarimas, naudojame intraklasines koreliacijas arba ICC (angl. *intra-class correlation*). Šių koreliacijų skaičiavimas yra SPSS programos dalis (*Analyze – Scale – Reliability analysis*). Paspaudus nuorodą atsidaro patikimumo analizės lentelė. Į kintamųjų langelį sukeliama visų vertintojų duomenys (24 pav.). Renkantis modelius paliekama Cronbacho alfa.



24 pav. Keturių vertintojų duomenys, sukelti į kintamųjų langelį

Paspaudus dešinėje mygtuką „Statistika“, atsidaro nauja lentelė, kurioje reikia pažymėti intraklasines koreliacijas ir spausti mygtuką „Tęsti“, o pagrindiniame lange – mygtuką OK (25 pav.).



25 pav. Intraklasinės koreliacijos koeficiento pažymėjimas

Duomenų išvesties lange matome lentelę, kurioje ir pateikiama koreliacija, parodanti vertintojų sutarimą. Šios koreliacijos interpretacija panaši kaip ir kapos koeficiento. Jei 0,40–0,60, tai sutarimas vidutinis, jei 0,61–0,80 – pakankamas, o jei 0,81–1,00 – beveik idealus (Shrout and Fleiss, 1979). Šiame pavyzdyje vertintojų sutarimas yra 0,382 (26 pav.). Tai nėra tinkamas sutarimas. Galime daryti išvadą, kad vertintojai skirtingai vertina matuojamus reiškinius.

Intraclass Correlation Coefficient							
	Intraclass Correlation ^a	95% Confidence Interval		F Test with True Value 0			
		Lower Bound	Upper Bound	Value	df1	df2	Sig.
Single Measures	.382 ^b	.324	.442	3.476	321	963	.000
Average Measures	.712 ^c	.657	.760	3.476	321	963	.000

26 pav. Intraklasinės koreliacijos koeficientas duomenų išvesties lange

Intraklasinės koreliacijos kartais skaičiuojamos ir turint pakartotinę matavimą ir norint įvertinti pakartotinių testavimų patvirtintą patikimumą.

4.3. Užduotis

Tyrimo metu vaikai buvo vertinami, kiek įsitraukia į veiklą internete, kai duodama tam tikra užduotis. Juos vertino du tyrėjai. Ar sutampa abiejų tyrėjų vertinimai?

5. Patikimumo aprašymas

Aprašydami tyrimo metodus, pristatome moksliniame tyrime naudotas įvertinimo priemones (pvz., skales, klausimynus, testus). Jei naudotas klausimynas ar instrumentas turi keletą skalių, visada galime pristatyti Cronbacho alfas lentelėje. O jei skaičiuojame tik vieną Cronbacho alfą visam klausimynui ar skalei, tai pristatome tekste. Kada verta skaičiuoti vieną Cronbacho alfą visam klausimynui, o kada kelias atskiroms klausimyno skalėms, jei klausimynas tokių turi? Tai priklauso nuo tyrimo idėjos ir tyrimo klausimų. Jei tyrėjui rūpi globalesnis konstruktas, tai dažnai ir pristatoma viena Cronbacho alfa ir analizėms naudojamas vienas toks konstruktas. Jei svarbūs ir įvairūs konstrukto aspektai, tai pateikiamos ir atskirų skalių Cronbacho alfos.

Pavyzdžiui: „Klausimyną sudaro 20 klausimų (nurodome, apie ką jie), tie klausimai vertinami 5 lygių skale (nuo 1 – visiškai nesutinku iki 5 – visiškai sutinku). Viso klausimyno Cronbacho $\alpha = 0,893$.“

Arba: „Klausimyną sudaro 20 klausimų (nurodome, apie ką jie), tie klausimai vertinami 5 lygių skale (nuo 1 – visiškai nesutinku iki 5 – visiškai sutinku). Viso klausimyno Cronbacho $\alpha = 0,893$. Šiame klausimyne pateikti klausimai sudaro tris atskiras skales. Atskirų skalių patikimumas ir klausimų skaičius pristatomas x lentelėje.“

x lentelė. Klausimyno (pavadinimas) skalių patikimumas

Skalė	Cronbacho α	Teiginių skaičius skalėje	Teiginių pavyzdys
A skalė	0,798	4
B skalė	0,897	5	...
C skalė	0,764	11	...

Validumas

Validumas dažnai pateikiamas kaip metodikų kokybės kriterijus – jų tinkamumas, adekvatumas (Meidus, 2004). Dažniausiai literatūroje yra minimos kelios validumo rūšys: konstrukto, turinio ar kriterijaus, nors validumo rūšių yra ir daugiau. Literatūroje pateikiama įvairių validumo rūšių, tačiau moksliniuose darbuose dažniausiai pasitaiko viena ar kelios, tai vėlgi priklauso nuo metodikos ir darbo tikslo. Validumas nurodo, ar metodika matuoja tai, ką ketinta ja matuoti. Jei metodikai trūksta validumo, negalima visiškai pasitikėti gautais rezultatais.

1. Konstrukto validumas

Konstrukto validumas (angl. *construct validity*) yra viena dažniausiai pristatomų validumo rūšių. Jis rodo, ar pasirinkta metodika matuoja konkretų konstrukta. Konstrukto validumas ir atsako į klausimą, ar testas, skalė, metodika matuoja tai, kas numatyta. Siekiama teorinio konstrukto ir pasirinktos metodikos panašumo. Konstrukto validumui užtikrinti taikomi įvairūs metodai. Labai dažnai moksliniuose darbuose vertinant konstrukto validumą pateikiama tiriamoji ir / arba patvirtinamoji faktorių analizė, kuri padeda įvertinti konstrukto struktūrą, tinkamiausią jos modelį, ryšius tarp konstrukto kintamųjų. Gali būti pateikiamas ekspertinis vertinimas, nurodantis, kaip turimi kintamieji atspindi norimą teorinį konstrukta. Tai dažniau pasitaiko kuriant naujas metodikas. Arba gali būti pateikiamas ryšys su tyrimo metu naudojamomis panašiomis priemonėmis, šis ryšys vertinamas ir sprendžiama, ar metodikoje reikia ką nors keisti. Tokiam lyginimui naudojamos jau patikrintos priemonės. Taip pat gali būti taikoma eksperimentinė tyrimo strategija, kai turima eksperimentinė ir kontrolinė grupės ir bandoma vertinti konstrukta ar atskirus kintamuosius grupių tyrimo metu. Yra skiriamas konvergentinis (angl. *convergent*) ir diskriminantinis (angl. *discriminant*) konstrukto validumas. Šios validumo rūšys nurodo, kad buvo ieškoma ryšių tarp pateiktos metodikos ir į ją labai panašių (matuojančių tapatų konstrukta) ar priešingų (matuojančių visiškai priešingą konstrukta)

tą) metodikų. Tarkime, turima metodika, kuri vertina matematikos pasiekimus, ir kartu tirama panaši metodika, kuri vertina dalykus, kuriems reikia matematikos žinių ir tam tikro pasiekimų lygio. Tai būtų konvergentinis validumas. Turint metodikas, kuriomis matuojami skirtingi konstruktai, pavyzdžiui, matematikos ir sporto pasiekimai, intraversija ir ekstraversija, būtų diskriminantinis validumas. Konstruktai gali sietis, bet jie turėtų būti priešingi. Konvergentinis ir diskriminantinis validumas dažnai pristatomas koreliacijos koeficientais.

2. Kriterinis validumas

Kriterinis validumas (angl. *criterion validity*) nurodo, kiek taikomos metodikos rezultatai atitinka tiriamą elgesį ar savybę. Labai dažnai turimas išorinis objektyvus kriterijus ir, naudojant tam tikrą priemonę, yra lyginami tiriamųjų pateikti duomenys su objektyviu kriterijumi. Pavyzdžiui, tiriamieji atsakinėjo apie balsavimą, o mes turime objektyvius balsavimo rezultatus. Objektyvūs kriterijai gali būti patys įvairiausi, žiūrint, koks darbo tikslas, pavyzdžiui, pažymiai, atliktų užduočių skaičius, pardavimų skaičius, ekspertų vertinimai ir pan. Labai dažnai, kalbant apie kriterinį validumą, nustatomas diagnostinis arba laike sutampantis (angl. *concurrent*) ir prognostinis (angl. *predictive*) validumas. Šie validumai paremti realiais matavimais ar kriterijais, bet ne ryšiais su kitomis metodikomis. Diagnostinis validumas parodo metodikos gebėjimą atskirti grupes, kurias teoriškai turėtų atskirti. Tarkime, sukurta priemonė, kuri vertina depresijos simptomus, vadinasi, ši priemonė turėtų gebėti atskirti žmones, turinčius šių simptomų, nuo žmonių, turinčių kitam sutrikimui būdingų simptomų. Kuriant naują priemonę dažnai ir bandoma nustatyti, ar vienos grupės rezultatai skiriasi nuo kitos, grupės lyginamos tarpusavyje. Jei tikslas yra sukurti ar adaptuoti diagnostinę priemonę, šį validumą reikėtų pristatyti. Diagnostinis validumas dažnai išreiškiamas koreliacijos koeficientu arba nurodomas chi kvadratas.

Prognostinis validumas rodo, ar priemonė pajėgi nuspėti, ką teoriškai turėtų nuspėti, t. y., ar naudojant priemonę padarytos išvados po kurio laiko pasitvirtins. Parodomas ryšys tarp įvertinimo, gauto naudojantis instrumentu, ir būsimos veiklos. Tarkime, teoriškai galima manyti, jog geri vaiko matematikos gebėjimai rodo, kad jam gerai seksis mokytis tikslųjų mokslų reikalaujančių specialybių. Tuomet žiūrima, koks yra vaiko matematikos pasiekimų, kurie vertinami sukurtu instrumentu, ir tikslųjų mokslų specialybių studijų rezultatų ryšys. Prognostinis validumas dažnai išreiškiamas koreliacijos arba regresijos koeficientu.

3. Turinio validumas

Turinio validumas parodo, ar tikrai tai, ką matuojame, galime vadinti tam tikru konstruktu, ar naudojama priemonė atspindi visus to konstrukto aspektus ir prasnę. Šis validumo rūšis dažna aprašant žinių, pasiekimų, gebėjimų vertinimo priemones. Bet šis validumas svarbus ir vertinant atskirus konstruktus, pavyzdžiui, demokratiją, ir bandant sudaryti jos matavimo metodiką. Validumas dažnai vertinamas ekspertiniu būdu – vertinamas turinio validumas. Ekspertų prašoma nurodyti, kiek kiekvienas kintamasis atitinka matuojamos srities specifiką.

4. Kitos validumo rūšys

Čia aprašomos validumo rūšys nėra vienintelės, bet jos dažniausiai pateikiamos pristatant metodikas. Kartais yra aprašomas išorinis validumas (angl. *face validity*), kuris nurodo, kiek instrumentas priimtinas tiriamiesiems, gal kas – instrukcijos, klausimai – buvo neaiškūs. Dažnai tai susiję su metodikos priimtinumu, kiek iš pirmo žvilgsnio priemonė atrodo validi. Kartais galima pastebėti pagerėjimo (angl. *incremental validity*) validumą, kuris padeda nustatyti, ar priemonė teikia reikšmingą indėlį, naudojama kartu su kitomis metodikomis. Pavyzdžiui, ar naudojant vertinimo priemonę gaunami geresni tam tikri rezultatai (sakykime, žmogus pateikia daugiau duomenų apie savo priklausomybę), kai atliekamas interviu, ar geriau priemonės nenaudoti ir atlikti tik interviu, nes rezultatai būtų panašūs (pvz., žmogus tiek pat papasakotų apie savo priklausomybę). Tai validumas, kuris gali nurodyti, kada geriau naudoti priemonę. Aprašant šį validumą, dažnai pristatomi regresijos koeficientai.

Pristatant įvertinimo priemones, svarbu atsižvelgti į tai, kaip kiti tyrėjai, kurie naudojami ta pačia įvertinimo priemone, pristato validumo informaciją. Gerai yra peržvelgti publikacijas, kuriose aprašomos panašios priemonės. Dažnai darbuose net neįvardijama validumo rūšis ir tiesiog pateikiamos koreliacijos su objektyviais kriterijais ar kitomis priemonėmis arba pateikiama tiriamoji ir / ar patvirtinamoji faktorių analizė. Metodikų patikimumą reikėtų skaičiuoti visada, o validumo kartais galima ir nevertinti. Jei kiti tyrėjai metodiką jau yra išvertę, gal net standartizavo arba taikė tapačiai imčiai (tai svarbi sąlyga), validumo galima ir nepateikti. Tačiau jei kitų autorių pristatytos imties ypatybės bent kiek skiriasi, net jei metodika versta, adaptuota, reikia patikrinti savo imties validumą ir galima atlikti tiriamąją ar patvirtinamąją faktorių analizę. Studentai dėl naudojamos priemonės validumo pateikimo turėtų pasitarti su savo dėstytojais. Be reikalo nėra ko pristatyti visų validumo rūšių

vien todėl, kad jas žinome, o tik tas, kurios būtinos ir siejasi su atliekamu tyrimu ar gautais duomenimis. Taip pat nereikėtų atlikti tos pačios imties tiriamosios ir patvirtinamosios faktorių analizės, kurios vertinant konstrukto validumą dažnai pateikiamos tuo pačiu metu. Jas siūloma atlikti skirtingų imčių, tai gali būti bandomojo tyrimo ir pagrindinio tyrimo imtis, arba naudotis ankstesniuose tyrimuose atlikta tiriamąja faktorių analize ir pristatyti tik patvirtinamąją faktorių analizę (Tabachnik and Fidell, 2006). Ne visada reikia pristatyti ir abiejų šių faktorių analizių rezultatus. Kuo tiriamoji ir patvirtinamoji faktorių analizė skiriasi, į kokius klausimus gali atsakyti ir kaip jas atlikti?

5. Validumo skaičiavimas

Faktorių analizė yra statistinis metodas, labai dažnai taikomas analizuojant tiek socialinių, tiek kitų mokslų tyrimų metu surinktus duomenis ir vertinant priemonės validumą. Šis metodas, kaip nurodo SPSS programa, yra skirtas kintamųjų kiekiui sumažinti (angl. *data reduction*). Juo apdorojamas didesnis kintamųjų kiekis ir ieškoma būdo, kaip atskirus kintamuosius sugrupuoti į tam tikrus komponentus, konstruktus (t. y. faktorius). Tad faktorių analizė padeda surasti mažiausią skaičių konstruktų, t. y. faktorių, kurie tyrimo metu tiesiogiai nematuojami, bet nustatomi naudojantis tyrimo metu surinktais duomenimis. Pavyzdžiui, tyrimo metu verbalinis ir konstrukcinis intelektas tiesiogiai nevertinamas, tiriamieji tik atlieka įvairias užduotis ar atsako į įvairius klausimus, kurie atspindi šiuos konstruktus, ir tik tai tiesiogiai matuojama. Tokie kintamieji dar vadinami latentiniais. Faktorių analizė dažniausiai yra naudojama įvertinti naudojamų ar sudaromų skalių, klausimynų, metodikų validumą (Carmines and Zeller, 1979).

5.1. Tiriamoji faktorių analizė

Yra dvi faktorių analizės rūšys – tiriamoji ir patvirtinamoji. Naudojant tiriamąją faktorių analizę (angl. *exploratory factor analysis*) galima surasti tam tikrus apdorojamų duomenų konstruktus. Šis metodas dažniausiai taikomas pasitelkus SPSS ar kitus programinius paketus. Analizuojant kintamuosius, šiuo metodu bandoma surasti kuo mažesnę latentinių faktorių skaičių, tai yra panašius kintamuosius sugrupuoti į atskirus faktorius. Šis metodas dažnai pasitelkiamas turint pradinius tyrimų duomenis ar bandomojo tyrimo duomenis, kai dar tik numatomi atskirų kintamųjų ryšiai ir juos norima įvertinti.

5.1.1. Tyrimo klausimai faktorių analizei

Labai dažnai norime žinoti, į kokius klausimus galime atsakyti, taikydami vieną ar kitą statistinį metodą. Faktorių analizė leidžia sužinoti, kiek konstruktų ir kokius juos gali sudaryti turimi kintamieji; kiek konstruktų / faktorių gali būti vienoje ar kitoje naudojamoje skalėje ar klausimyne; ar naudojamos skalės konstruktai / faktoriai atitinka ankstesniuose tyrimuose, naudojantis šia skale, išskirtus konstruktus. Faktorių analizė atsako į klausimus, susijusius su taikomos metodikos, skalės ar klausimyno struktūra.

5.1.2. Duomenų tinkamumas tiriamajai faktorių analizei

Faktorių analizei tinka ne visi duomenys. Tad, prieš atliekant tokią analizę, būtina duomenis įvertinti. Yra svarbūs keli duomenų vertinimo aspektai.

Imties dydis. Būtina įvertinti turimos imties dydį. Nuo to priklauso faktorių analizės rezultatai. Autoriai diskutuoja dėl tinkamo faktorių analizei imties dydžio, kol kas nesutariama, kokią imtį, t. y., kiek tiriamųjų, reikia turėti norint atlikti tokią analizę. Dažnai rašoma, kad imtis turi būti didelė, kuo didesnė, tuo geriau. Faktoriai, išskirti tiriant mažas imtis, gali būti mažiau patikimi ar skirtis nuo tiriant didesnes imtis išskirtų faktorių. Tai nereiškia, kad turint mažą imtį negalima atlikti faktorių analizės. Tik ją atliekant reikia atsargiai interpretuoti gautus rezultatus ir ieškoti patvirtinimo analizuojant kitų imčių rezultatus. Pastaruoju metu literatūroje teigiama, kad imties dydis turi būti proporcingas kintamųjų, naudosimų faktorių analizės metu, skaičiui. J. C. Nunnally (1978) rekomenduojama proporcija – 10:1, tai reiškia, kad turi būti bent 10 tiriamųjų kiekvienam kintamajam, kurie bus naudojami faktorių analizei. Kiti autoriai (Tabachnick and Fidell, 1996) pateikia proporciją 5:1, bent penki tiriamieji kiekvienam kintamajam. Pavyzdžiui, atliekant 20 kintamųjų faktorių analizę (juos vienu metu sudėjus į faktorių analizę), reikėtų turėti bent $20 \times 5 = 100$ žmonių ar objektų imtyje. Yra autorių (Kline, 1994), kurie pateikia ir mažesnes proporcijas ir siūlo turėti bent 2:1, tai yra du tiriamieji kiekvienam faktorių analizės kintamajam. Tačiau dauguma autorių sutaria, kad kuo daugiau kintamųjų vienu metu naudojama faktorių analizei, tuo daugiau žmonių turėtų būti imtyje. Kaip minėta, faktorių analizę galima atlikti ir kai žmonių skaičius mažesnis (proporcija mažiau nei 5:1), tačiau tuomet reikia atsargiai interpretuoti gautus rezultatus.

Ryšiai tarp kintamųjų. Kitas aspektas – ryšiai (koreliacijos) tarp kintamųjų, kurie bus naudojami faktorių analizei. Ryšius tarp kintamųjų galima tikrinti prieš atliekant faktorių analizę arba ją atlikti netikrinus, nes ją atliekant skaičiuojami rodi-

kliai, kurie ir parodo, ar duomenys tinkami faktorių analizei. Tarpusavyje nesusijusių kintamųjų faktorių analizė nėra tikslinga. B. G. Tabachnick ir L. S. Fidell (1996) rašo, kad vieno faktoriaus kintamieji turėtų būti susiję, tai yra koreliacijos tarp jų turėtų būti 0,30 ir daugiau. Tačiau jei koreliacijos koeficientai didesni negu 0,80, tai irgi gali būti problemiška. Tuomet reikėtų pasirinkti vieną iš kintamųjų, tarp kurių yra tokia tvirta koreliacija, ir tik jį naudoti faktorių analizės metu, o ne abu kartu. Prieš atliekant faktorių analizę SPSS programa (*Analyze – Correlate – Bivariate*), visada galima pasitikrinti ryšius tarp kintamųjų (žr. 10 pav.). Paspaudus nuorodą atsidaro naujas langas ir į kintamųjų langelį sukeliama tie kintamieji, kurie bus naudojami faktorių analizei (11 ir 12 pav.) ir kurie, mūsų manymu, turėtų sudaryti vieną faktorių, sakydame, manome, kad kintamieji p1–p4 gali sudaryti pasitikėjimo savimi konstrukta / faktorių, tai juos ir sukeliame į langelį. SPSS programos duomenų išvesties lange matyti koreliacijos tarp tikrinamų kintamųjų (p1–p4) lentelė (27 pav.).

→ **Correlations**

[DataSet1] D:\Duomenys faktorinei analizei.sav

		p1	p2	p3	p4
p1	Pearson Correlation	1	.351**	.275**	.408**
	Sig. (2-tailed)		.000	.000	.000
	N	331	327	330	326
p2	Pearson Correlation	.351**	1	.445**	.392**
	Sig. (2-tailed)	.000		.000	.000
	N	327	327	326	322
p3	Pearson Correlation	.275**	.445**	1	.421**
	Sig. (2-tailed)	.000	.000		.000
	N	330	326	330	326
p4	Pearson Correlation	.408**	.392**	.421**	1
	Sig. (2-tailed)	.000	.000	.000	
	N	326	322	326	326

** . Correlation is significant at the 0.01 level (2-tailed).

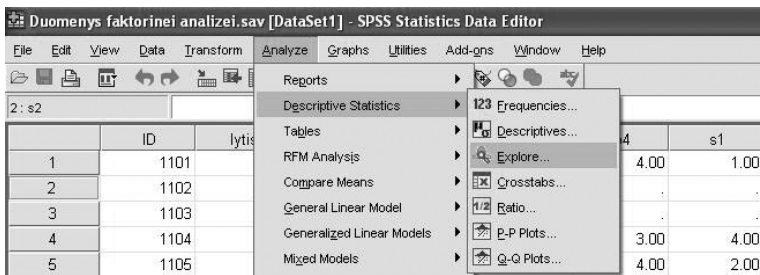
27 pav. Koreliacijos koeficientai tarp p1–p4 kintamųjų

Koreliacijos koeficientai yra pirmoje kiekvieno langelio eilutėje (pvz., pažymėtas koreliacijos koeficientas tarp p1 ir p2 yra 0,351). Antra langelio eilutė rodo p reikšmę (reikšmingumo lygmenį). Jei ši p reikšmė yra < 0,05, vadinasi, koreliacijos koeficientas tarp šių kintamųjų statistiškai reikšmingas. Paskutinė langelio eilutė (N) rodo tiriamųjų skaičių, tai yra kelių tiriamųjų duomenys buvo įtraukti į šio koreliacijos koeficiento skaičiavimą. Šiame pavyzdyje N (tiriamųjų skaičius) svyruoja nuo 322 iki 330, nes ne visi tiriamieji atsakė į visus klausimus, tarp kurių koreliacijos skaičiuojamos. Pateiktoje lentelėje tarp p1–p4 kintamųjų (kurie gali sudaryti vieną faktorių) koreliacijos koeficientai svyruoja nuo 0,28 iki 0,45. Mažiausias koreliaci-

jos koeficientas yra tarp p_1 ir p_3 ($r = 0,28$), tačiau jis labai arti siūlomos ribos 0,30. Visos koreliacijos tarp kintamųjų yra statistškai reikšmingos. Tad visi kintamieji, klausimai yra susiję ir juos galima naudoti faktorių analizei. Jei būtų kintamųjų, kurie nesusiję vienas su kitu arba visi kintamieji nesusiję tarpusavyje, faktorių analizė nebūtų naudinga.

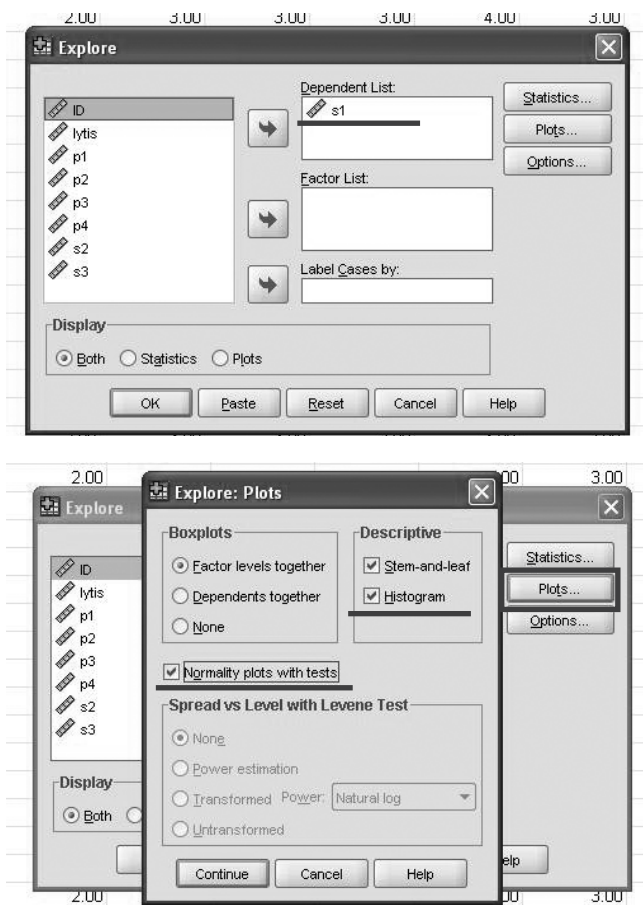
Kaip minėta, prieš atliekant faktorių analizę galima ir nežiūrėti, kokios koreliacijos, kokie ryšiai tarp kintamųjų, nes SPSS programa, atliekant šią analizę, pateikia koeficientus, kurie ir leidžia spręsti, ar duomenys jai tinka. Bartleto sferiškumo testas arba kriterijus (angl. *Bartlett's test of sphericity*) parodo, ar tarp kintamųjų yra statistškai reikšmingos koreliacijos, o Kaizerio, Mejerio ir Olkino matas arba KMO (angl. *Keiser-Meyer-Olkin measure*) – ar kintamųjų porų koreliacijos yra paaiškinamos kitais kintamaisiais. Tinkamos faktorių analizės, tai yra kai duomenys tinka tokiai analizei, Bartleto sferiškumo testas turėtų būti reikšmingas (reikšmingumo lygmuo $p < 0,05$), o KMO koeficientas (jis gali būti tarp 0 ir 1) turėtų būti 0,6 ir daugiau, jei KMO mažiau nei 0,5, tai duomenys faktorių analizei nėra tinkami (Tabachnick and Fidell, 1996).

Duomenų pasiskirstymas ir linijiniai ryšiai. Faktorių analizė yra pritaikyta duomenims, kurie pasiskirstę normaliai. Taip pat svarbu, kad kintamieji būtų susiję linijiniais ryšiais (padarius dviejų kintamųjų reikšmių išklotinę, naudojantis x ir y ašimis, per šias reikšmes galima nubrėžti tiesią liniją). Linijiniai ryšiai yra svarbūs daugumai statistinių metodų. Kintamųjų duomenų normalumas, kaip ir kiti aspektai, gali būti tikrinamas SPSS programa (*Analyze – Descriptive statistics – Explore*) (28 pav.).



28 pav. Duomenų pasiskirstymo tikrinimas

Paspaudus nuorodą atsidaro naujas langas, kuriame į priklausomųjų kintamųjų (angl. *dependent list*) langelį įkeliame kintamąjį ar kelis kintamuosius, kurių pasiskirstymą ir kitus rodiklius norime matyti. Paspaudus nuorodą „Išklotinė“ (angl.



29 pav. Duomenų pasiskirstymo funkcijų pasirinkimas

plots), atsirado naujas langas, kuriame, be jau pažymėtų dalykų, galime nurodyti histogramą (angl. *histogram*) ir duomenų normalumo testą (angl. *normality plots with tests*), tuomet spaudžiame nuorodą „Tęsti“ ir pagrindiniame lange OK (29 pav.).

Duomenų išvesties lange pirmiausia pateikiama aprašomosios statistikos lentelė (30 pav.). Joje įrašytas kintamojo vidurkis (angl. *mean*); vidurkio 95 proc. pasikliautinio intervalo reikšmės (angl. *95 % confidence interval for mean*), kurios nurodo intervalą, kuriame, tikėtina, ir yra vidurkis; 5 proc. nupjautasis vidurkis (angl. *5 % trimmed mean*), kuris parodo, koks yra vidurkis, kai atmetami tiriamieji, kurie papuola į normalumo kreivės galus ir gali turėti ekstremalias reikšmes; mediana (angl. *median*); dispersija (angl. *variance*); standartinis nuokrypis (angl. *std. deviation*); didžiausia ir mažiausia kintamojo reikšmė (angl. *minimum, maximum*); duomenų aibės plotis (angl.

Descriptives				
			Statistic	Std. Error
s1	Mean		4.0987	.06736
	95% Confidence Interval for Mean	Lower Bound	3.9662	
		Upper Bound	4.2313	
	5% Trimmed Mean		4.2208	
	Median		5.0000	
	Variance		1.425	
	Std. Deviation		1.19362	
	Minimum		1.00	
	Maximum		5.00	
	Range		4.00	
	Interquartile Range		2.00	
	Skewness		-1.190	.138
	Kurtosis		.359	.274

30 pav. Aprašomosios statistikos lentelė duomenų išvesties lange


range); kvartilų skirtumas (angl. *interquartile range*); asimetriškumo koeficientas (angl. *skewness*), kuris, esant normaliam pasiskirstymui, būna apie 0,03 (šis koeficientas turėtų versti susirūpinti normaliu kintamojo pasiskirstymu, jei jis didesnis negu 0,7 (0,8) ar mažesnis negu -0,7 (-0,8)) (kai kur pateikiamos ribos nuo 0,5 ir -0,5), tad šiame pavyzdyje šis koeficientas rodo, kad duomenys nėra normaliai pasiskirstę (Pallant, 2003), nes peržengia galimą ribą; eksceso koeficientas (angl. *kurtosis*), esant normaliam pasiskirstymui jis yra 0.

Šapiro ir Vilko (angl. *Shapiro-Wilk*) bei Kolmogorovo ir Smirnovo (angl. *Kolmogorov-Smirnov*) testai, kurie pristatyti lentelėje 31 pav., tikrina duomenų normalumą (parodo, ar nulinė hipotezė, kuri teigia, kad kintamasis normalus, gali būti atmesta, ar ne). Jei šių testų reikšmingumo lygmuo $p < 0,05$, tai duomenys nėra normaliai pasiskirstę (hipotezė, kad duomenys normaliai pasiskirstę, atmetama). Jei šių testų reikšmingumo lygmuo $p > 0,05$, tai duomenys normaliai pasiskirstę. Šiuo atveju galima sakyti, kad s1 kintamasis nėra normaliai pasiskirstęs. Abu testai taikytini, vieni dažniau pristato Kolmogorovo ir Smirnovo, o kiti – Šapiro ir Vilko testą, tik Šapiro ir Vilko testas patikimesnis, kai tiriamųjų skaičius imtyje < 50 .

Tests of Normality						
	Kolmogorov-Smirnov ^a			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
s1	.310	314	.000	.752	314	.000

a. Lilliefors Significance Correction

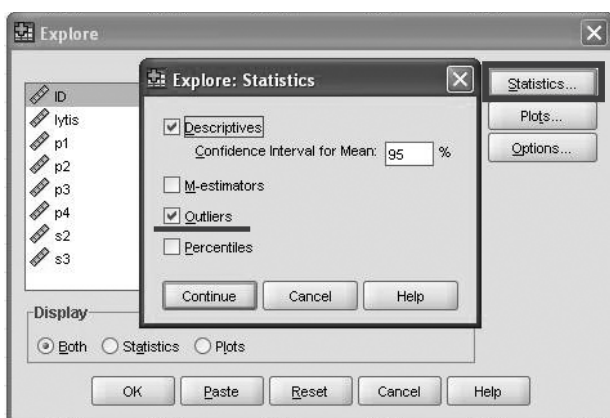
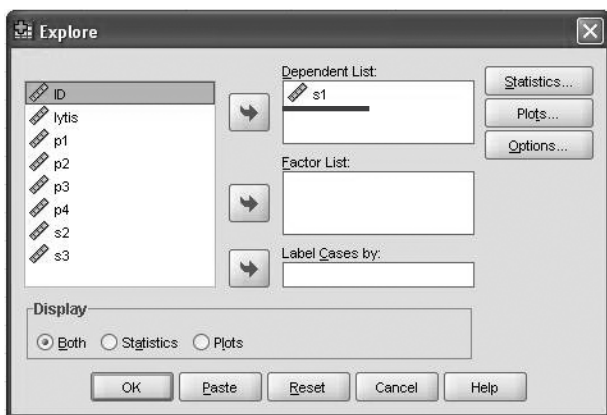
31 pav. Kolmogorovo ir Smirnovo bei Šapiro ir Vilko testų koeficientai duomenų išvesties lange



32 pav. s1 kintamojo histograma

Normalumas tikrinamas ne tik testais, kartais jais negalima visiškai pasikliauti, viskas priklauso nuo matavimų ir surinktų duomenų. Normalumą parodo ir pateikiama histograma, kuri, kai duomenys pasiskirstę normaliai, turėtų būti varpo formos, atspindėti Gauso skirstinį (32 pav.). Šis pavyzdys rodo, kad kintamasis nėra normaliai pasiskirstęs, nes histogramoje matyti viena Gauso skirstinio dalis, bet nėra kitos pusės. Jei duomenys nėra normaliai pasiskirstę, labai dažnai siūloma juos transformuoti. Transformuojami tik tie kintamieji, kurie nėra normaliai pasiskirstę. Transformuojant daroma prielaida, kad duomenys po transformacijos bus šiek tiek normaliau pasiskirstę. Tačiau prieš transformuojant duomenis svarbu įsitikinti, ar to tikrai reikia. Duomenys transformuojami atsižvelgiant į histogramos formą ir pagal tai parenkamos transformacijai reikalingos formulės (žr. Pallant, 2003).

Išskirtys. Faktorių analizė gali būti jautri išskirtims (angl. *outliers*). Išskirtys – tai ekstremalios reikšmės. Kai kur nurodoma, kad jei reikšmės yra didesnės nei trys standartiniai nuokrypiai nuo kintamojo vidurkio arba kintamojo reikšmės mažiau nei 3,3 ir daugiau nei $-3,3$, kai kintamasis yra paverstas standartiniais balais (z balais), tai ir yra ekstremali reikšmė arba išskirtis (Pallant, 2003). Jei išskirčių yra nemažai, tuomet reikėtų atidžiai peržiūrėti savo duomenis ir spręsti, ar galima ką nors padaryti. Turint daug tiriamųjų, išskirčių būna mažiau, bet kai tiriamųjų mažai ir imtis maža, galimybė, kad duomenys turės išskirčių, didėja. Jei išskirčių nėra daug, jos ir paliekamos. Svarbu patikrinti, ar nėra išskirčių ir klaidų duomenyse prieš pradėdant faktorių analizę. Kaip ir atliekant bet kurią kitą analizę, svarbu nusimanyti apie savo duomenis ir žinoti, su kuo dirbame. Išskirtis galime pamatyti naudodamiesi ta pačia komanda, kaip ir



33 pav. Išskirčių funkcijos pažymėjimas

tikrindami duomenų normalumą (*Analyze – Descriptive statistics – Explore*). Paspaudus nuorodą atsidaro naujas langas, kuriame į priklausomųjų kintamųjų langelį vėl įkeliame kintamąjį ar kelis kintamuosius, kurių išskirtis norime matyti. Paspaudus nuorodą „Statistika“ (angl. *statistics*), atsidaro naujas langas, kuriame ir pažymime išskirtis (33 pav.). Tuomet spaudžiame nuorodą „Tęsti“ ir pagrindiniame lange OK.

Duomenų išvesties lange pateikiama lentelė, kurioje matome ekstremalias kintamojo reikšmes (viršutinė lentelės dalis nurodo didžiausias reikšmes, o apatinė – mažiausias) ir kintamojo identifikacinį kodą (angl. *case number*) pagal SPSS programos langą (34 pav.). Pavyzdžiui, pateiktoje lentelėje nurodoma, kad 9 tiriamasis, atsakydamas į s1 klausimą, pažymėjo didžiausią balą (tai yra 5). Tas žmogus yra devintoje SPSS eilutėje (nors mes jam suteikėme visai kitokį kodą).

		Case Number	Value
s1	Highest	1	9
		2	12
		3	14
		4	15
		5	20
			5.00 ^a
Lowest		1	284
		2	283
		3	277
		4	272
		5	260
			1.00 ^b


a. Only a partial list of cases with the value 5.00 are shown in the table of upper extremes.

b. Only a partial list of cases with the value 1.00 are shown in the table of lower extremes.

ID	lytis	p1	p2	p3	p4	s1
1	1101	1.00	3.00	3.00	4.00	4.00
2	1102	2.00
3	1103	2.00
4	1104	2.00	2.00	3.00	3.00	3.00
5	1105	2.00	3.00	4.00	3.00	4.00
6	1106	1.00
7	1107	2.00	3.00	3.00	4.00	2.00
8	1108	1.00
9	1109	1.00	3.00	3.00	3.00	3.00
10	1110	1.00	3.00	3.00	3.00	4.00

34 pav. Ekstremalios kintamojo reikšmės duomenų išvesties lange

Tiriamasis, kuris yra 284 eilutėje, atsakydamas į s1 klausimą, pažymėjo mažiausią balą (tai yra 1). Tad pirmiausia šioje lentelėje galime matyti, ar nėra kokių keistų reikšmių, atsiradusių dėl duomenų pateikimo klaidų (pvz., vietoje 5 įvesta 55). Taip pat galime pamatyti, ar tik vienas, ar daugiau tiriamųjų yra pasirinkę mažiausias ar didžiausias kintamojo reikšmes. Galimas išskirtis taip pat rodo duomenų išvesties lange šios analizės gale esantis grafikas – stačiakampė diagrama (angl. *boxplot*) (35 pav.). Iš šios diagramos galime spręsti apie kintamojo išsibarstymą, didžiausias ir mažiausias reikšmes. Stačiakampis paprastai braižomas nuo pirmojo iki trečiojo kvartilio ir padalijamas ryškesniu brūkšniu į dvi dalis ties mediana (šiam pavyzdyje mediana sutampa su trečiuoju kvartiliu). Nuo stačiakampio paprastai į abi puses eina linijos (pavyzdyje tik į vieną pusę). Šios linijos tęsiasi iki paskutinių neišsiskiriančių iš duomenų aibės reikšmių. Išskirtys žymimos rutuliukais arba žvaigždutėmis, tai priklauso nuo nutolimo (Čekanavičius ir Murauskas, 2000). Šiam pavyzdyje išskirčių nėra.



35 pav. Išskirčių pateikimas grafike duomenų išvesties lange

Šalia pateiktame paveikslėlyje (35 pav.) apačioje jau matyti išskirtys, kurios pažymėtos rutuliuku ir nurodyti tiriamųjų eilutės numeriai. Čia jau tiriamojo, kuris yra 113 eilutėje, duomenys traktuojami kaip galimos išskirtys. Rutuliuku žymimos išskirtys, kurios nutolusios mažiau kaip pusė tarpkvartilinio skirtumo nuo trečiojo kvartilio, o žvaigždute, – kurios yra nutolusios daugiau nei pusė. Paprastai kalbant, visada gerai peržiūrėti tiriamuosius, ypač tuos, kurie pažymėti žvaigždutėmis. Tačiau tai nereiškia, kad iš karto tų tiriamųjų duomenis reikia pašalinti iš duomenų rinkmenos, skubėti tikrai nereikia. Vertėtų peržiūrėti, gal tiriamieji atsakė nenuoširdžiai ir visur sužymėjo didžiausias ar mažiausias reikšmes. Vertinti reikėtų atsargiai, peržiūrėti visus to tiriamojo duomenis ir tik tuomet spręsti, ar juos ištrinti, ar palikti.

5.1.3. Faktorių išskyrimas ir sukimas

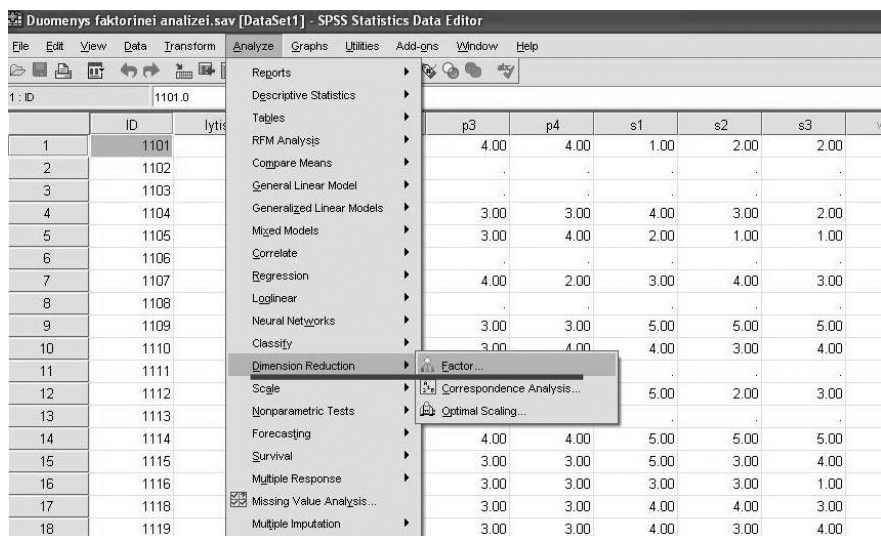
Jei duomenys tinkami, tai galime atlikti faktorių analizę. Analizuodama faktorius programa stengiasi surasti ir išskirti tuos, kurie geriausiai atspindi pateiktus kintamuosius. Kiek faktorių bus išskirta? Faktorių išskyrimas remiasi mažiausiu faktorių skaičiumi, kuris geriausiai gali reprezentuoti ryšius tarp turimų kintamųjų. Yra keletas faktorių išskyrimo metodų, kurie taikomi dirbant SPSS programa. Vienas dažniausių – pagrindinių komponentių analizė (angl. *principal component analysis*). Tačiau yra ir kitų faktorių išskyrimo metodų, pavyzdžiui, grupinis, minimalių liekanų, didžiausiojo tikėtimumo (Čekanavičius ir Murauskas, 2002). Faktorių išskyrimas remiasi taikomais metodais, tačiau galutinis sprendimas, kiek faktorių turėti, priklauso nuo tyrėjo. Programa stengiasi rasti mažiausią galimų faktorių, kurie paaiškintų daugiausia dispersijos, skaičių. Nėra nurodoma, kiek tiksliai dispersijos turi paaiškinti faktorių analizė, tačiau norima kuo daugiau. Tai tarsi būdas nuspręsti, kiek

faktorių reikėtų turėti. SPSS programa pateikia ir kitą metodą – tikrinės reikšmės. Verti būti palikti tik tie faktoriai, kurių tikrinės reikšmės didesnės nei 1. Dažnai yra siūloma atlikti kelias faktorių analizes, kai faktorių skaičius skirtingas, ir tada spręsti, kuri tinkamiausia ir kiek faktorių reikėtų turėti (Pallant, 2003). Kartais tai naudinga, kai turime nemažai kintamųjų, kuriuos naudojame faktorių analizei. Faktorių analizė parodo, kiek galima jų turėti, tačiau kaip juos pavadinti, interpretuoti ir, galiausiai, nuspręsti, kiek jų reikėtų, yra tyrėjo reikalas.

Atliekant faktorių analizę jie ne tik išskiriami, bet ir sukami. Dažnai būna, kad sunku interpretuoti gautus faktorius, nes tas pats kintamasis gali priklausyti keliems jų. Tuomet išeitis gali būti faktorių sukimas. Tai nepakeičia pačių faktorių skaičiaus, tik padeda lengviau juos interpretuoti, taip pat gali keistis ir kiekvieno faktoriaus paaiškinama dispersijos dalis. Tai tarsi kintamųjų išgryninimas. Galutinė faktorių interpretacija priklauso nuo paties tyrėjo ar jo teorinės perspektyvos. SPSS tik pateikia, kurie klausimai ar kintamieji geriausiai atspindi vieną ar kitą faktorių. Yra įvairių sukimo būdų. Pirmiausia jie skiriami į ortogonalius (angl. *orthogonal*) ir neortogonalius (angl. *oblique*). Dažniausiai taikomi ortogonalus sukimo metodai. Taikant šiuos metodus gautus rezultatus yra lengviau interpretuoti. Tačiau šis sukimas tarsi daro prielaidą, kad faktoriai / konstruktai tarpusavyje nėra susiję (neturi korelacinių ryšių). Neortogonalus sukimas lyg ir teigia, kad faktoriai tarpusavyje susiję korelaciniais ryšiais. Yra įvairių ortogonalus sukimo metodų. SPSS pateikia keletą jų – *Varimax*, *Quartimax*, *Equamax*. Dažniausiai naudojamas *Varimax* sukimas. Šis sukimo metodas tarsi siekia sumažinti kintamųjų, kurie turi didelius faktorių svorius, skaičių, maksimizuoja faktorių dispersiją. *Quartimax* sukinys siekia sumažinti faktorių, reikalingų kiekvienam faktorių analizės kintamajam paaiškinti, skaičių. Šis sukinys minimizuoja faktorių dispersiją ir gali būti, kad atskiri kintamieji bus priskirti atskiriems faktoriams, o nebus sudaromas vienas faktorius iš panašių kintamųjų. *Equamax* sukinys yra tarsi tarpinis tarp *Varimax* ir *Quartimax*. Iš neortogonalus sukimo metodų dažniausiai taikomas *Direct Oblimin*. Šis metodas paprastai pateikia labai panašius faktorius, kaip taikant *Varimax* sukinį, tik atliekant šį sukinį daroma prielaida, kad faktoriai susiję, tarp jų yra koreliacija. SPSS iš neortogonalus sukimo metodų dar pateikia *Promax* sukinį. Šis sukinys leidžia faktoriams koreliuoti ir gerai tinka esant didelėms duomenų bazėms, dideliame faktorių skaičiui. Labai dažnai rezultatai, gauti taikant tiek ortogonalius, tiek neortogonalius sukimo metodus, yra panašūs. Kartais gali būti, kad nė vienas sukimo metodas nepadeda lengviau interpretuoti gautų faktorių. Faktorių sukimo pasirinkimas naudojant SPSS programą pateikiamas 40 pav.

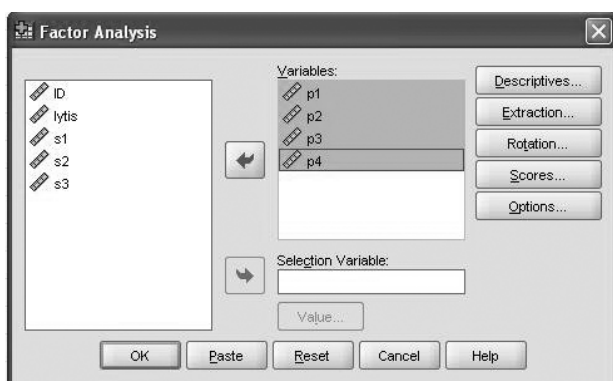
5.1.4. Tiriamosios faktorių analizės atlikimas

Tiriamoji faktorių analizė yra SPSS programos dalis (*Analyze – Dimension reduction – Factor*) (36 pav.).



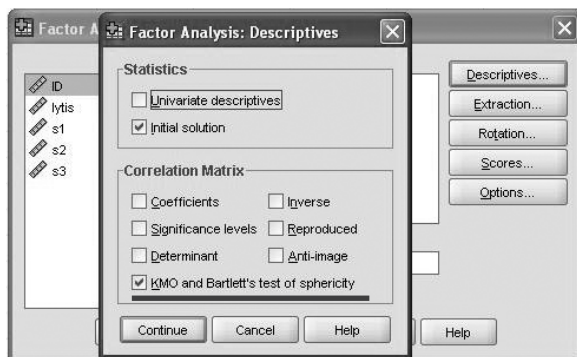
36 pav. Tiriamosios faktorių analizės pasirinkimas

Paspaudus nuorodą atsidaro faktorių analizės lentelė. Į kintamųjų langelį sukeliami visi kintamieji, kurie bus naudojami tai faktorių analizei. Tarkim, norima patikrinti, ar kintamieji p1, p2, p3 ir p4 (kurie yra pasitikėjimo savimi klausimai) gali sudaryti vieną faktorių (37 pav.).



37 pav. Kintamųjų faktorių analizei pasirinkimas

Paspaudus nuorodą „Aprašymas“ (angl. *descriptives*) atsidaro aprašomosios faktorių analizės statistikos lentelė (38 pav.). Čia reikėtų pažymėti KMO ir Bartleto sferiškumo testą. Tai leis įvertinti duomenų tikimą faktorių analizei. Pasirinkus KMO ir Bartleto sferiškumo testą spaudžiama nuoroda „Tęsti“.

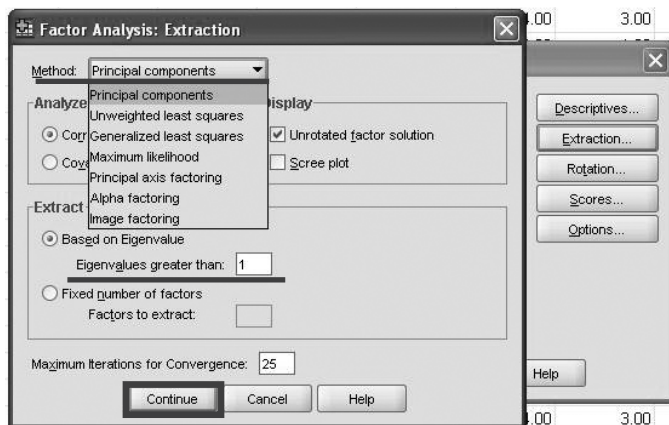
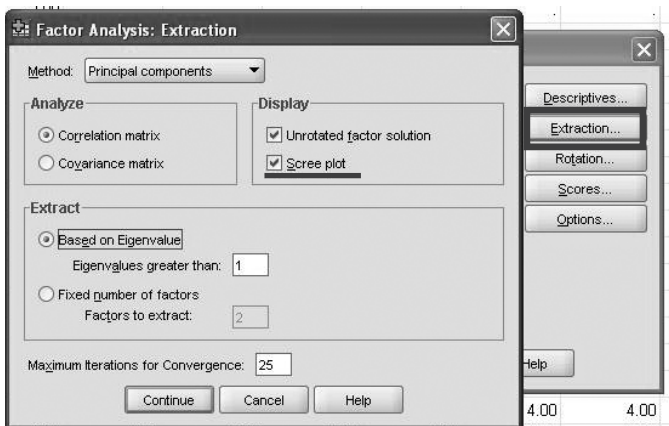


38 pav. KMO ir Bartleto sferiškumo testo pasirinkimas

Paspaudus nuorodą „Faktorių išskyrimas“ (angl. *extraction*) galima pažymėti (nors tai nėra būtina) tikrinių reikšmių grafiką (angl. *scree plot*) (39 pav.). Tai leis vizualiai įvertinti faktorius ir jų skaičių. Šiame langelyje taip pat galima pasirinkti kitą, nei priskirtas programos, faktorių išskyrimo metodą (programos būna priskirtas pagrindinių komponentių metodas). Spustelėjus rodyklę pasirodo kiti faktorių išskyrimo metodai. Šiame langelyje būna nurodyta, kad faktoriai išskiriamai remiantis tikrinėmis reikšmėmis, didesnėmis negu 1. Pasirinkus spaudžiama nuoroda „Tęsti“.

Toliau yra sukimo (angl. *rotation*) nuoroda, kur galima pažymėti norimą sukimo metodą (40 pav.). SPSS programa standartiškai nebūna priskyriusi jokio sukimo metodo. Jei manoma, kad bus tik vienas faktorius, galima sukimo ir nesirinkti, nes esant vienam faktoriui, kuris sudarytas iš visų nurodytų kintamųjų, sukimas nebūna atliekamas. Sukimas atliekamas tuomet, kai faktorių skaičius didesnis negu vienas. Koks sukimo metodas taikomas, priklauso nuo duomenų ir prielaidų. *Varimax* – dažniausiai pasirenkamas, nors gal ir ne visada tinkamiausias, faktorių sukiny. Pasirinkus spaudžiama nuoroda „Tęsti“.

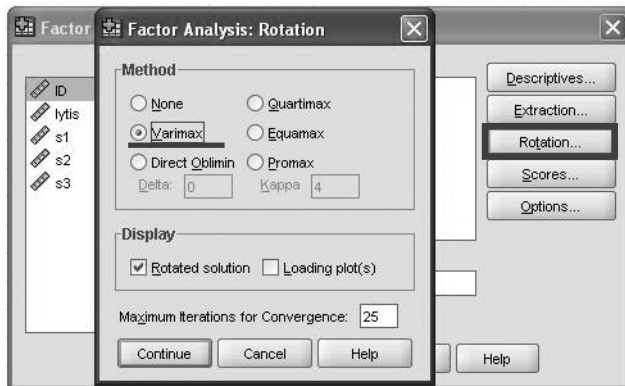
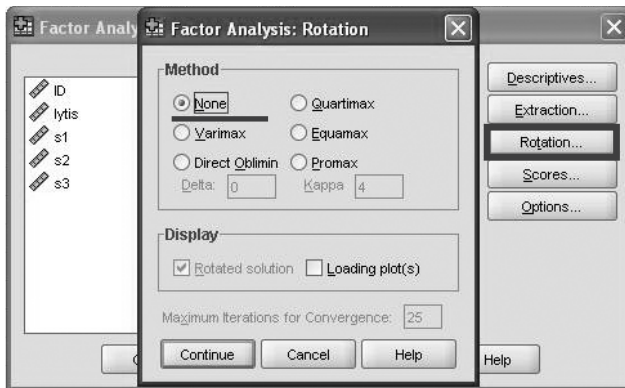
Tai ir yra pagrindiniai pasirinkimai atliekant faktorių analizę. Padarius visus pasirinkimus, spaudžiamas mygtukas OK pagrindiniame lange ir nagrinėjami rezultatai duomenų išvesties lange, kuriame pateikti atliktos analizės rezultatai.



39 pav. Tikrinių reikšmių grafiko ir faktorių išskyrimo metodo pasirinkimas

5.1.5. Tiriamosios faktorių analizės rezultatai

Pirmiausia duomenų išvesties lange pateikiamas duomenų tinkamumo faktorių analizei įvertinimas (41 pav.). Tai Bartleto sferiškumo testas ir KMO. Tinkamos faktorių analizės Bartleto sferiškumo testas turėtų būti reikšmingas (reikšmingumo lygmuo $p < 0,05$), o KMO koeficientas turėtų būti 0,60 ir daugiau (Pallant, 2003). Šiame pavyzdyje Bartleto sferiškumo testas yra reikšmingas ir $KMO = 0,73$. Taigi turimi duomenys (kintamieji p1–p4) yra tinkami faktorių analizei. Šiame pavyzdyje ir imtis yra pakankamai didelė. Faktorių analizei naudojome keturis kintamuosius, tai imtyje turėtų būti bent $4 \cdot 5 = 20$ (geriau $4 \cdot 10 = 40$) tiriamųjų. Šioje imtyje yra 330 tiriamųjų.



40 pav. Faktorių sukimo pasirinkimas

➔ **Factor Analysis**

[DataSet1] D:\Duomenys faktorinei analizei.sav

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		.734
Bartlett's Test of Sphericity	Approx. Chi-Square	230.824
	df	6
	Sig.	.000

41 pav. KMO ir Bartleto sferiškumo testo koeficientai duomenų išvesties lange

Kiek faktorių / konstrukty vėta išskirti, parodo bendra paaiškintos dispersijos (angl. *total variance explained*) lentelė. Faktorių analizei svarbūs tik tie komponentai, kurių tikrinės reikšmės yra daugiau negu 1. Stulpelis „Bendra“ (angl. *total*) ir parodo tikrinę reikšmę (42 pav.). Čia tik vienas faktorius turi tikrinę reikšmę, didesnę negu 1, t. y. 2,156. Visų kitų galimų faktorių tikrinės reikšmės mažesnės negu vienetas.


Vadinasi, šie kintamieji (p1–p4) turėtų sudaryti vieną faktorių, bet ne daugiau. Stulpelis „Komponentai“ (angl. *components*) ir parodo faktorių skaičių. Kartais tiesiog rašoma, kad visiškai užpildytos lentelės eilutės (čia tokių tik viena) ir nurodomas faktorių skaičius (Pallant, 2003).

Total Variance Explained						
Component	Initial Eigenvalues			Extraction Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.156	53.907	53.907	2.156	53.907	53.907
2	.733	18.331	72.238			
3	.596	14.893	87.131			
4	.515	12.869	100.000			

Extraction Method: Principal Component Analysis.

42 pav. Tikrinių reikšmių pateikimas duomenų išvesties lange

Šis vienas faktorius paaiškina 53,907 proc. dispersijos (žr. stulpelį *Cumulative %*). Kad geriausia turėti vieną faktorių, rodo ir tikrinių reikšmių grafikas (angl. *Scree test*). Šis grafikas, dar vadinamas Ketelo testu (angl. *Catell's scree test*), vaizduoja faktorius grafike (43 pav.). Šiame grafike svarbus taškas, kuriame grafikas tampa horizontalus. Grafiko x ašyje yra faktorių skaičius, o y ašyje – tikrinės reikšmės. Mums svarbūs tik tie faktoriai, kurių tikrinės reikšmės yra daugiau negu 1. Faktoriai (jie grafike vaizduojami rutuliukais), kurie yra vertikalesnėje grafiko dalyje, paaiškina daugiausia duomenų pasiskirstymo ir jų skaičių geriausia turėti. Taigi svarbūs tik tie faktoriai (rutuliukai), kurie yra virš grafiko lūžio taško. Šiame grafike tik vienas rutuliukas yra virš lūžio taško. Vadinasi, kai duomenys tokie, geriausia turėti tik vieną komponentą, vieną faktorių.



43 pav. Tikrinių reikšmių grafikas duomenų išvesties lange

Gali būti, kad bendra paaiškintos dispersijos lentelė pateikia vieną siūlymą, o grafikas tarsi rodo, kad faktorių skaičius kitoks. Kai kurie tyrėjai pasikliauna tik lentele, o kiti tik grafiku. Tačiau svarbu atsižvelgti ir į teorinius svarstymus, kiek faktorių / konstrukty geriausia ar logiškiausia turėti, kai yra tokie kintamieji. Visada galima išbandyti kelis faktorių analizės variantus ir pažiūrėti, kurį lengviau teoriškai pagrįsti.

Kita komponentų matricos lentelė (angl. *component matrix*) pateikia faktorių svorius (44 pav.). Stulpelių skaičius atspindi faktorius (šiuo atveju vienas stulpelis, nes geriausia turėti tik vieną faktorių). Skaičiai stulpeliuose – faktorių svoriai. Faktorių svoriai yra koreliacijos tarp kintamųjų ir faktoriaus. Faktorių svoriai gali būti teigiami ar neigiami. Neigiami faktorių svoriai rodo, kad kintamasis neigiamai siejasi su pačiu fakto-

Component Matrix ^a		Rotated Component Matrix ^a
	Component	
	1	
p1	.679	
p2	.753	
p3	.739	
p4	.763	

Extraction Method: Principal Component Analysis.

a. 1 components extracted.

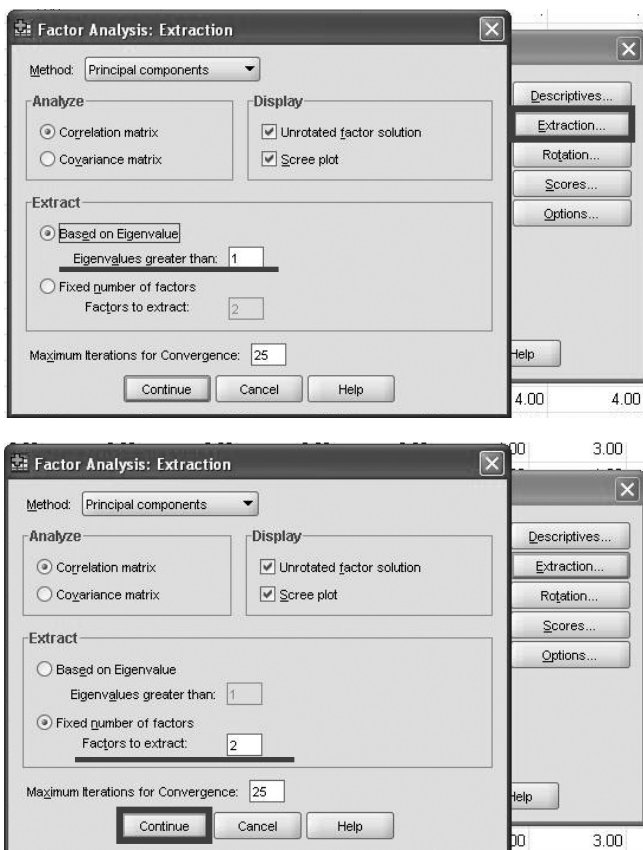
a. Only one component was extracted. The solution cannot be rotated.

44 pav. Komponentų matricos lentelė

riumi, taigi kartu ir su kitais to paties faktoriaus kintamaisiais. Toks kintamasis dažniausiai perkoduojamas, kad teigiamai sietųsi su to paties faktoriaus kintamaisiais. Kuo kintamojo faktoriaus svoris didesnis, tuo jis labiau siejasi su tuo faktoriu arba geriau atspindi tą faktorių. Norima, kad faktorių svoriai būtų didesni negu 0,4 (Raubenheimer, 2004). Retais atvejais svoriai gali būti bent jau didesni negu 0,25 (Raubenheimer, 2004). Visuomet reikia atsižvelgti į teorinius aspektus, kuriais vadovaujantis metodika sukurta, o ne vien į konkrečias ribas. Šiame pavydyje faktoriaus kintamųjų svoriai labai panašūs, vadinasi, visi kintamieji panašiai paaiškinami vieno faktoriaus. Jei turime tik vieną faktorių, sukimo neatliekame ir faktorių svorių po sukimo (angl. *rotated component matrix*) nepateikiame. Jei reikia, kai turime tik vieną faktorių, skelbiami tie faktorių svoriai, kurie yra komponentų matricos lentelėje.

5.1.6. Tiriamosios faktorių analizės, kai nustatomas norimas faktorių skaičius, atlikimas

Tarkime, norime, naudodami tuos pačius kintamuosius, atlikti kitą faktorių analizę, nes, pavyzdžiui, manome, kad kintamieji turi sudaryti ne vieną, o du faktorius. Teoriškai klausimai gali sudaryti du atskirus konstruktus. SPSS programa neleidžia konkrečių kintamųjų savo nuožiūra priskirti vienam ar kitam faktoriui, tačiau galime bent jau nurodyti mums reikiamą faktorių skaičių. Analizei naudojame tuos pačius kintamuosius ir, paspaudę nuorodą „Aprašymas“, pasirenkame KMO ir Bartleto sferiškumo testą. Paspaudę nuorodą „Faktorių išskyrimas“ galime vėl pažymėti (nors tai nebūtina) tikrinių reikšmių grafiką (45 pav.). Šiame langelyje jau būna nurodyta, kad faktoriai išskiriami remiantis tikrinėmis reikšmėmis, didesnėmis už 1. Tačiau, jei norime išbandyti tam tikrą faktorių skaičių, šiuo atveju 2 faktorius su



45 pav. Fiksuoto faktorių skaičiaus nurodymas

esamais kintamaisiais, šios funkcijos nesirenkame, o pasirenkame fiksuotą faktorių skaičių (angl. *fixed number of factors*). Šalia esančiame langelyje įrašome numanomų ar norimų patikrinti faktorių skaičių, pavyzdžiui, 2.

Toliau prie sukimo nuorodos pažymimas norimas sukimas, tarkim, Varimax. Šiuo atveju programa jau bandys sudaryti du faktorius ir tuomet sukimas yra svarbus. Prisimintina, kad sukimo metodo pasirinkimas priklauso nuo duomenų ir prielaidų. Atlikus šiuos pasirinkimus (po kiekvieno pasirinkimo spaudžiama nuoroda „Tęsti“), paspaudžiamas mygtukas OK ir nagrinėjami gauti rezultatai.

5.1.7. Tiriamosios faktorių analizės, kai nustatomas norimas faktorių skaičius, rezultatai

Pirmiausia duomenų išvesties lange vėl pateikiamas duomenų tinkamumo faktorių analizei įvertinimas. Tai Bartleto sferiškumo testas ir KMO (46 pav.). Šiame pavyzdyje Bartleto sferiškumo testas yra reikšmingas ir $KMO = 0,73$. Taigi, duomenys yra tinkami ir šiai faktorių analizei.

➔ **Factor Analysis**

[DataSet1] D:\Duomenys faktorinei analizei.sav

KMO and Bartlett's Test

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		.734
Bartlett's Test of Sphericity	Approx. Chi-Square	230.824
	df	6
	Sig.	.000

46 pav. KMO ir Bartleto sferiškumo testo koeficientai dviejų faktorių analizei

Bendros paaiškintos dispersijos lentelėje dvi eilutės visiškai užpildytos, taigi, tiek faktorių ir išskirta (47 pav.). Kaip minėta, faktorių analizei svarbūs tik tie komponentai, kurių tikrinės reikšmės yra daugiau negu 1. Čia yra tik vienas faktorius, turintis tikrinę reikšmę, didesnę negu 1, t. y. 2,156. Antro faktoriaus tikrinė reikšmė yra mažesnė nei vienetą (0,733). Taigi reikėtų įvertinti visus rezultatus ir pagalvoti, ar tikrai reikia dviejų faktorių. Šie du faktoriai paaiškina 72,24 proc. dispersijos – gerokai daugiau, negu paaiškintų vienas faktorius, tačiau reikia prisiminti, kad antrojo faktoriaus tikrinė reikšmė mažesnė negu vienetą.


Total Variance Explained

Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.156	53.907	53.907	2.156	53.907	53.907	1.609	40.222	40.222
2	.733	18.331	72.238	.733	18.331	72.238	1.281	32.016	72.238
3	.596	14.893	87.131						
4	.515	12.869	100.000						

Extraction Method: Principal Component Analysis.

47 pav. Bendros paaiškintos dispersijos lentelė esant dviem faktoriams

Kad geriausia turėti vieną faktorių, rodo ir tikrinių reikšmių grafikas (48 pav.). Tad šiame pavyzdyje bendra paaiškintos dispersijos lentelė pateikia vieną galimybę, o grafikas tarsi rodo kitokį faktorių skaičių.



48 pav. Tikrinių reikšmių grafikas dviem išskirtiems faktoriams analizuoti

Component Matrix ^a			Rotated Component Matrix ^a		
	Component			Component	
	1	2		1	2
p1	.679	.660	p1	.123	.939
p2	.753	-.247	p2	.744	.273
p3	.739	-.473	p3	.873	.087
p4	.763	.114	p4	.528	.563

Extraction Method:
Principal Component Analysis.
a. 2 components extracted.

Extraction Method:
Principal Component Analysis.
Rotation Method:
Varimax with Kaiser Normalization.
a. Rotation converged in 3 iterations.

49 pav. Komponentų matricos lentelė turinti du faktorius

Komponentų matricos lentelė, kuri pateikia faktorių svorius, gali padėti tiksliai nustatyti, kiek faktorių turėti (49 pav.). Stulpelių skaičius atspindi faktorius (šiuo atveju stulpeliai du, nes buvo nurodyti du faktoriai). Skaičiai stulpeliuose – faktorių svoriai. Šiuo atveju turime du faktorius, taigi galime iš karto žiūrėti į matricos lentelę po sukimo (angl. *rotated component matrix*). Kiekvienas kintamasis (jie lentelės kairėje) turi skaičių abiejuose stulpeliuose. Kuriame stulpelyje skaičius didesnis, tas faktorius ir paaiškina atskirą kintamąjį. Pavyzdžiui, p1 kintamojo svoris pirmame yra 0,123, o antrame – 0,939. Tai rodo, kad antras faktorius paaiškina šį kintamąjį arba šis kintamasis priskiriamas antram faktoriui. Kintamieji p2 ir p3 priskiriami pirmam faktoriui, jis juos ir paaiškina. Vadinasi, faktorius paaiškina tuos kintamuosius, kurių faktorių svoriai yra dideli (bent jau didesni negu 0,4). O kintamasis p4 yra susiklojantis (jo abiejų faktorių svoriai panašūs), todėl nelabai aišku, kuriam faktoriui šis kintamasis gali būti priskirtas. Šį kintamąjį paaiškina abu faktoriai, kintamasis turėtų būti priskiriamas tam faktoriui, kuris geriau tinka pagal prasmę, t. y. kurį sudarantys kintamieji labiau susiję pagal prasmę. Visi rezultatai (lentelė, grafikas, faktorių

svoriai) šiame pavyzdyje rodo, kad gal nėra gerai turėti du faktorius, lengviau būtų interpretuojamas vienas faktorius. Bet galutinį sprendimą, kiek faktorių geriausia turėti, remdamasis visais gautais duomenimis, priima kiekvienas, kuris atlieka faktorių analizę. Turint du ar daugiau faktorių, skelbiami faktorių svoriai, kurie yra matricos lentelėje po sukimo.

5.1.8. Tiriamosios faktorių analizės, turint kelių priemonių kintamuosius, atlikimas

Tarkime, turime klausimų apie pasitikėjimą savimi (p1–p4) ir santykius su draugiais (s1–s3). Norime žinoti, ar šie klausimai gali sudaryti du atskirus komponentus, faktorius. Tada, atlikdami faktorių analizę (*Analyze – Dimension reduction – Factor*), į kintamųjų langelį sukeliame visus norimus įtraukti į analizę kintamuosius, šiuo atveju p1–p4 ir s1–s3. Prie nuorodos „Aprašymas“ pasirenkame KMO ir Bartleto sferiškumo testą. Paspaudę nuorodą „Faktorių išskyrimas“ vėl galime pažymėti (nors tai nebūtina) tikrinių reikšmių grafiką. Šiame langelyje nurodome, kad faktoriai išskiriami remiantis tikrinėmis reikšmėmis, didesnėmis negu 1. Taip darome, nes norime patikrinti, ar galimi keli faktoriai, ar ne. Faktorių skaičių nurodome testuodami konkrečias hipotezes ar tikrindami kitas idėjas. Toliau prie sukimo nuorodos pažymime norimą sukimą, tarkim, *Varimax*. Visada galima atlikti faktorių analizę be sukimo ir pažiūrėti, kiek programa pateikia faktorių, o tada kartoti faktorių analizę ir atlikti sukimą. Prisimintina, kad sukimo metodo pasirinkimas priklauso nuo duomenų ir prielaidų. Atlikus šiuos pasirinkimus (po kiekvieno pasirinkimo spaudžiama nuorodą „Tęsti“), paspaudžiamas mygtukas OK ir nagrinėjami gauti rezultatai.

5.1.9. Tiriamosios faktorių analizės, turint kelių priemonių kintamuosius, rezultatai

Pirmiausia, kaip ir atlikus kiekvieną faktorių analizę, duomenų išvesties lange pateikiamas duomenų tinkamumo faktorių analizei įvertinimas (50 pav.). Tai Bartleto sferiškumo testas ir KMO. Šiame pavyzdyje Bartleto sferiškumo testas yra reikšmingas ir $KMO = 0,736$. Vadinasi, duomenys yra tinkami faktorių analizei.

KMO and Bartlett's Test		
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		.736
Bartlett's Test of Sphericity	Approx. Chi-Square	499.569
	df	21
	Sig.	.000


50 pav. KMO ir Bartleto sferiškumo testas faktorių analizei, kai įtraukiami p1–p4 ir s1–s3 kintamieji

Bendros paaiškintos dispersijos lentelėje pilnos yra dvi eilutės, taigi įmanoma turėti tiek faktorių (51 pav.). Faktorių analizei svarbūs tik tie komponentai, kurių tikrinės reikšmės yra daugiau negu 1. Čia yra du faktoriai, turintys tikrinę reikšmę, didesnę negu 1, t. y. 2,609 ir 1,655. Tad programa pateikia, kad galimi du faktoriai iš pateiktų kintamųjų (p1–p4 ir s1–s3). Šie du faktoriai paaiškina 60,92 proc. dispersijos.

Total Variance Explained									
Component	Initial Eigenvalues			Extraction Sums of Squared Loadings			Rotation Sums of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	2.609	37.277	37.277	<u>2.609</u>	37.277	37.277	2.151	30.732	30.732
2	1.655	23.643	60.920	<u>1.655</u>	23.643	60.920	2.113	30.188	60.920
3	.733	10.468	71.388						
4	.639	9.130	80.518						
5	.516	7.368	87.887						
6	.464	6.630	94.517						
7	.384	5.483	100.000						

Extraction Method: Principal Component Analysis.

51 pav. Bendros paaiškintos dispersijos lentelė faktorių analizei, kai įtraukiami p1–p4 ir s1–s3 kintamieji



52 pav. Tikrinių reikšmių grafikas faktorių analizei, kai įtraukiami p1–p4 ir s1–s3 kintamieji

Kad geriausia turėti du faktorius, rodo ir tikrinių reikšmių grafikas (52 pav.). Kaip minėta, šiame grafike svarbūs tik tie faktoriai, rutuliukai, kurie yra virš grafiko lūžio taško. Šiame grafike virš lūžio taško yra du rutuliukai. Rezultatai rodo, kad, turint šiuos duomenis, geriausia imti du komponentus, du faktorius.

Komponentų matricos lentelė pateikia faktorių svorius (53 pav.). Stulpelių skaičius atspindi faktorius (šiuo atveju du

stulpelius, t. y. du faktorius). Skaičiai stulpeliuose – faktorių svoriai. Vėl turime du faktorius, tai galime iš karto žiūrėti į matricos lentelę po sukimo. Rezultatai rodo, kad pirmasis faktorius paaiškina p1, p2, p3 ir p4 kintamuosius, o antrasis faktorius – s1, s2 ir s3 kintamuosius. Visi šie kintamieji ir sudaro du atskirus faktorius, kurių vieną galima pavadinti pasitikėjimo savimi faktoriumi, o kitą – santykių su draugais faktoriumi.

Component Matrix ^a			Rotated Component Matrix ^a		
	Component			Component	
	1	2		1	2
p1	.566	.356	p1	.655	.135
p2	.611	.421	p2	.732	.120
p3	.574	.496	p3	.758	.039
p4	.580	.500	p4	.765	.042
s1	.633	-.554	s1	.073	.838
s2	.634	-.500	s2	.111	.800
s3	.669	-.546	s3	.104	.857

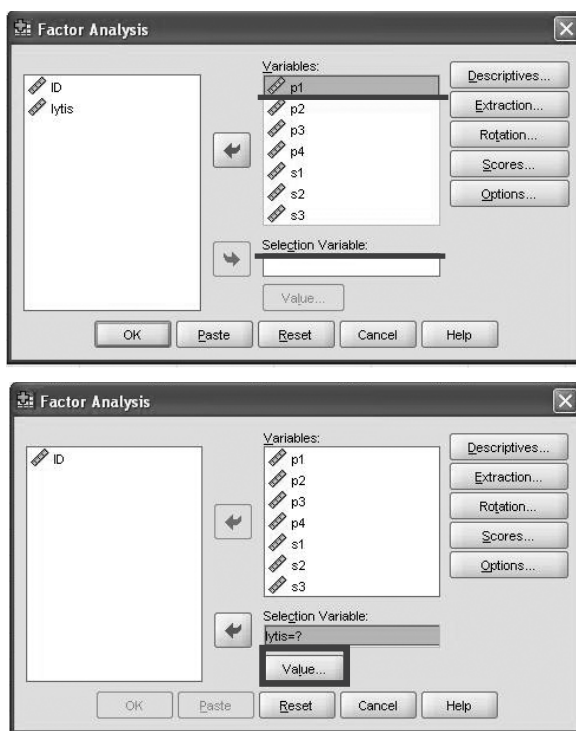
Extraction Method: Principal Component Analysis.
a. 2 components extracted.

Extraction Method: Principal Component Analysis.
Rotation Method: Varimax with Kaiser Normalization.
a. Rotation converged in 3 iterations.

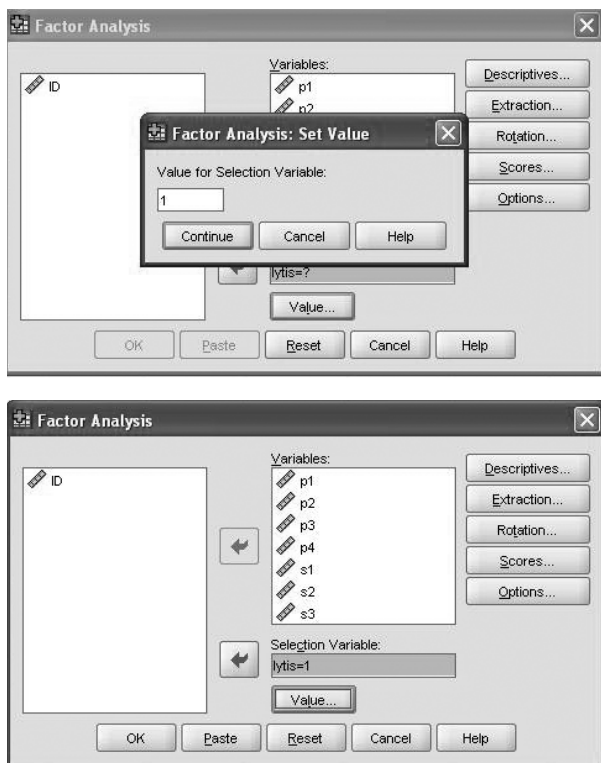
53 pav. Komponentų matricos lentelė faktorių analizei, kai įtraukiami p1–p4 ir s1–s3 kintamieji

5.1.10. Tiriamosios faktorių analizės atlikimas atskiroms grupėms

Kartais gali būti prašoma atskirai pristatyti tam tikrų grupių (pvz., berniukų) faktorių analizę. Visuomet galima kurti atskirą duomenų rinkmeną, į kurią įtrauksime tik tos grupės (pvz., berniukų) duomenis. Tačiau yra ir paprastesnis būdas atlikti tą pačią faktorių analizę. Tarkime, norime pažiūrėti, ar galimi tokie patys du faktoriai iš visų kintamųjų (p1–p4 ir s1–s3) tik berniukams, neįtraukinat į analizę mergaičių. Atliekant tą pačią faktorių analizę (*Analyze – Dimension reduction – Factor*) sukeliami visi norimi įtraukti į faktorių analizę kintamieji (54 pav.). Apačioje yra galimybė pasirinkti atrankos kintamąjį (angl. *selection variable*). Čia įkeliamas kintamasis, kuris atspindi norimas grupes, pavyzdžiui, lytis, amžius, tautybė ar pan. Kai įkeliamas tas kintamasis, toje vietoje atsiranda jo pavadinimas, lygybės ženklas ir klausukas. Taip



54 pav. Faktorių analizės skirtingoms grupėms pasirinkimas



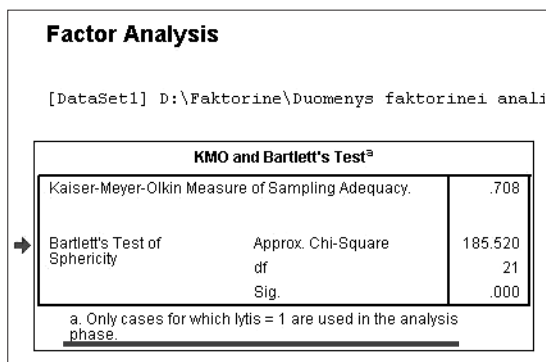
55 pav. Grupių reikšmių pateikimas

programa tarsi klausia, kurią grupę rinksimės. Po atrankos kintamojo langeliu yra „Reikšmės pasirinkimas“ (angl. *value*).

Paspaudus „Reikšmės pasirinkimas“, atsirado naujas langas (55 pav.). Šiame lange prie „Pasirinkto kintamojo reikšmė“ (angl. *value for selection variable*) langelyje įrašome norimą grupę atitinkantį skaičių, reikšmę. Šiame pavyzdyje berniukai duomenų rinkmenoje buvo užkoduoti 1, taigi įrašomas vienetas. Norint pažiūrėti mergaičių faktorių analizę, reikėtų įrašyti 2, nes mergaitės duomenų rinkmenoje užkoduotos dvejetu. Paspaudę mygtuką „Tęsti“, grįžtame į pradinį langą. Jame matyti, kad prie kintamojo pavadinimo, lygybės ženklo jau nėra klausuko, o įrašytas skaičius. Tai ir rodo, kokią tiriamųjų grupę pasirinkome analizuoti. Visi kiti pasirinkimai daromi, kaip ir analizuojant anksčiau (KMO ir Bartleto sferiškumo testas, galima rinktis ir tikrinių reikšmių grafiką, atitinkamą faktorių sukimą).

5.1.11. Tiriamosios faktorių analizės atskirų grupių rezultatai

Čia, kaip ir atlikus kiekvieną faktorių analizę, duomenų išvesties lange matyti tie patys duomenys – pirmiausia pateikiamas duomenų tinkamumo faktorių analizei įvertinimas. Tai Bartleto sferiškumo testas ir KMO (56 pav.), vėliau bendra paaš-
kintos dispersijos lentelė, tikrinių reikšmių grafikas, faktorių svorių lentelės. Po visomis lentelėmis ar grafiku yra priedas, kad tai tik duomenys, kurie atitinka nurodyto kintamojo reikšmę, naudoti šioje analizėje (angl. *only cases for which lytis = 1 are used in the analysis phase*). Taip galima atskirai atlikti visų tiriamųjų grupių faktorių analizę ir jas lyginti, jei tik yra toks klausimas ar užmanymas.



The screenshot shows the 'Factor Analysis' dialog box in SPSS. The data source is '[DataSet1] D:\Faktorine\Duomenys faktorinei anali...'. The 'KMO and Bartlett's Test' section is expanded, showing the following results:

KMO and Bartlett's Test ^a		
Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		.708
Bartlett's Test of Sphericity	Approx. Chi-Square	185.520
	df	21
	Sig.	.000

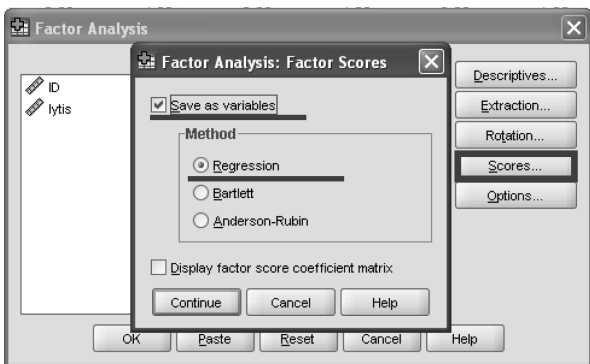
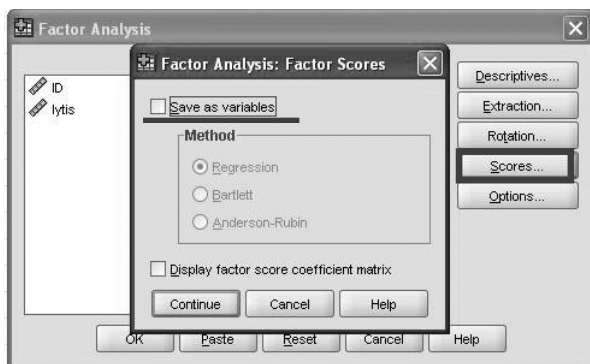
a. Only cases for which lytis = 1 are used in the analysis phase.

56 pav. Vienos iš tiriamų grupių KMO ir Bartleto sferiškumo testo koeficientai

5.1.12. Faktorių reikšmių išsaugojimas kaip kintamųjų

Kartais yra svarbu išsaugoti faktorių reikšmes kaip kintamuosius, nes jie bus naudojami kitoms analizėms. Faktorių reikšmes tada galima išsaugoti duomenų rinkmenoje, su kuria dirbama. Atliekant faktorių analizę, pasirinkus „Duomenys“ (angl. *scores*), atsidaro naujas langas, kuriame ir nurodome, kad norime išsaugoti faktorių duomenis kaip kintamuosius (angl. *save as variables*) (57 pav.). Tai reikia pažymėti varnele. Yra skirtingų metodų, kuriais gaunamos faktorių reikšmės – regresija (angl. *regression*), Bartleto metodas (angl. *Bartlett*) ir Andersono ir Rubino metodas (angl. *Anderson-Rubin*). Andersono ir Rubino metodas užtikrina, kad faktorių reikšmės nėra susijusios ir norint jas bus galima naudoti regresinei analizei. Jei nesvarbu, ar faktorių reikšmės susijusios, ar ne, tinka regresijos metodas. Šis metodas nuspėja kiekvieno tiriamojo vietą faktoriuje ar konstrukte (DiStefano et al., 2009). Bartleto metodas tarsi teigia, kad tik bendri faktoriai lemia faktorių reikšmes ir šios reikšmės stipriai siejasi su vienu jas atspindinčiu faktoriumi, bet ne su kitu. Kurį metodą pasirinkti, priklauso nuo to, kas bus daroma su faktorių reikšmėmis.

Pasirinkus ir paspaudus „Tęsti“ ir pagrindiniame lange OK, duomenų rinkmenoje atsiras naujų kintamųjų (jų bus tiek, kiek faktorių, šiame pavyzdyje – du, nes turėti du faktoriai – kintamųjų p1–p4 ir s1–s3), kurių reikšmės gautos pritaikius pasirinktą metodą (58 pav.).



57 pav. Faktoriaus reikšmių išsaugojimas

SPSS Statistics Data Editor window showing the results of a factor analysis. The data table includes variables p4, s1, s2, s3, FAC1_1, and FAC2_1. The FAC1_1 and FAC2_1 columns are highlighted with a black box.

		p4	s1	s2	s3	FAC1_1	FAC2_1	var
1	0	4.00	1.00	2.00	2.00	-0.80548	2.55375	
2	
3	
4	0	3.00	4.00	3.00	2.00	-1.00400	0.14699	
5	0	4.00	2.00	1.00	1.00	-0.97365	2.78948	
6	
7	0	2.00	3.00	4.00	3.00	-0.46852	0.17921	
8	
9	0	3.00	5.00	5.00	5.00	0.61737	-1.16573	
10	0	4.00	4.00	3.00	4.00	0.12223	0.43245	

58 pav. Duomenų rinkmenoje išsaugotos faktoriaus reikšmės

Atskirų faktorių reikšmės kursiniuose darbuose analizuojamos gana retai. Dažniau jų pasitaiko moksliniuose straipsniuose, kai ieškoma ryšių tarp faktorių reikšmių ir kitų kintamųjų skirtumų tarp grupių ar faktoriai naudojami regresinėms analizėms. Kur juos galima panaudoti, priklauso nuo keliamų tyrimo klausimų.

5.1.13. Galimas tiriamosios faktorių analizės aprašymas

Gana dažnai faktorių analizė nėra tyrimų tikslas ir todėl tik aprašant metodikas siauriau ar plačiau paminimi faktorių analizės rezultatai. Paprastai yra aprašomas kiekvienas faktorius, jie pavadinami, pateikiami jų svoriai, duomenų tinkamumo faktorių analizei testai. Tai nėra vieninteliai tinkami aprašymai, nes faktorių analizės rezultatai gali labai pakoreguoti aprašymą.

Siauresnis aprašymas prie metodikos aprašymo: „Siekdami patikrinti, kelis konstruktus sudaro (pavadinimas) klausimyno teiginiai, atlikome principinių komponentių faktorių analizę su *Varimax* sukiniu. Rezultatai parodė, kad duomenys tinka faktorių analizei: $KMO = 0,84$, o Bartleto sferiškumo testo $p < 0,005$ (gerai įvardyti, kokios turi būti KMO ribos ir koks – Bartleto sferiškumo testas). Faktorių analizės rezultatai leidžia teigti, kad klausimyno lietuviško varianto teiginiai sudaro tris faktorius (kaip ir nurodo klausimyno autoriai) ir paaiškina 69 proc. duomenų išsibarstymo. Faktorių svoriai kiekviename faktoriuje svyruoja nuo 0,72 iki 0,88.“

Platesnis aprašymas prie metodikos aprašymo: „Siekdami patikrinti, kelis konstruktus sudaro (pavadinimas) klausimyno teiginiai, atlikome principinių komponentių faktorių analizę taikydami *Varimax* sukinių. Rezultatai parodė, kad duomenys tinka faktorių analizei: $KMO = 0,84$, o Bartleto sferiškumo testo $p < 0,005$ (gerai įvardyti, kokios turi būti KMO ribos ir koks – Bartleto sferiškumo testas). Faktorių analizės rezultatai leidžia teigti, kad lietuviško varianto teiginiai sudaro tris faktorius (kaip ir nurodo klausimyno autoriai) ir paaiškina 69 proc. duomenų išsibarstymo. Kintamųjų faktorių svoriai kiekviename faktoriuje pateikti x lentelėje.“

Galimas aprašymas prie metodikos aprašymo, kai rezultatai prieštarauja originaliai metodikai: „Siekdami patikrinti, kelis konstruktus sudaro (pavadinimas) klausimyno teiginiai, atlikome principinių komponentių faktorių analizę taikydami *Varimax* sukinių. Rezultatai parodė, kad duomenys tinka faktorių analizei: $KMO = 0,84$, o Bartleto sferiškumo testo $p < 0,005$ (gerai įvardyti, kokios turi būti KMO ribos ir koks – Bartleto sferiškumo testas). Faktorių analizės rezultatai rodo, kad klausimyno lietuviško varianto teiginiai sudaro du faktorius (klausimyno autoriai nurodo tris) ir paaiškina 69 proc. duomenų išsibarstymo. 1, 2 ir 3 klausimai atsiranda faktoriuje,

x lentelė. (Pavadinimas) klausimyno teiginių faktorių analizės svoriai

Klausimai	Faktoriai		
	1 faktorius (pavadinimas)	2 faktorius (pavadinimas)	3 faktorius (pavadinimas)
1 klausimas	-0,65	0,14	0,43
2 klausimas	-0,03	-0,07	0,84
3 klausimas	-0,23	-0,20	0,68
4 klausimas	0,81	0,26	-0,18
5 klausimas	0,82	0,32	-0,01
6 klausimas	0,70	0,28	-0,08
7 klausimas	0,28	0,71	-0,07
8 klausimas	0,32	0,71	-0,03
9 klausimas	0,03	0,81	-0,19

kuriame yra 4, 5 ir 6 klausimai, nors, pasak autorių, tai turėtų būti du atskiri faktoriai. Vis dėlto, kad galėtume palyginti rezultatus, pakartojome faktorių analizę prieš tai nurodę SPSS programai klausimyno teiginius suskirstyti į tris faktorius. Bet ir atlikus šią analizę antrojo teiginio svoris susiklojo su pirmojo ir antrojo faktoriaus, tačiau tolesnėje analizėje šį teiginį vis tiek priskyrėme (pavadinimas) skalei, nes originaliame klausimyne tokio susiklojimo nėra ir šiame darbe lyginsime rezultatus su kitais tą patį klausimyną naudojusiais autorių darbais.“

Daugiau aprašymo pavyzdžių iš psichologijos srities galima rasti įvairiuose moksliniuose žurnaluose, kuriuose skelbiami moksliniai darbai. Yra nemažai darbų lietuvių, anglų ir kitomis kalbomis, pristatančių faktorių analizę ir jos rezultatus įvairių sričių psichologijos žurnaluose. Svarbu prisiminti, kad jei faktorių analizė yra mūsų tyrimo tikslas, tai tos analizės duomenys, dažnai ne vienos analizės, pateikiami dalyje „Rezultatai“ ir ji jau yra išsamesnė, nes turėtų būti nagrinėjami net ir smulkiausi niuansai.

5.1.14. Užduotis

Kokius ir kiek konstrukčių gali sudaryti visi prieraišumo kintamieji? Kiek faktorių geriausia turėti? Koks yra didžiausias ir mažiausias faktorių svoris vieno faktoriaus ribose (pvz., pirmo faktoriaus). Ar yra susiklojančių kintamųjų, kurie priklausytų keliems faktoriams? Padarykite tiriamąją faktorių analizę naudodami prieraišumo kintamuosius tik mergaitėms.

5.2. Patvirtinamoji faktorių analizė

Patvirtinamoji faktorių analizė (angl. *confirmatory factor analysis*) padeda tikrinti atskiras hipotezes apie tam tikrų konstrukty, faktorių struktūrą, kurią sudaro matuoti kintamieji, taip pat koreliacinius kelių latentinių (tiesiogiai nematuojamų) konstrukty ryšius. Tai yra tarsi jau numanome, kokie kintamieji kokį faktorių turi sudaryti, ir bandome tai patvirtinti. Pavyzdžiui, žinome, kad atminties užduotys turėtų atspindėti konstrukcinį intelektą, o panašumų ieškojimo užduotis – verbalinį intelektą. Tarsi jau žinome faktorius (latentinius kintamuosius) ir nurodome, koks kintamasis kuriam priklauso. Taigi tarsi klausiamo, ar tikrai vienas ar kitas kintamasis atspindi pasitikėjimą savimi. Patvirtinamoji faktorių analizė dažnai ir naudojama norint patikrinti atskirus konstruktus, skales, ar gerai sugrupuoti klausimai. Patvirtinamoji faktorių analizė yra viena iš struktūrinių lygčių modeliavimo sričių. Todėl ši faktorių analizė atliekama naudojant struktūrinių lygčių modeliavimu paremtus programinius paketus. Struktūrinių lygčių modeliavimas yra statistinė modeliavimo technika, naudojama įvairiuose moksluose. Tai tarsi faktorių, regresinės ir kelių analizės (angl. *path analysis*) kombinacija ar galimybė šiuos metodus analizuoti kartu. Struktūrinių lygčių modeliavimas labai dažnai naudojamas įvertinti teorinius konstruktus, latentinius faktorius, kurių tiesiogiai negalima išmatuoti patvirtinamosios faktorių analizės metodu.

5.2.1. Duomenų tinkamumas patvirtinamajai faktorių analizei

Duomenų tinkamumas atitinka tuos pačius reikalavimus kaip ir atliekant tiriamąją faktorių analizę. Vėl reikia įvertinti ryšius tarp kintamųjų. Taip pat svarbus turimos imties dydis. Svarbus ir naudojamų duomenų, kintamųjų normalus pasiskirstymas. Tačiau atliekant patvirtinamąją faktorių analizę galima analizuoti ir duomenis, nukrypusius nuo normalaus pasiskirstymo (tai yra galimybė pasirinkti kitą modelio vertinimo metodą, kuris labiau tinka duomenims, neatitinkantiems normalaus pasiskirstymo). Yra svarbu, kaip ir atliekant tiriamąją faktorių analizę, atsižvelgti į išskirtis ir jas įvertinti. Visuomet, prieš pradėdant bet kokią analizę, svarbu gerai išstudijuoti savo duomenis, kad būtų galima geriau parinkti vertinimo metodus ir tiksliai aprašyti kintamuosius programoms.

5.2.2. Struktūrinių lygčių programos

Yra keletas dažniausiai naudojamų struktūrinių lygčių programų – AMOS (Arbuckle, 2005), LISREL (Jöreskog and Sörbom, 2004), „Mplus“ (Muthén L. K. and Muthén B. O., 2006). Tai ne vienintelės struktūrinių lygčių modeliavimo programos. Kiekviena programa turi savų pranašumų ir trūkumų. Kuria programa dirbti, priklauso nuo tyrėjo. Vieni renkasi vienas, kiti – kitas programas. Čia pateiksiu tik modelius AMOS ir „Mplus“ programomis. AMOS programa leidžia piešti diagramas ir naudotis SPSS duomenų rinkmenomis. „Mplus“ programa nesuteikia galimybės piešti diagramas ar naudotis SPSS duomenų rinkmenomis. Čia duomenų rinkmenos turi būti perdaromos. Tačiau „Mplus“ programa turi kelis pranašumus dirbant su duomenimis, kuriuose yra praleistų reikšmių, ar duomenimis, kurie neatitinka normalaus pasiskirstymo. Taip pat šia programa galima atlikti tiriamąją faktorių analizę, jau nekalbant apie galimybes atlikti sudėtingas analizes (pvz., latentinių klasių analizę). AMOS programa turi bandomąją 14 dienų versiją. „Mplus“ programos kūrėjai suteikia teisę neribotą laiką naudotis demonstracine versija, tačiau ribojamas kintamųjų skaičius – galimi tik 6 priklausomieji ir 2 nepriklausomieji kintamieji. AMOS programą ir bandomąją versiją galima rasti www.ibm.com (ieškoti prie programų arba paieškos lauke įvesti AMOS). „Mplus“ programą ir demonstracinę versiją galima rasti www.statmodel.com. Šiame puslapyje taip pat yra įvairių straipsnių ir įvairių modelių vertinimo sintaksės pavyzdžių.

5.2.3. Modelio vaizdavimas


Kiekvienas testuojamas, analizuojamas ar vertinamas struktūrinių lygčių modelis turi turėti teorinį pagrindimą. Be teorinio pagrindimo negalima įrodyti jokio modelio teisingumo, pavyzdžiui, kodėl vienas kintamasis priskirtas būtent tam latentiniam faktoriui, o ne kitam. Visi struktūrinių lygčių modeliavimo modeliai, ir patvirtinamosios faktorių analizės, ir kiti, dažniausiai vaizduojami piešiniais – diagramomis. Kai kurios programos ir piešia modelius, diagramas (pvz., naudojant AMOS programą galima sudėlioti norimo modelio diagramą), tačiau kitose programose nesuteikia galimybės piešti, bet leidžia diagramą aprašyti (pvz., „Mplus“ programa piešimo funkcijos neturi ir diagramą reikia aprašyti pasitelkus sintaksę). Modelio diagrama – tai jo pavaizdavimas priimtina ženklų sistema. Diagrama padeda skaitantiesiems suprasti, koks modelis yra tikrinamas. Modeliuojant struktūrines lygtis yra naudojami dviejų tipų kintamieji – matavimų arba stebimieji (kurie yra tiesiogiai matuojami skalių klausimais, klausimynais, tam tikromis priemonėmis)

ir latentiniai (jie tiesiogiai nėra matuojami, o sukuriami ir autorius kelia prielaidą, kad jie yra). Matavimų kintamieji diagramose žymimi kvadratu arba stačiakampiu, o latentiniai kintamieji – apskritimu ar ovalu. Matavimų ir latentinių kintamųjų pavadinimai gali būti trumpinami, žymimi viena raide ar rašomas visas pavadinimas keturkampio ar ovalo viduryje.

Matavimų / stebimasis kintamasis



Latentinis kintamasis



Ryšiai tarp kintamųjų žymimi linijomis su rodyklėmis. Atliekant patvirtinamąją faktorių analizę dažnai vertinami koreliaciniai ryšiai tarp faktorių, jei modelyje jų yra keletas. Koreliaciniai ryšiai vaizduojami linija su abiejuose jos galuose esančiomis rodyklėmis arba linija be rodyklių.

Koreliacija



Ryšys tarp latentinio ir matavimų / stebimojo kintamojo vaizduojamas linija su viename gale esančia rodykle. Tokios linijos rodo esant vienusį priežastinį ryšį, tačiau patvirtinamosios faktorių analizės modeliuose tokios vienusės linijos tarp matavimų ir latentinių kintamųjų nėra vadinamos priežastinio ryšio linijomis, nes latentinis faktorius nenulemia matavimų kintamųjų. Šios linijos literatūroje dažniausiai vadinamos faktorių svoriais. Atliekant patvirtinamąją faktorių analizę tokios linijos visuomet vaizduojamos nuo latentinio faktoriaus į matavimų / stebimąjį kintamąjį, nes patvirtinamosios faktorių analizės modeliais daroma prielaida, kad latentinio faktoriaus elementai yra jau turimi matavimų kintamieji, kurie atspindi sudaromą latentinį faktorių, tačiau visada reikia atsiminti, kad ne viskas pamatuota, todėl gali būti ir daugiau neišmatuotų kintamųjų, kurie atspindėtų tą patį latentinį faktorių.

Vienusis priežastinis ryšys

(tačiau patvirtinamojoje faktorių analizėje tai faktoriaus svoris)



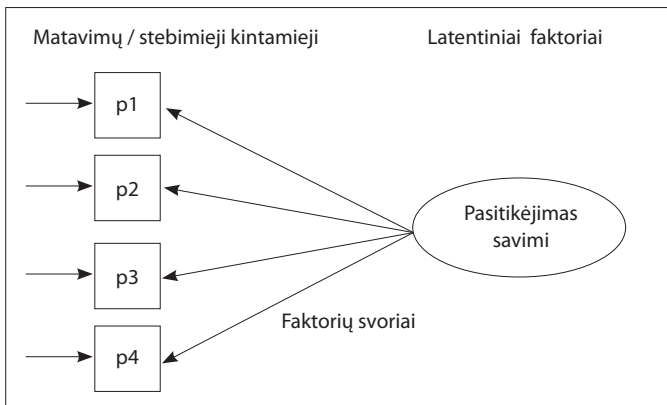
Paklaidos (dar vadinamos liekamosiomis paklaidomis) yra svarbus modelio komponentas. Jos taip pat vaizduojamos diagramoje. Kiekvienas matavimas yra susijęs su tam tikra paklaida, nėra nė vieno tobulo matavimo. Paklaida – tai variacijos

kiekis, kurio matavimų / stebimasis kintamasis nepaaiškina būdamas tam tikro latentinio kintamojo dalis. Paklaidos žymimos trumpa rodykle į matavimų kintamąjį arba mažu apskritimu ir trumpa rodykle į matavimų kintamąjį.

Paklaida ir matavimų / stebimasis kintamasis

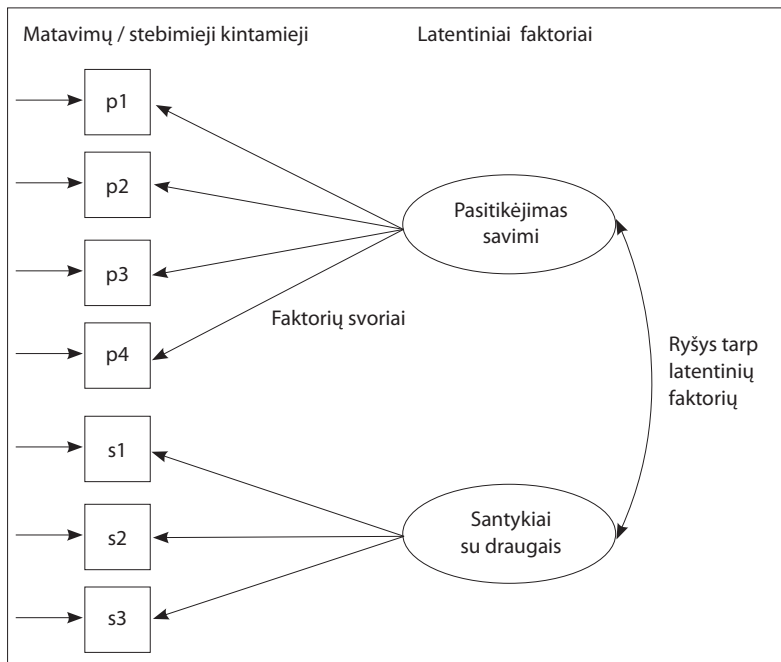


Modelio diagrama dažniausiai pateikiama ir publikacijose ar mokslo darbuose, tad ją reikia korektiškai parengti. Labai dažnai ir gauti rezultatai pristatomi diagramomis. Tarkim, savo tiriamiesiems davėme atsakyti į keturis klausimus apie pasitikėjimą savimi ir norime įvertinti, ar tikrai pateikti klausimai atspindi pasitikėjimą savimi. Tokį modelį vaizduotume kaip pateikta 59 pav. p1–p4 klausimai, kuriuos davėme tiriamiesiems apie pasitikėjimą savimi, vaizduojami keturkampiais ar stačiakampiais ir turi paklaidas (mažos rodyklės). Šie matavimų / stebimieji kintamieji atspindi vieną latentinį kintamąjį (jo pavadinimą reikia sukurti patiems).



59 pav. Vieno faktoriaus modelio diagrama ir jos paaiškinimas

O jei savo tiriamiesiems dar davėme tris klausimus apie santykius su draugais ir norime įvertinti, ar tikrai pateikti klausimai atspindi santykius su draugais, šalia p1–p4 kintamųjų, kurie sudaro vieną latentinį kintamąjį – pasitikėjimas savimi, pridėdame s1–s3 kintamuosius, kurie sudarys antrą latentinį kintamąjį – santykiai su draugais. Taip pat norime įvertinti ryšį (koreliaciją) tarp pasitikėjimo savimi ir santykių su draugais. Tokį modelį vaizduotume kaip pateikta 60 pav. Visi p1–p4 klausimai apie pasitikėjimą savimi, kuriuos davėme tiriamiesiems, vaizduojami keturkampiais ar stačiakampiais ir turi paklaidas (mažos rodyklytės). s1–s3 duoti klausimai apie santykius su



60 pav. Dviejų faktorių modelio diagrama ir jos paaiškinimas

draugais taip pat vaizduojami keturkampiais ir turi paklaidas. Šie matavimų / stebimieji kintamieji atspindi du latentinius faktorius. Dažnai tyrėjai pradeda nuo vieno latentinio faktoriaus sudarymo modelio, o tik paskui testuoja kitą modelį, kur yra pridedami nauji latentiniai kintamieji ir vertinami ryšiai tarp latentinių kintamųjų.

5.2.4. Modelio identifikavimas

Kai žinome, kokį modelį norime patikrinti (t. y. turime diagramą), prieš paleidžiant struktūrinių lygčių modeliavimo programą reikia išsiaiškinti, ar modelis identifikuojamas, tai yra ar jis toks įmanomas. Reikia žiūrėti, ar turime pakankamai informacijos kintamųjų parametrus įvertinti (Čekanavičius ir Murauskas, 2009). Parametrai yra pagrindiniai modelio elementai (labai dažnai tai visos rodyklės diagramoje), jie atspindi, kas tyrėjui nėra žinoma, tačiau ką jis nori apskaičiuoti.

Modeliuojant struktūrines lygtis parametrai yra nežinomi reiškinio / fenomeno aspektai, kuriais domimės. Tai tarsi visos vietos modelyje, kurias norime įvertinti. Modelio identifikacija pasako, ar toks modelis galimas, ar jį tikrai galima įvertinti, tačiau tikrai nepasako, kokios klaidos galimos, ar visi parametrai bus apskaičiuoti. Gali būti, kad modelis identifikuojamas, tačiau atskiri parametrai nebus identifikuojami

(pvz., nebus pateikti tam tikri faktorių svoriai ar koreliacijos). Jei modelyje yra bent vienas toks parametras, geriau nepasitikėti tokiais skaičiais. Kad parametras neidentifikuojamas, galima matyti iš programos pateiktų skaičiavimų (toje vietoje, kur negali identifikuoti parametro, programa dažnai nepateikia skaičių, sužymi tik žvaigždutes arba pateikia labai didelius skaičius). Viena iš būtinų modelio identifikavimo sąlygų – t taisyklė, ji taikoma visiems paprastesniems modeliams ir galima net nepradėjus dirbti ta programa pažiūrėti, ar ji galės įvertinti tokį modelį (Kelloway, 1998).

T – taisyklė: $t \leq [(q)(q + 1)]/2$; čia q – matavimų / stebimieji kintamieji modelyje, t – vertinami modelio parametrai (reikėtų suskaičiuoti visas modelio vietas, kurias norėsime apskaičiuoti). Dviejų faktorių modelis 59 pav. (kur yra pasitikėjimo ir santykių su draugais latentiniai kintamieji) turi 7 (šioje taisyklėje atitinka q) matavimų / stebimuosius kintamuosius, tai $[(q)(q + 1)]/2 = [(7)(7 + 1)]/2 = 28$. Vadinasi, vertinamų modelio parametru negali būti daugiau negu 28. O kiek yra vertinamų parametru? Vertinami modelio parametrai (paprastiau tarti juos esant modelio elementus, kuriuos norima apskaičiuoti): 7 faktorių svoriai, 7 paklaidos ir viena koreliacija. Tad t ir bus šių parametru suma – 15. O $15 \leq 28$, vadinasi, modelis identifikuojamas ir galima pradėti dirbti ta programa. Skirtumas tarp $[(q)(q + 1)]/2$ ir t atitinka modelio laisvės laipsnius (df). Tad šiame modelyje $df = 28 - 15 = 13$. Modeliai, kurie nebus identifikuojami, turės neigiamą laisvės laipsnių reikšmę. Taip dažniausiai skaičiuojami modelių, tikrinamų „Mplus“ programa, parametrai. Knygoje, kuriose modeliai pristatomi, parametru skaičiavimas AMOS programa šiek tiek skiriasi. Naudojant šią programą, kiekvieno latentinio faktoriaus vienas iš svorių fiksuojamas vienetu, taigi skaičiuojami vertinami parametrai: 5 faktorių svoriai (tokiu atveju fiksuojama po vieną abiejų latentinių faktorių kintamąjį ir jie neskaičiuojami), 7 paklaidos, viena koreliacija tarp latentinių kintamųjų ir dvi latentinių faktorių dispersijos (jos skaičiuojamos vietoje prarastų faktorių svorių). Rezultatas tas pats, tik skaičiavimas skiriasi.

5.2.5. Modelio parametru įvertinimas

Kai žinome, kokį modelį norime įvertinti (t. y. turime diagramą), ir apskaičiavome, kad modelį programa turėtų įvertinti (t. y. taikėme t taisyklę), galime pradėti dirbti naudodami struktūrinių lygčių programą. Tikrindami modelį norime žinoti, ar tas modelis galimas realiame gyvenime, ar jis tinka mūsų surinktiems duomenims. Programos, vertindamos modelį, tikrina, ar modelis tinka duomenims. Jos iš turimų duomenų skaičiuoja idealaus modelio koreliacijas ir jas prilygina turimoms koreliacijoms tarp kintamųjų, kurie naudojami modelyje. Kitaip tariant, skaičiuojama,

ar kintamųjų koreliacijos atitinka idealias koreliacijas. Tai ir yra parametru įvertinimas. Modeliuojant struktūrines lygtis yra skiriami įvairūs modelių įvertinimo metodai. Vienas jų yra didžiausiojo tikėtino metodo (angl. *Maximum likelihood*). Šis metodas tinka normaliai pasiskirsčiusiems duomenims, tačiau jei imtis didelė, tai normalus duomenų pasiskirstymas nėra toks svarbus ir šį metodą galima taikyti. Didžiausiojo tikėtino metodo yra dažniausiai pasitelkiamas. Jis pasirenkamas kaip išankstinis visų SEM programų nustatymas. FIML (angl. *Full information maximum likelihood*) taip pat dažnai taikomas, kai naudojamuose duomenyse yra praleistų reikšmių (Raykov and Marcoulides, 2006), pavyzdžiui, ne visi tiriamieji atsakė į tam tikrus klausimus, ir jas norima įtraukti į analizę. Tad, kai trūksta duomenų, kai kurios programos nebūtinai reikalauja vietoje jų įrašyti kokią nors reikšmę (tarkim, vidurkius), bet galima naudoti FIML. MLR (angl. *Maximum likelihood robust*) gerai naudoti, kai imtis maža arba duomenys nėra normaliai pasiskirstę (Raykov and Marcoulides, 2006). ULS (angl. *Unweighted least squares*) tinka, kai kintamųjų matavimo skalės panašios ir dažnai naudojamas, kai imtis labai didelė (Kline, 2005). GLS (angl. *Generalized least squares*) tinka simetriškai, bet nenormaliai pasiskirsčiusiems duomenims (Shapiro and Browne, 1987). ADF (angl. *Asymptotically distribution free*) naudojama, kai imtis didelė ir duomenys nėra normaliai pasiskirstę (Kline, 2005). WLS (angl. *Weighted least squares*) tinka, kai kintamieji yra kategoriniai ar ranginiai duomenys (Kline, 2005).

5.2.6. Modelio tinkamumas

Modelio tinkamumo koeficientai. Kai programa jau vertina modelį, svarbu nustatyti, kaip jis tinka turimiems duomenims. Modelio tinkamumas – tai testuojamo modelio tinkamumas turimiems duomenims. Modelio tinkamumą gali lemti dauguma faktorių, vienas jų yra kintamieji. Kintamieji turi būti patikimi ir validūs. Kintamieji taikant patvirtinamąją faktorių analizę gali būti atskiri klausimai, atskiros jau sudarytos skalės ir naudojami kaip matavimų kintamieji. Nors visi modelio tinkamumo kriterijai rodo, kad modelis geras, negalima tvirtinti, jog tai vienintelis geras modelis turimiems duomenims. Gali būti ir kitų panašių modelių, kurie gerai tinka tiems duomenims. Kuris iš kelių modelių geresnis, galima spręsti pasitelkus statistiką, tačiau reikia nepamiršti teorinių svarstymų. Modelio tinkamumui įvertinti naudojami įvairūs kriterijai. Skirtingos programos pateikia nevienodą skaičių kriterijų, kuriais remiantis galima įvertinti modelio tinkamumą duomenims. Chi kvadratas (χ^2) pateikiamas visose programose. Chi kvadratas – tai nulinės hipotezės, kuri rodo, kad modelis idealiai tinka turimiems duomenims, tikrinimas.

Jei chi kvadrato p reikšmė yra mažiau negu 0,05, tai nulinė hipotezė (modelis idealiai tinka duomenims) atmetama. Reikšmingas chi kvadratas ($p < 0,05$) įspėja, kad modelis mažai tinka duomenims, o nereikšmingas chi kvadratas ($p > 0,05$) rodo, kad modelis gerai tinka duomenims. Nurodoma, kad χ^2 jautrus imties dydžiui ir tampa reikšmingas didėjant imčiai (dažniausiai, jei imtis daugiau kaip 100, chi kvadratas gali būti reikšmingas). Tad vieno chi kvadrato niekas neskelbia, visuomet pateikiami ir kiti modelio tinkamumo indeksai (Raykov and Marcoulides, 2006).

Kitas darbuose dažniausiai skelbiamas kriterijus, į kurį siūloma atsižvelgti, – vidutinės aproksimacijos paklaidos kvadratinė šaknis (angl. *Root Mean Square Error of Approximation* (RMSEA)) (Steiger and Lind, 1980). RMSEA nėra labai jautri imties dydžiui, tačiau jautri modelio kompleksiskumui, tad kuo modelis sudėtingesnis, tuo šis kriterijus gali būti prastesnis. Kuo RMSEA reikšmė arčiau 0, tuo šis kriterijus geresnis, o modelis labiau tinka duomenims. RMSEA reikšmė mažiau negu 0,05 rodo, kad modelis geras, nuo 0,05 iki 0,08 – priimtinas, nuo 0,08 iki 0,10 – galimas, tačiau reikėtų patikrinti, ar nėra geresnių modelių (Browne and Cudeck, 1993).

Sąlyginis suderintumo kriterijus (angl. *Comparative-fit index* (CFI)), kaip ir RMSEA, lygina tikrinamą modelį su nuliniu modeliu (tai modelis, kuriame nėra jokių ryšių tarp kintamųjų) (Bentler, 1990). CFI reikšmės arčiau 1 rodo, kad modelis geras. Jei reikšmės $> 0,90$, – modelis tinkamas, jei $> 0,95$ – geras (Kline, 2005). Takerio ir Liuiso indeksas (angl. *Tucker-Lewis index* (TLI)), panašiai kaip CFI, lygina tikrinamą modelį su nuliniu modeliu. Takerio ir Liuiso indekso reikšmės taip pat interpretuojamos kaip CFI: jei reikšmės $> 0,90$, modelis tinkamas, jei $> 0,95$ – geras (Raykov and Marcoulides, 2006).

Kiekvienas struktūrinių lygčių modeliavimo programinis paketas pateikia įvairius modelio tinkamumo kriterijus, pavyzdžiui: GFI, AGFI, NFI, NNFI kriterijų reikšmės turi būti daugiau kaip 0,90, jei $> 0,95$ – modelis geras (Hu and Bentler, 1999); *Akaike Information Criterion* (Akaike, 1987) naudojamas lyginant skirtingus modelius, kai norima atrinkti geriausiai tinkantį modelį pasitelkus ne tik chi kvadrato testą. Tad svarbu įvertinti tikrinamo modelio tinkamumą, tačiau dar svarbiau, kad modelyje visi keliai ir ryšiai tarp kintamųjų būtų teoriškai pagrįsti. Vertinant modelio tinkamumą reikia atsižvelgti ne tik į suderinamumo indeksus, bet ir į ryšius tarp parametrų, jų ženklus, standartinių paklaidų dydžius.

Įverčiai. Modelio tinkamumo koeficientai įvertina modelio visumą, tačiau tai neužtikrina atskirų modelio dalių tinkamumo duomenims. Svarbu įvertinti ir atskiras modelio dalis. Atskiros modelio dalys, tiksliau, atskiri modelio parametrų koeficientai gali būti ne visai teisingi arba klaidinantys. Tad atsižvelgti vien į tinkamumo

koeficientus neužtenka. Svarbu peržiūrėti visus modelio įverčius – faktorių svorius, koreliacijas, regresijos koeficientus (jei turima tokių modelių), liekamąsias paklaidas. Reikėtų atkreipti dėmesį į liekamąsias paklaidas – jos negali būti didesnės kaip 1. Jei šios paklaidos didesnės už vienetą, būtina peržiūrėti visus modelio parametrus ir patikrinti, ar nėra labai stiprių koreliacijų tarp kintamųjų, ar kintamieji tikrai susiję tiesiniais ryšiais. Visi standartizuoti modelio parametrai negali būti didesni nei 1 (Raykov and Marcoulides, 2006). Modelio įverčiai (jei jie netinkami) gali rodyti, kad pažeistos patvirtinamosios faktorių analizės prielaidos: duomenų normalumas, tvirtos koreliacijos tarp matavimo kintamųjų, išskirčių buvimas.

5.2.6. Matavimų kintamųjų skaičius

K. A. Bollen (1989) teigė, kad kiekvienas latentinis kintamasis turėtų turėti bent du matavimų kintamuosius (dviejų indikatorių taisyklė). Tačiau, turint tik du matavimų kintamuosius kiekvienam latentiniam kintamajam, gali kilti didesnių modelio įvertinimo problemų, ypač kai imtis yra maža. Tad rekomenduojama turėti bent tris matavimų kintamuosius vienam latentiniam kintamajam (Kline, 2005). Tačiau būna taip, kad turime nemažai matavimų kintamųjų ir norime juos priskirti vienam matavimų kintamajam. Tarkime, turime 20 kintamųjų, klausimų apie santykius su draugais. Ką tuomet daryti? Yra keletas galimų būdų, tačiau kuris tinka, tyrėjas turi nuspręsti pats, atsižvelgdamas į savo duomenis, modelį ir tiriamųjų skaičių.

Galima naudoti 20 matavimų kintamųjų vienam latentiniam kintamajam. Tai nėra blogas būdas, ypač jei modelis nedidelis, nebus daug latentinių kintamųjų, turinčių tokią didelį matavimų kintamųjų skaičių. Tačiau jei modelyje būtų 10 latentinių kintamųjų ir jie visi turėtų po 20 matavimų kintamųjų, tai jau būtų sudėtinga ir reikėtų galvoti apie matavimų kintamųjų sumažinimą. Tai nėra lengvas būdas, bet tyrėjų dažnai naudojamas. Pirmiausia reikėtų atlikti patvirtinamąją faktorių analizę imant visus 20 matavimų kintamųjų ir vieną latentinį kintamąjį. Jei galutiniame modelyje yra daugiau latentinių ir matavimų kintamųjų, jie į analizę neįtraukiami ir mažinamas kiekvieno latentinio kintamojo matavimų kintamųjų skaičius atskirai. Atlikę vieno latentinio kintamojo ir, tarkim, 20 matavimų kintamųjų patvirtinamąją faktorių analizę ir gavę faktorių svorius, pasirenkame kintamuosius, kurių faktorių svoris didžiausias ir mažiausias. Iš šių dviejų kintamųjų, naudodami SPSS programą, sukursime naują kintamąjį (skaičiuosime jų vidurkį). Tada pasirenkame kitus du kintamuosius, kurių faktorių svoris didžiausias ir mažiausias, ir iš jų SPSS programa sukursime naują kintamąjį (skaičiuosime jų vidurkį). Taip darysime ir su likusiais. Taigi iš 20 jau gausime 10 kintamųjų. Tada kartojame patvirtinamąją faktorių analizę, tik kaip matavimų kin-

tamuosius jau naudojame turimus 10 naujų kintamųjų. Ir vėl iš šios analizės pasirenkame kintamuosius, turinčius didžiausią ir mažiausią faktorių svorį. Iš šių dviejų kintamųjų SPSS programa sukursime naują kintamąjį (skaičiuosime jų vidurkį). Tada vėl pasirenkame kitus du kintamuosius, kurių faktorių svoris didžiausias ir mažiausias, ir iš jų SPSS programa sukursime naują kintamąjį (skaičiuosime jų vidurkį). Taip padarome su visais likusiais. Tada iš 10 kintamųjų turėsime jau 5. Jei tai paranku, galime naudoti tuos 5 matavimų kintamuosius arba dar kartą atlikti šių 5 matavimų kintamųjų patvirtinamąją faktorių analizę, vėl pasirinkti kintamuosius, kurių faktorių svoriai didžiausias ir mažiausias ir iš jų sukurti naują kintamąjį (skaičiuoti jų vidurkį). Tada pasirinksime antrą didžiausią ir antrą mažiausią faktorių svorį turintį kintamąjį ir juos sujungsime. Likusį vieną kintamąjį paliksime vieną, jo su kitu neįjungsime. Taigi turėsime tris galutinius matavimų kintamuosius, kuriuos ir naudosime modelyje. Visuomet galima sujungti matavimų kintamuosius ne pagal didžiausią ir mažiausią faktorių svorį, bet pagal prasmę, ir taip konstruoti tris matavimų kintamuosius. Reikėtų prisiminti, kad matavimų kintamųjų skaičių sumažinti prasminga tada, kai modelyje žada būti nemažai latentinių kintamųjų, kuriems priskirsime didelį skaičių matavimų kintamųjų. Bet norint patikrinti, ar 20 kintamųjų sudaro vieną latentinį faktorių, tikrai nereikėtų mažinti matavimo kintamųjų skaičiaus.

5.2.7. Dviejų modelių lyginimas

Labai dažnai tikrinamas ne vienas modelis, o keli, t. y. pridėjus naujų matavimo kintamųjų ar naujų latentinių kintamųjų ir panašiai. Tikrinant kelis modelius svarbu juos tarpusavyje palyginti ir pasakyti, ar tie modeliai statistiškai skiriasi ar ne, ar vienas iš jų statistiškai geresnis ir tinkamesnis. Dviejų modelių lyginimas remiasi chi kvadratu (Hoyle and Panter, 1995). Pirmiausia testuojame vieną modelį (pvz., tikriname tik pasitikėjimo savimi konstrukta, neįtraukdami santykių su draugais konstrukto) ir pasižymime gautą chi kvadratą (χ^2) bei laisvės laipsnius (df), o tada testuojame kitą modelį (pvz., kur yra abu konstruktai – pasitikėjimas savimi ir santykiai su draugais) ir vėl pasižymime gautą šio modelio chi kvadratą ir laisvės laipsnius (df). O tada iš antrojo chi kvadrato atimame pirmą ir iš antrojo laisvės laipsnio atimame pirmojo laisvės laipsnius. Tarkim, pirmojo modelio chi kvadratas lygus 8,1 ir df = 2, o antrojo $\chi^2 = 17,1$ ir df = 13. Tada atimame: $\Delta \chi^2 = 17,1 - 8,1 = 9$, $\Delta df = 13 - 2 = 11$. Atlikę šiuos skaičiavimus žiūrime į chi kvadrato lentelę, kurią galime rasti daugumoje statistikos vadovėlių ar internete, ir surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 11 laisvės laipsnių (61 pav.). Tada ir

df	$\chi^2_{.995}$	$\chi^2_{.990}$	$\chi^2_{.975}$	$\chi^2_{.950}$	$\chi^2_{.900}$	$\chi^2_{.100}$	$\chi^2_{.050}$	$\chi^2_{.025}$	$\chi^2_{.010}$	$\chi^2_{.005}$
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
5	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
6	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
7	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
8	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
9	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
10	2.156	2.558	3.247	3.940	4.865	15.987	18.307	20.483	23.209	25.188
11	2.603	3.053	3.816	4.575	5.578	17.275	19.675	21.920	24.725	26.757
12	3.074	3.571	4.404	5.226	6.304	18.549	21.026	23.337	26.217	28.300
13	3.565	4.107	5.009	5.892	7.042	19.812	22.362	24.736	27.688	29.819
14	4.075	4.660	5.629	6.571	7.790	21.064	23.685	26.119	29.141	31.319
15	4.601	5.229	6.262	7.261	8.547	22.307	24.996	27.488	30.578	32.801

61 pav. Chi kvadrato lentelė (iš Howell, 1997)

nustatome, ar skirtumas tarp modelių yra statistiškai reikšmingas, ar vienas modelis pagal statistinius rodiklius geresnis negu kitas. Standartiškai chi kvadratų lentelėse viršuje yra reikšmingumo lygmenys (reikėtų susirasti $p = 0,05$), o dešinėje – laisvės laipsniai (df). Juos šiuo atveju galima susirasti prie laisvės laipsnių 11. Esant 11 laisvės laipsnių, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05, chi kvadrato skirtumas turėtų būtų 19,675 ir daugiau. Tačiau šiuo atveju chi kvadrato skirtumas yra tik 9, tad modeliai statistiškai nesiskiria ir renkamės tą, kuris geriau atspindi turimas teorines idėjas.

Dažniausiai du modeliai tarpusavyje lyginami skaičiuojant chi skirtumą. Kaip du modeliai lyginami tarpusavyje, taip testuodami vieną dviejų grupių (pvz., berniukų ir mergaičių) modelį naudojamės chi kvadrato skirtumu.

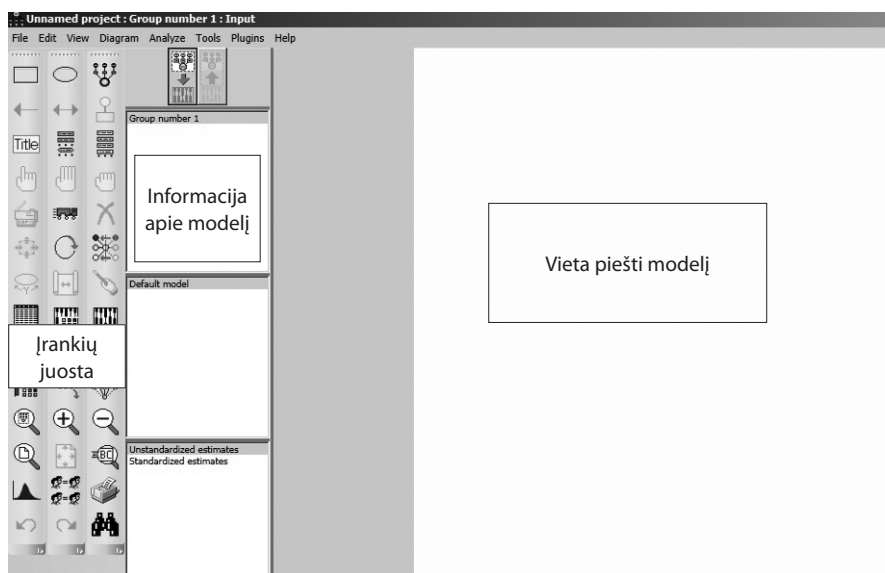
5.2.8. Modelio modifikavimas

Modifikavimas – tai modelio tobulinimas. Tačiau reikėtų prisiminti, kad modelio tobulinimas turi remtis ne tik statistiniais skaičiavimais, bet ir teorinėmis prielaidomis. SEM programos skaičiavimų pagalba pati pasiūlo modelio modifikacijas – modifikavimo indeksus (MI). Jų reikšmės parodo, kiek gali sumažėti chi kvadrato reikšmė, į modelį įtraukus nurodytą ryšį tarp kintamųjų ar tam tikrus suvaržymus (Hoyle and Panter, 1995). Visuomet verta peržiūrėti programos pasiūlymus, tačiau priimant sprendimus atsižvelgtina į teorines modelio prielaidas. Reikėtų įvertinti modifikacijos indeksus, kurių reikšmė didžiausia. Kai kurios SEM programos pateikia tik modifikacijos indeksus, kurie yra didesni nei 3,84, nes per šį skaičių du modeliai gali skirtis statistiškai reikšmingai (tai parodo chi kvadrato skirtumas), kai

modelio df pakinta vienu laipsniu. Padarius siulomus (ir teoriškai logiškus) pakeitimus, naujas modelis lyginamas (žr. „Dviejų modelių lyginimas“) su ankstesniu ir žiūrima, ar jis statistiškai geresnis negu pirminis, ar ne. Jei statistiškai geresnis, tai pakeitimai paliekami, jei nėra geresnis, galima pakeitimus palikti arba ne (čia jau pasikliaujama teoriniais svarstymais).

5.2.9. Patvirtinamosios faktorių analizės atlikimas, naudojantis AMOS programa

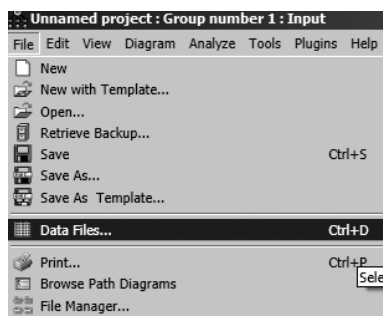
Tik pradėjus dirbti AMOS programa, geriausia naudotis grafine jos išraiška. Paleidus programą atsidaro langas, kuriame kairėje pusėje matyti papildoma įrankių juosta, o dešinėje – vieta dėlioti / piešti tikrinamą modelį (62 pav.). Per vidurį esančiuose langeliuose bus pateikiama informacija apie modelį. Atliekant visas pagrindines funkcijas (pateikiant duomenų rinkmeną, pasirenkant analizę, peržiūrėti duomenų išvesties langą) galima naudotis grafinais paveikslėliais iš įrankių juostos arba tai padaryti naudojantis meniu įrankiais.



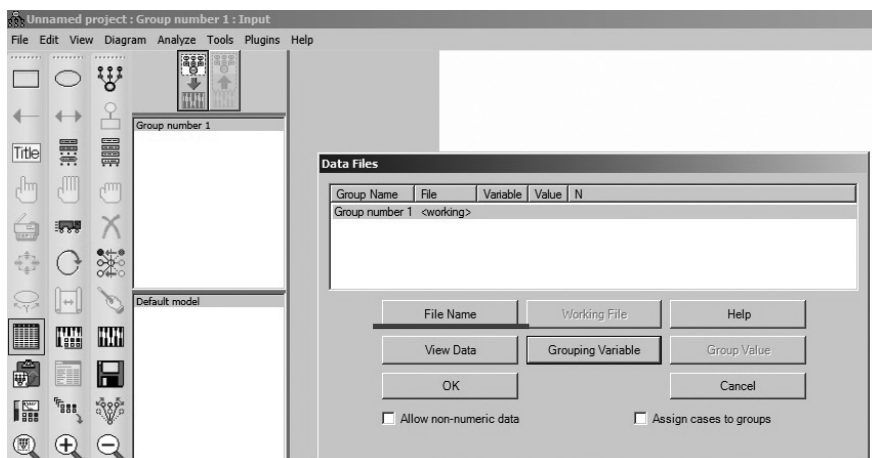
62 pav. AMOS programos pagrindinis langas

AMOS programai pateikiame SPSS rinkmenose esančius duomenis. Atidarę šią programą, turime pateikti duomenis, kurių reikės modeliui kurti. Per meniu įrankius programai pateikiame duomenų rinkmeną (*File – Data Files*) (63 pav.).

Paspaudus nuorodą „Duomenų rinkmenos (angl. *data files*), atsiranda naujas langas, kuriame prašoma nurodyti duomenų rinkmeną ir jos vietą (64 pav). Tam naudojama nuoroda „Rinkmenos vardas“ (angl. *file name*). Paspaudus šią nuorodą, atsidaro langas, kuriame susirandame savo rinkmeną, kur ją saugome. Ieškome taip pat, kaip ir bet kurios kitos rinkmenos kompiuteryje. AMOS pirmiausia ieško SPSS duomenų rinkmenų (.sav), tačiau gali mas ir kitoks formatas, tarkim, „Excel“ programa sudarytos rinkmenos (.xls).



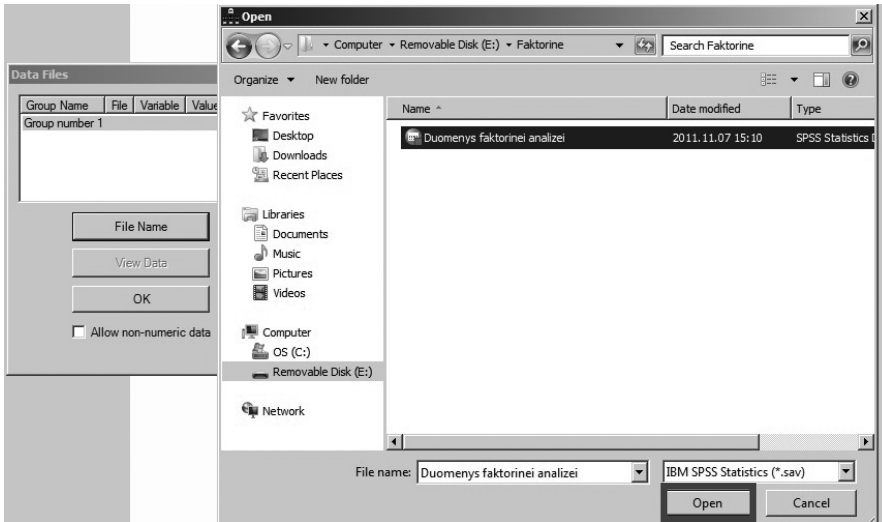
63 pav. Duomenų rinkmenos pateikimo nuoroda



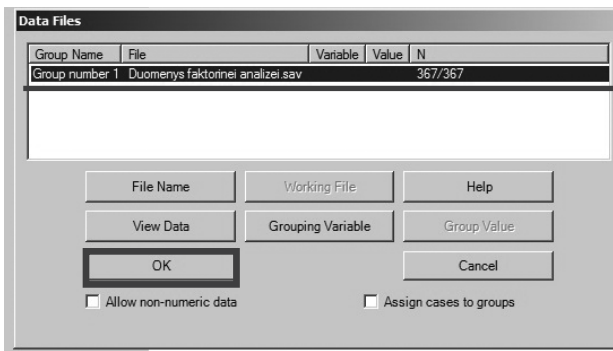
64 pav. Duomenų rinkmenos suradimas

Suradus reikiamą rinkmeną, spaudžiamas mygtukas „Atidaryti“ (angl. *open*) (65 pav.).

Tada pirminiame lange ir matome savo duomenų rinkmenos pavadinimą. Jei taip yra, tai duomenys programai jau nurodyti ir spaudžiame mygtuką OK (66 pav.).



65 pav. Duomenų rinkmenos atidarymas

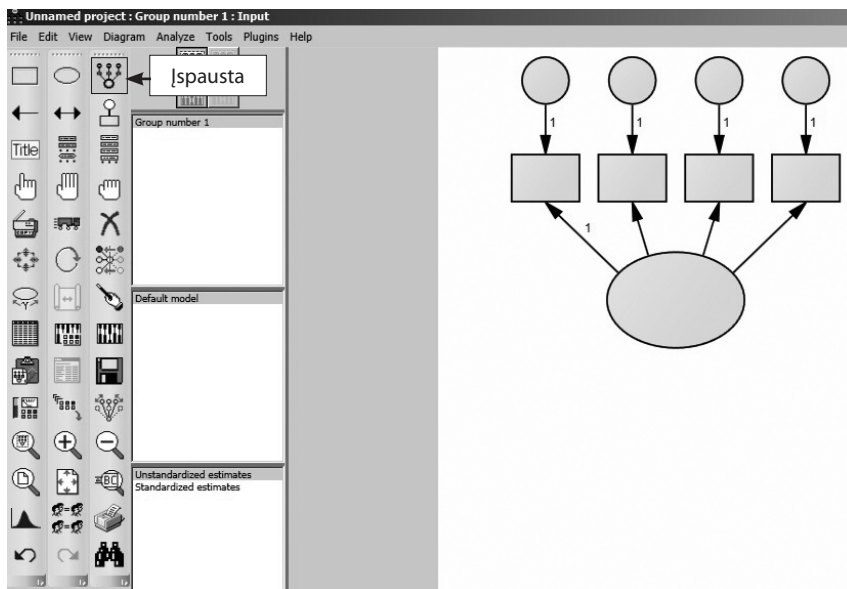


66 pav. AMOS programai nurodyta duomenų rinkmena

Kai programa jau turi duomenų rinkmeną, reikia grafiškai pavaizduoti modelį, kurį norime patikrinti, tai yra nubraižyti diagramą. Geriausia naudotis įrankiais, kurie yra kairėje pusėje – tiesiog perpiešti paveikslėlių iš esančiųjų kairėje pusėje į programą.







Viršutiniai trys AMOS programos grafiniai paveikslėliai yra skirti kintamiesiems kurti. Kvadratas atspindi matavimų / stebimuosius kintamuosius, ovalas – latentinius, o paskutinis grafinis indeksas skirtas latentiniams matavimų kintamiesiems kurti. Kuriant latentinius kintamuosius galima naudotis pirmais dviem ar paskutiniu paveikslėliu. Tarkime, norime patikrinti, ar p1–p4 kintamieji tikrai sudaro pasitikėjimo savimi faktorių. Tai yra turime keturis matavimų kintamuosius (p1–p4) ir vieną latentinį (pasitikėjimas savimi) kintamąjį. Naudojamiesi paskutiniu įrankiu, skirtu latentiniam kintamajam ir matavimų kintamiesiems



67 pav. Grafinis modelio vaizdas

kurti, jį paspaudžiame ir dešinėje pusėje pelės paspaudimu gausime latentinį kintamąjį ir vieną matavimų kintamąjį. Norėdami sukurti daugiau matavimų kintamųjų, pelę spaudžiame tiek kartų, kiek turime kintamųjų (šiam pavyzdyje būtų keturi) (67 pav.). Kai grafine išraiška nebesinaudojame, ją, grįžus į kairę pusę, reikia dar kartą paspausti.

Šiame modelyje yra tik keturi matavimų / stebimieji kintamieji, kuriuos atspindi vienas latentinis kintamasis. Tad daugiau nieko piešti nereikia. Jei norime atlikti dar kitus veiksmus (pvz., ką nors ištrinti ar pridėti), galime naudotis kitais įrankiais. Jie atlieka įvairias funkcijas.

	Piešti matavimų / stebimąjį kintamąjį		Kintamųjų sąrašas duomenų rinkmenoje
	Piešti latentinį kintamąjį		Pažymėti vieną objektą
	Piešti latentinį kintamąjį ir matavimų kintamuosius		Pažymėti visus objektus
	Priežastinis ryšys		Panaikinti žymėjimus
	Koreliacija		Dubliuoti objektus
	Pavadinimas		Judinti objektus
	Kintamųjų sąrašas modelyje		Ištrinti objektus



Pakeisti objektų formą



Pasukti latentinio kintamojo matavimų kintamuosius



Pasirinkti duomenų rinkmeną



Analizės savybės / ypatumai

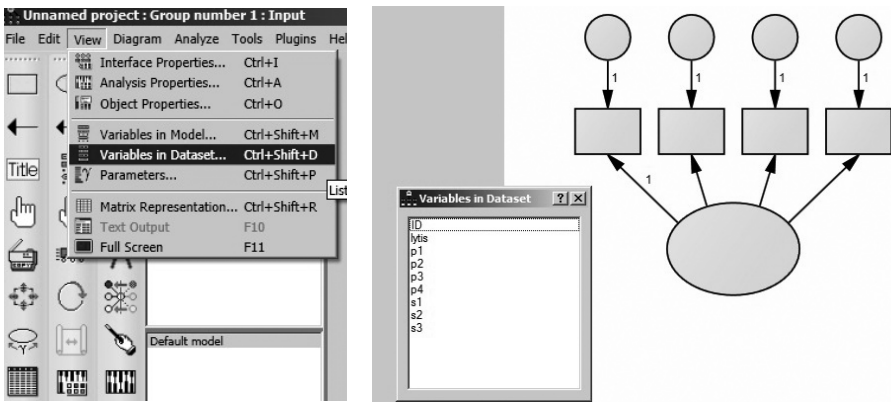


Žiūrėti duomenų išvesties langą




Išsaugoti diagramą

Pasidarius pavaizduotą modelį, reikia į jį iš savo duomenų rinkmenos įkelti kintamuosius (matavimų / stebimuosius), kurie bus naudojami (*View – Variables in dataset*). Tuomet atsidaro naujas mažesnis langelis, kuriame yra kintamųjų pavadinimai (jie tokie pat, kai ir naudojamoje SPSS duomenų rinkmenoje) (68 pav.).



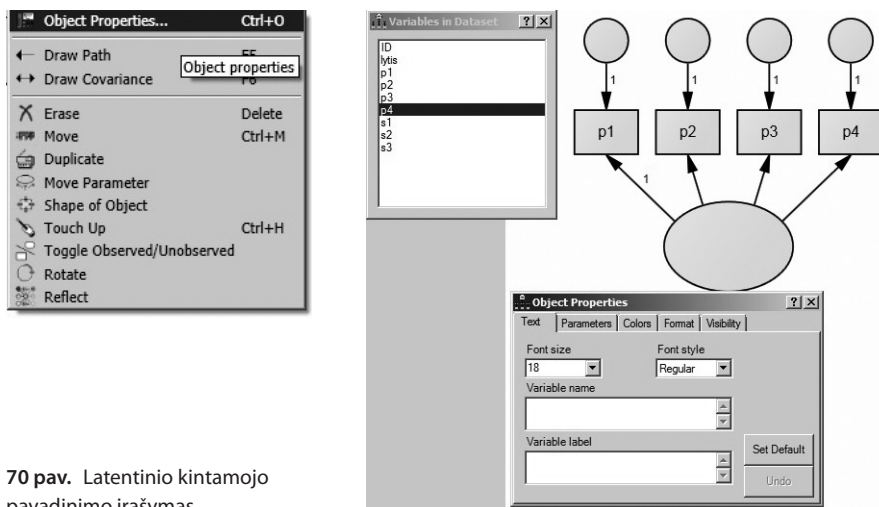
68 pav. Kintamųjų pavadinimų įkėlimas į modelį



69 pav. Matavimų kintamųjų pavadinimai modelyje

Paspaudę kintamojo pavadinimą jį galime tiesiog perkelti į paveiksluką (į tą stačiakampį, kuriame jis turėtų būti). Kai visi matavimų / stebimieji kintamieji sudėlioti į vietas, kintamųjų lentelę galime uždaryti – paspausti x dešiniajame jos kampe (69 pav.).

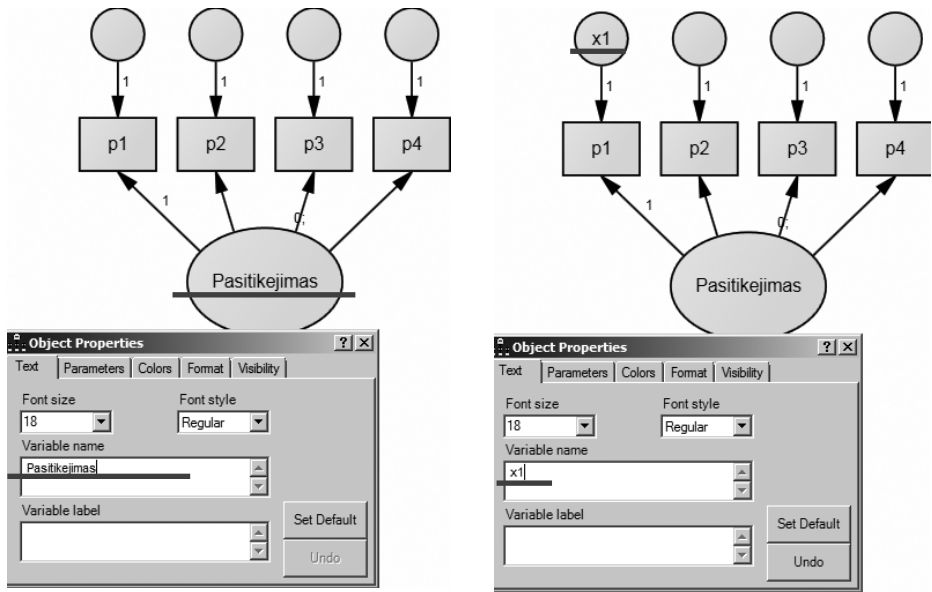
O tada reikia pavadinti latentinį kintamąjį. Kadangi šis kintamasis nėra matuojamas, jo SPSS duomenų rinkmenoje nėra. Jo pavadinimą reikia sugalvoti patiems. Norint įrašyti latentinių kintamųjų pavadinimus, užėjus ant latentinio kintamojo nupieštoje diagramoje ir paspaudus dešiniąją pelės klavišą, atsidarys maža lentelė, kurioje reikėtų pasirinkti „Objekto savybės“ (angl. *object properties*), ir tuomet atsidaro lentelė (70 pav.). Tokia pat lentelė atsidarytų ir užėjus ant kintamojo su pele ir du kartus ją paspaudus.




70 pav. Latentinio kintamojo pavadinimo įrašymas

Kintamojo pavadinimo langelyje (angl. *variable name*) reikia įrašyti savo sugalvotą pavadinimą. Tokiu pat būdu reikia pavadinti, sužymėti ir paklaidas (pavaizduotas rutuliukais, kurie turi rodykles į matavimų kintamuosius) diagramoje (71 pav.). Paklaidas galima pavadinti kaip patinka, tarkim, x_1 – x_4 . Tik reikėtų prisiminti, kad kintamųjų pavadinimai modelyje negali kartotis, t. y. visi turi turėti skirtingus pavadinimus, nes kitaip programa nepradės skaičiuoti (72 pav.).

Latentiniai kintamieji neturi matavimų skalės, nes jie nėra matuojami, ir, naudojant kai kurias AMOS programos versijas, reikia įkelti latentinių kintamųjų matavimo skalę. Naujesnės programos versijos (pvz., AMOS19) tai jau padaro automatiškai. Norint įkelti matavimų skalę latentiniams kintamiesiems, dažniausiai yra fiksuojamas vienas kelias tarp latentinio ir matavimų / stebimojo kintamojo ir prilyginamas vienetui, t. y. vienas faktoriaus svoris prilyginamas vienetui. Norėdami tai padaryti, užename ant pirmos (dažniausiai pirmasis prilyginamas vienetui) ar bet kurios kitos faktoriaus svorio rodyklės latentinio kintamojo ir du kartus paspaudžiame dešiniąją pelės klavišą



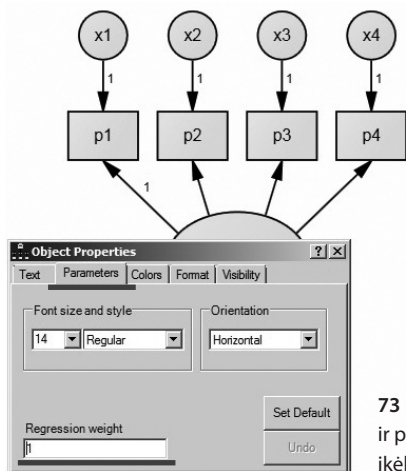
71 pav. Latentinio kintamojo ir paklaidų pavadinimai



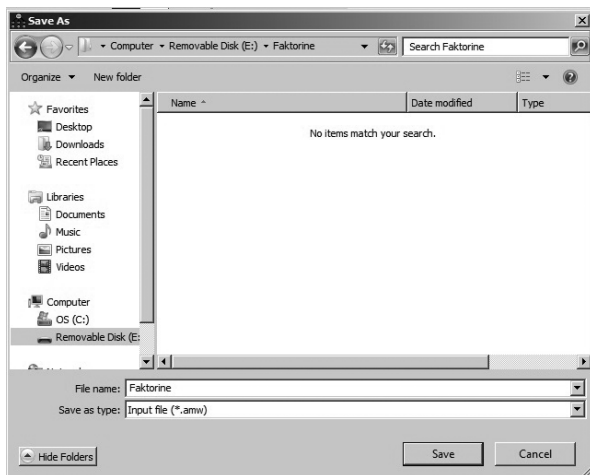
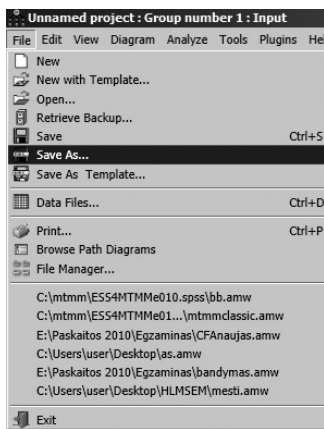
72 pav. Kintamųjų pavadinimai modelyje

arba pelę. Atsiraa ta pati objekto savybės lentelė (73 pav.). Joje prie parinkties „Parametrai“ (angl. *parameters*), kur yra langelis „Regresijos svoris“ (angl. *regression weight*), įrašome 1. Tada jį uždarome ir, pasirinkę kito latentinio kintamojo (jei tokių modelyje yra) vieną iš faktorių svorių, padarome tą patį. Kai kuriose AMOS programos versijose dažnai tokiu pat būdu ir paklaidos prilyginamos vienetui. To daryti nereikia naudojant naujesnes programos versijas, kai jau nupieštoje diagramoje matyti vienetai.

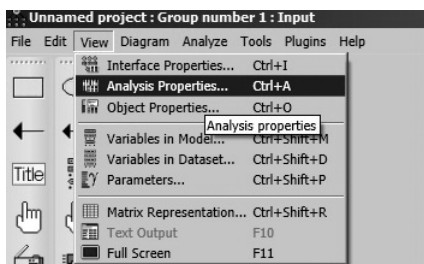
Visas objektų savybių lenteles galime uždaryti dešiniajame kampe paspaudę x. Susitvarkius modelį arba dar jį tvarkant reikėtų išsaugoti rinkmeną, kurią naudojome dirbdami. AMOS programa rinkmenos išsaugomos taip pat, kaip ir dirbant kitomis programomis. Meniu eilutėje pasirenkame „Išsaugoti rinkmeną“ (*File – Save as*) (74 pav.) ir nurodome programai, kurioje vietoje išsaugoti. Gerai tokias rinkmenas saugoti toje pačioje vietoje, kur ir SPSS duomenų rinkmena. AMOS programos rinkmenos baigiasi .amw. Programa, be vienos nurodytos rinkmenos, sukuria dar keletą rinkmenų, kurių jai reikia, tačiau jos svarbios tik pačiai programai, o ne vartotojui.



73 pav. Latentinio kintamojo ir paklaidos matavimo skalės įkėlimas

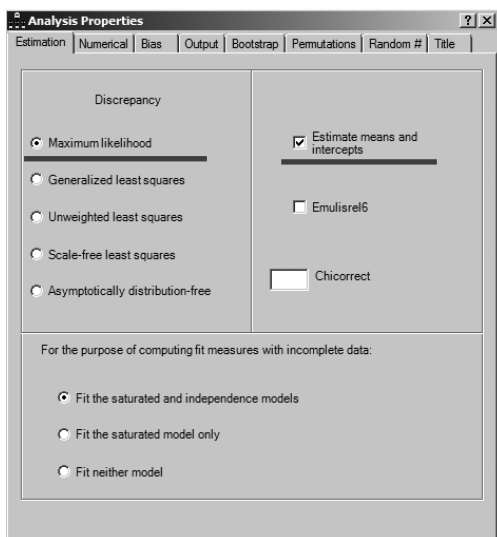


74 pav. Rinkmenos išsaugojimas naudojant AMOS programą



75 pav. Informacijos pasirinkimas duomenų išvesties langui

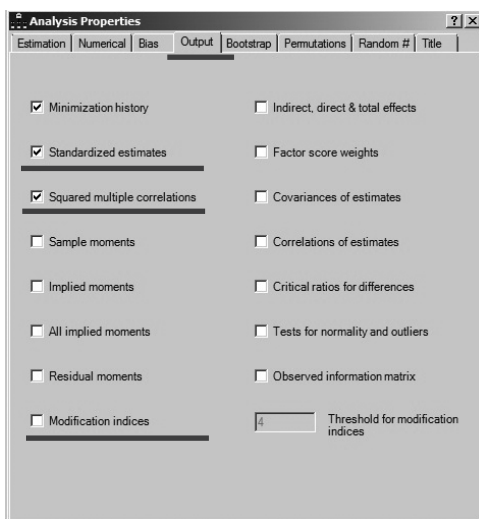
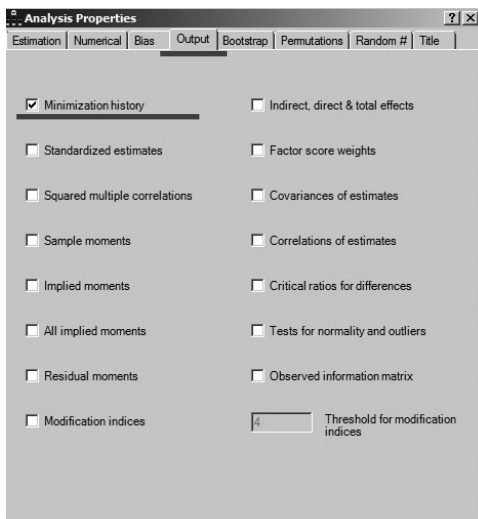
Išsaugojus savo dirbamą rinkmeną, prieš įvertinant modelį reikia pasirinkti, kurią informaciją norime matyti duomenų išvesties lange. Tam menu eilutėje pasirenkame „Analizės savybės“ (*View – Analysis Properties*) (75 pav.).



76 pav. Modelio įvertinimo pasirinkimas

Paspaudus nuorodą, atsiranda nauja lentelė. Čia ir reikia pasirinkti svarbią informaciją. Prie „Įvertinimas“ (angl. *estimation*) jau būna pažymėtas modelio didžiausiojo tikėtimumo metodas (76 pav.). Jei kintamuosiuose yra praleistų reikšmių ir jos paliekamos rinkmenoje, tai čia dar būtinai reikia pažymėti „Įvertinti vidurkius ir laisvuosius narius“ (angl. *estimate means and intercepts*). Nepažymėjus šios vietos ir turint duomenų rinkmenoje praleistų reikšmių, programa nepradės vertinti modelio.

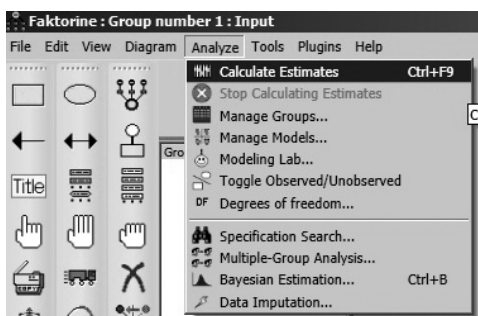
Kita tos pačios lentelės dalis yra skirta duomenų išvesties rezultatams. Dažniausiai jau būna pažymėta „Minimizacijos istorija“ (angl. *minimization history*) (77 pav.). Reikėtų pažymėti „Standartizuoti įverčiai“ (angl. *standardized estimates*), nes šie įverčiai dažniausiai ir skelbiami darbuose; daugialypių koreliacijų kvadratus (angl. *squared multiple correlations*), nurodančius, kiek dispersijos tame matavimų kintamajame paaiškinama latentiniu kintamuoju. Gerai pažymėti ir modifikacijos indeksus (angl. *modification indices*),



77 pav. Duomenų išvesties langų rezultatų pasirinkimas

tačiau juos pažymėti galime tik tada, kai nėra praleistų duomenų reikšmių (arba praleistos reikšmės pakeistos kintamojo vidurkiu). Jei yra praleista kintamųjų reikšmių, tai negalime žymėti modifikacijos indeksų, nes programa nepradės vertinti modelio.

Pasirinkus norimą informaciją, ši lentelė uždaroma (paspaudus x dešinėje pusėje). Tada jau galima pradėti vertinti modelį naudojantis meniu įrankiais (*Analyze – Calculate Estimates*) (78 pav.) ir analizuoti gautus rezultatus.



78 pav. Modelio parametrų skaičiavimas



5.2.10. Patvirtinamosios faktorių analizės, naudojantis AMOS programa, rezultatai

Baigę įvertinti modelį, diagramoje jau galime matyti koeficientus. Norint juos pamatyti, reikia paspausti „Žiūrėti duomenų išvesties rezultatus“ (angl. *view the output*) atitinkantį įrankį. Šis įrankis yra rinkmenos, su kuria dirbama, viršuje per vidurį, pažymėtas rodykle į latininį kintamąjį (79 pav.).


Tada diagramoje pasirodo nestandartizuoti koeficientai. Norint matyti standartizuotus koeficientus, reikia paspausti „Standartizuoti įverčiai“ langelyje, kuris yra tarp piešimo įrankių ir piešimo lauko. Modelio diagramoje bus matyti skaičiai (80 pav.).



79 pav. Duomenų išvesties lango rezultatų nustatymas



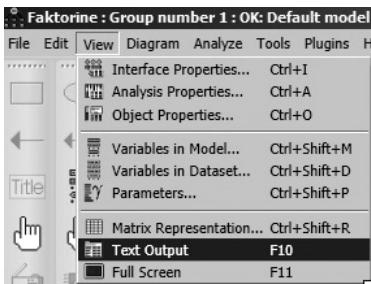
80 pav. Standartizuotų koeficientų nustatymas



81 pav. Chi kvadratas

80 pav. pateikti faktorių svoriai (tarp latentinio ir matavimų kintamųjų), daugialypės koreliacijos kvadratu (virš matavimo kintamojo, žemiau paklaidos), nurodančios, kiek pasiskirstymo tų matavimų, stebimojo kintamojo paaiškina latentinis kintamasis. Taip pat pateiktas chi kvadratas stulpelyje tarp diagramos piešimo, grafinių įrankių ir pačios diagramos (81 pav.).

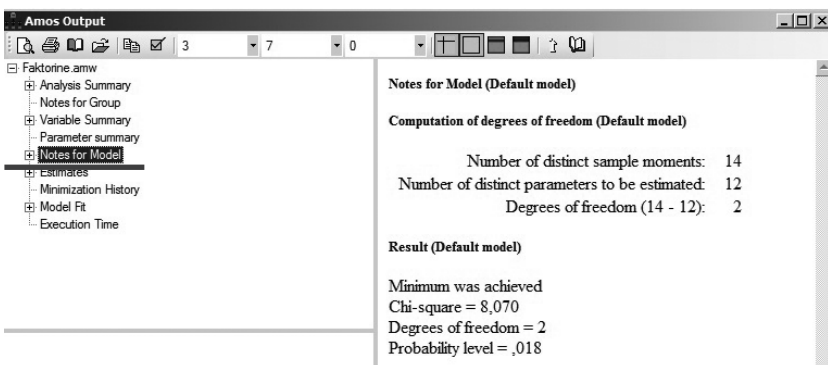
Matome (80 pav.), kad keturi kintamieji p1–p4 gali atspindėti vieną latentinį kintamąjį. Visų matavimų kintamųjų faktorių svoriai panašūs. Norint pamatyti daugiau rezultatų, išsamiai įvertinti modelio tinkamumą, reikėtų atsidaryti duomenų išvesties langą naudojantis meniu įrankiais (*View – Text output*) (82 pav.).



82 pav. Duomenų išvesties lango atidarymas

Atidarius duomenų išvesties langą, dažniausiai pasirodo informacija apie chi kvadratą, laisvės laipsnius, kurie yra prie „Modelio užrašai“ (angl. *notes for model*) (83 pav.).

Prie įverčių nurodyta informacija, kuri jau buvo pateikta diagramoje, kartu yra ir papildomos informacijos. Čia taip pat galime rasti faktorių svorius, kurie pateikti lentelėje, joje jie vadinami standartizuotais regresijos svoriais (angl. *standardized regression weights*) (84 pav.). Faktorių svoriai pateikiami dešinėje lentelės pusėje, o kuris svoris yra kurio faktoriaus, tai yra kuriam kintamajam priklauso, nurodyta kairėje pusėje. Tik čia skaičiai pateikiami kaip keliai, pavyzdžiui, nuo latentinio kintamojo „pasitenkinimas“ į p1, faktorių svoris yra 0,536.



83 pav. Duomenų išvesties lango modelio užrašai

Amos Output

Faktorine.amw

- Analysis Summary
- Notes for Group
- Variable Summary
- Parameter summary
- Notes for Model
- Estimates**
- Minimization History
- Model Fit
- Execution Time

Estimates (Group number 1 - Default model)

Scalar Estimates (Group number 1 - Default model)

Maximum Likelihood Estimates

Regression Weights: (Group number 1 - Default model)

		Estimate	S.E.	C.R.	P	Label
p1 <---	Pasitkejimas	1,000				
p2 <---	Pasitkejimas	1,107	,156	7,085	***	
p3 <---	Pasitkejimas	1,191	,170	7,025	***	
p4 <---	Pasitkejimas	1,165	,163	7,141	***	

Standardized Regression Weights: (Group number 1 - Default model)

		Estimate
p1 <---	Pasitkejimas	,536
p2 <---	Pasitkejimas	,647
p3 <---	Pasitkejimas	,629
p4 <---	Pasitkejimas	,663

84 pav. Faktorių svoriai duomenų išvesties lange

Taip pat galime rasti daugialypių koreliacijų kvadratus, nurodančius, kiek dispersijos tame matavimų kintamajame paaiškinama latentiniu kintamuoju (85 pav). Šie skaičiai taip pat matyti diagramoje.

Prie modelio tinkamumo kriterijų nuorodos yra įvairių modelio tinkamumo kriterijų (86 pav.).

Squared Multiple Correlations: (Group number 1 - Default model)

	Estimate
p4	,439
p3	,395
p2	,418
p1	,287

85 pav. Daugialypių koreliacijų koeficientai

Amos Output

Faktorine.amw

- Analysis Summary
- Notes for Group
- Variable Summary
- Parameter summary
- Notes for Model
- Estimates
- Minimization History
- Model Fit**
- Execution Time

Model Fit Summary

CMIN

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	12	8,070	2	,018	4,035
Saturated model	14	,000	0		
Independence model	4	233,465	10	,000	23,347

Baseline Comparisons

Model	NFI	RFI	IFI	TLI	CFI
	Delta1	rho1	Delta2	rho2	
Default model	,965	,827	,974	,864	,973
Saturated model	1,000		1,000		1,000
Independence model	,000	,000	,000	,000	,000

86 pav. Modelio tinkamumo kriterijai

Svarbu peržiūrėti bent kelis dažniausiai skelbiamus tinkamumo kriterijus: chi kvadratą, vidutinės aproksimacijos paklaidos (RMSEA) kvadratinę šaknį, sąlyginį suderinamumo kriterijų (CFI), Takerio ir Liuiso indeksą (TLI) (87 pav.). Pateikti tinkamumo kriterijai rodo, kad modelis nėra pats geriausias, jis galėtų būti tobulinamas, nes TLI = 0,864 (modelis geras, kai TLI reikšmės > 0,95), CFI = 0,973 (CFI reikšmės > 0,95 rodo, kad modelis geras), RMSEA = 0,091 (kai RMSEA reikšmė mažiau negu 0,05, modelis geras, nuo 0,05 iki 0,08 – priimtinas, nuo 0,08 iki 0,10 – galimas, tačiau reikėtų patikrinti, ar negalimi geresni modeliai). Tik vienas CFI indeksas rodo, kad modelis tinka duomenims, o kiti indeksai – kad reikėtų peržiūrėti. Kadangi aptariamuose duomenyse yra praleistų reikšmių, tai nėra galimybės pamatyti modifikacijos indeksų, kurie nurodytų, ką būtų galima keisti modelyje. Kitos struktūrinių lygčių programos, net ir kai yra praleistų reikšmių, pateikia modifikacijos indeksus. Tad ką keisti, reikėtų pagalvoti teoriškai. Taip pat kartu peržiūrėti, ar tikrai duomenys atitinka patvirtinamosios faktorių analizės prielaidas. Dar vienas būdas – sutvarkyti duomenis, kad neliktų praleistų reikšmių, ir kartoti modelio įvertinimą.

Baseline Comparisons					
Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	,965	,827	,974	,864	,973
Saturated model	1,000		1,000		1,000
Independence model	,000	,000	,000	,000	,000

RMSEA				
Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	,091	,032	,160	,110
Independence model	,247	,220	,275	,000

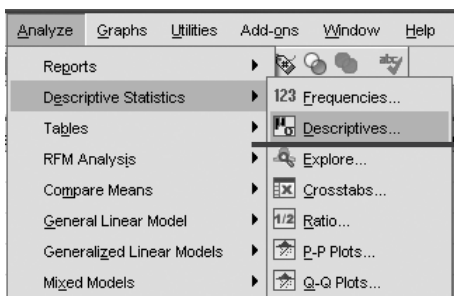
87 pav. Dažniausiai skelbiami modelio tinkamumo kriterijai

5.2.11. Modelio, naudojantis AMOS programa, modifikavimas

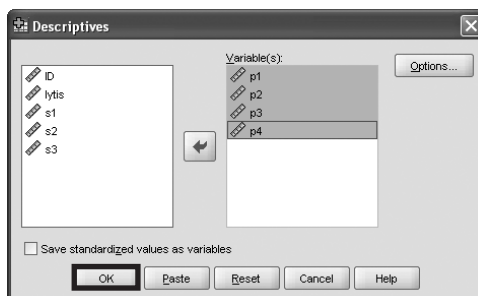
Norint modelį pagerinti pasitelkus modifikacijos indeksus, duomenyse negali likti praleistų reikšmių. Vienas iš lengvesnių būdų – praleistas reikšmes pakeisti kintamojo vidurkiniu balu. Tai padaroma SPSS duomenų rinkmenoje. Kintamųjų vidurkiai gaunami naudojantis aprašomosios statistikos funkcija (*Analyze – Descriptive statistics – Descriptives*) (88 pav.).

Paspaudus nuorodą, atsidaro lentelė, kurioje nurodoma, kurių kintamųjų aprašomąją statistiką norime matyti. Šiame pavyzdyje tai bus kintamieji p1–p4. Perkėlę juos į kintamųjų langelį, spaudžiame mygtuką OK (89 pav.).

Duomenų išvesties lange gauname lentelę, kurioje yra vienas stulpelis „vidurkis“ (angl. *mean*) (90 pav.).



88 pav. Aprašomosios statistikos funkcijos

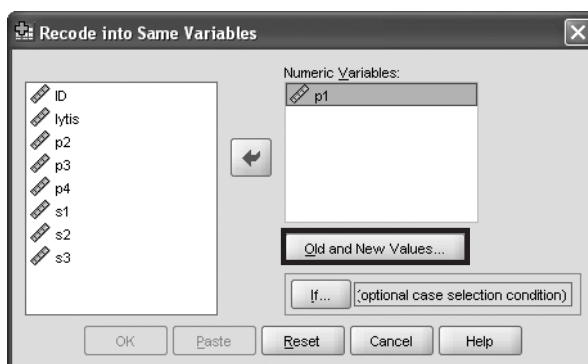
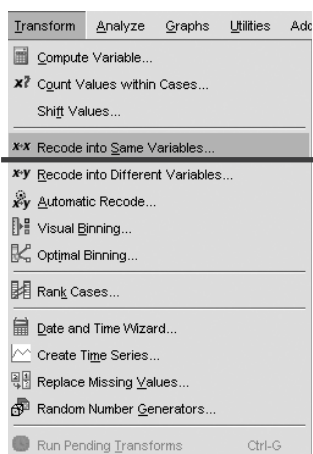


89 pav. Kintamųjų p1–p4 aprašomosios statistikos skaičiavimas

Descriptive Statistics					
	N	Minimum	Maximum	Mean	Std. Deviation
p1	331	1,00	4,00	2,9275	,65657
p2	327	1,00	4,00	3,0581	,60137
p3	330	1,00	4,00	3,1424	,66686
p4	326	1,00	4,00	3,2025	,61928
Valid N (listwise)	322				

90 pav. Kintamųjų p1–p4 vidurkiai duomenų išvesties lange

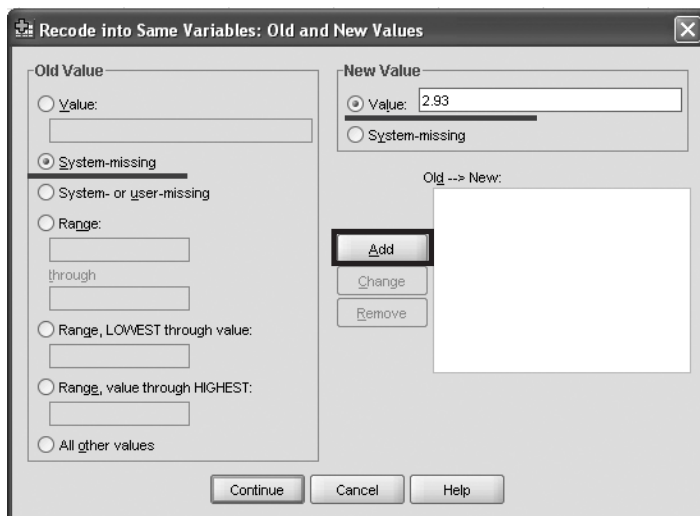
Šie vidurkiai naudojami perkodavimui. Pavyzdžiui, perkoduodami p1 kintamojo praleistas reikšmes, naudodami šio kintamojo vidurkį – 2,93. Norėdami perkoduoti praleistas reikšmes, vėl naudojames ta pačia funkcija, kaip ir perkoduodami kintamuosius. Perkodavimas atliekamas naudojant pačią SPSS programą, perkoduojama į tą patį stulpelį (*Transform – Recode into same variables*) (91 pav.). Paspaudus šią nuorodą, atsirado lentelė, kurioje nurodome, kuri kintamąjį norime perkoduoti (pvz., p1). Jį ir perkeliame į kintamųjų langelį. Tuomet spaudžiame mygtuką „Senos ir naujos reikšmės“.



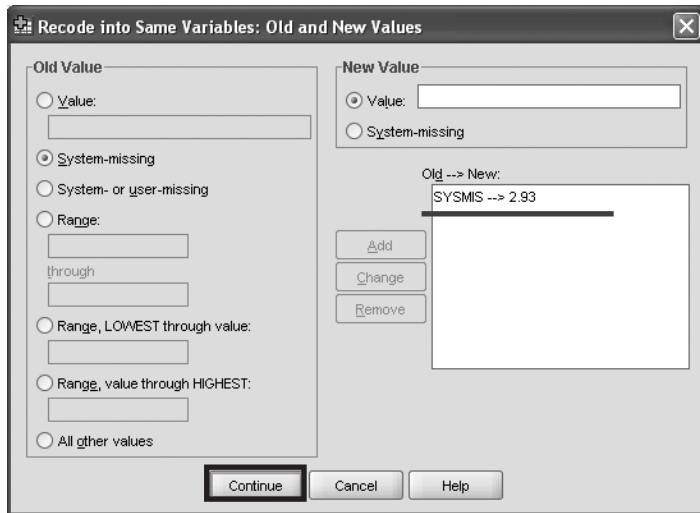
91 pav. Kintamųjų perkodavimas naudojant SPSS programą

Atsidarius naujai lentelei, prie senų reikšmių langelyje pasirenkame „Praleistos reikšmės“ (angl. *system-missing*). O naujų reikšmių pusėje įrašome „Perkodavimas“, to kintamojo vidurkį ir spaudžiame mygtuką „Pridėti“ (angl. *add*) (92 pav.).

Tada spaudžiame mygtuką „tęsti“, pagrindiniame lange OK (93 pav.) ir kintamasis p1 neturi praleistų reikšmių.



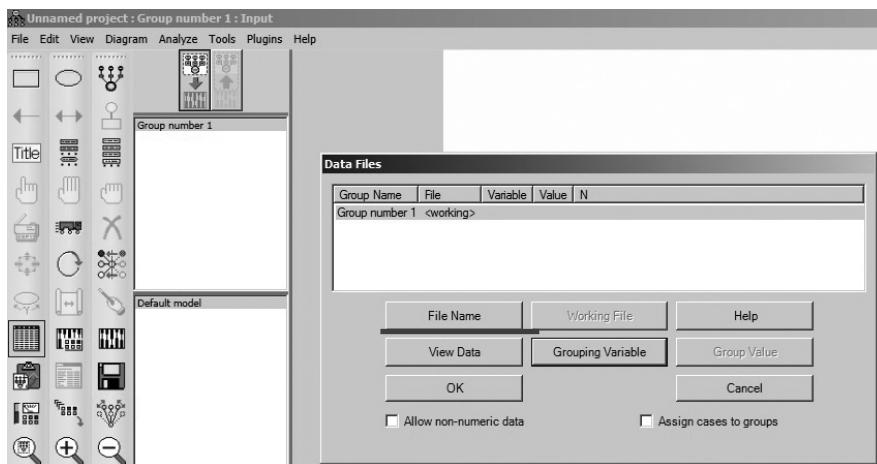
92 pav. Kintamųjų praleistų reikšmių perkodavimas vidurkiu



93 pav. Kintamojo p1 praleistų reikšmių perkodavimas vidurkiu

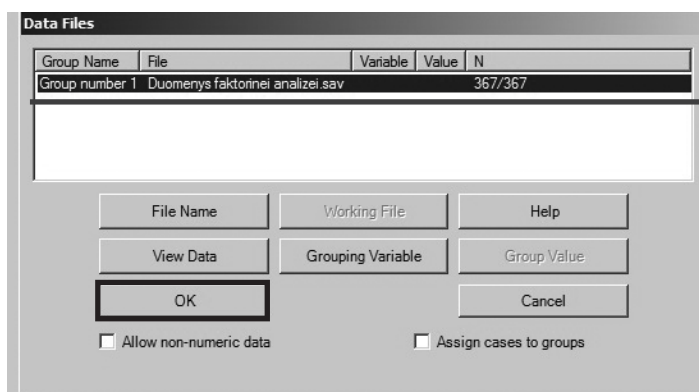
Taip reikėtų padaryti su visais kintamaisiais (p1–p4), kuriuos naudosime modelyje. Baigę pakeitimus išsaugome duomenų rinkmenoje (geriau išsaugoti kaip naują duomenų rinkmeną ir visuomet turėti originalią rinkmeną, kuri nekeičiama).

Jei naudojamės ta pačia AMOS rinkmena, kurioje jau nupiešėme diagramą (p1–p4 atspindi vieną latentinį faktorių), tai meniu įrankiais programai pateikiame naują duomenų rinkmeną (*File – Data Files*). Paspaudus nuorodą „Duomenų rinkmenos“ atsiranda naujas langas, kuriame prašoma nurodyti duomenų rinkmeną ir jos vietą (tam naudojama nuoroda „Rinkmenos vardas“). Paspaudus šią nuorodą, atsidaro langas, kuriame susirandame naująją rinkmeną ten, kur ją išsaugojome (94 pav.).

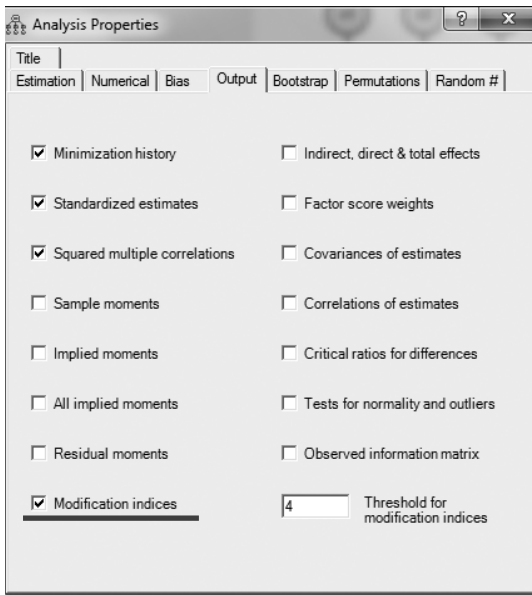


94 pav. Naujos duomenų rinkmenos paieška

Tada pirminiame lange ir matome savo naujosios duomenų rinkmenos pavadinimą. Jei taip yra, tai duomenys jau nurodyti programai ir spaudžiame mygtuką OK (95 pav.).



95 pav. Naujos duomenų rinkmenos pateikimas programai



96 pav. Modifikacijos indeksų pasirinkimas

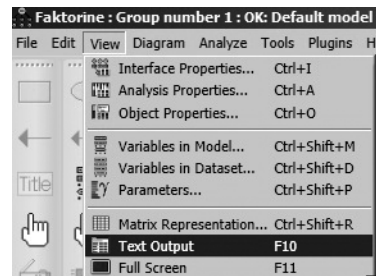
Norėdami nustatyti modifikacijos indeksus, meniu eilutėje pasirenkame „Analizės savybės“ (*View – Analysis Properties*). Paspaudus nuorodą, atsiranda nauja lentelė. Čia reikia pasirinkti „Modifikacijos indeksai“ (96 pav.). Taip pat čia turime nuimti varnelę, kuria uždėjome pirmos analizės metu, nuo „Įvertinti vidurkius ir laisvuosius narius“.

Pasirinkę lentelę uždarome (paspaudžiame x dešinėje pusėje) ir pradėdami modelio įvertinimą naudodamiesi meniu įrankiais (*Analyze – Calculate Estimates*).

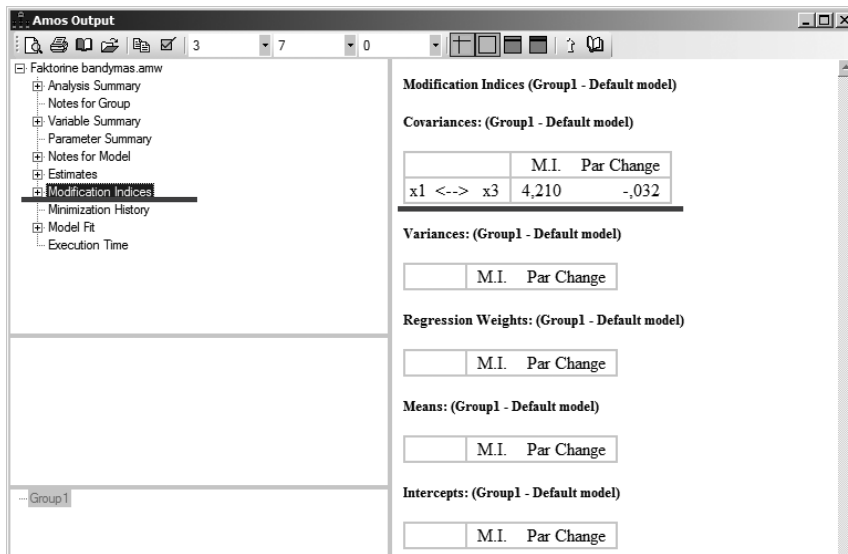
5.2.12. Modelio, naudojantis AMOS programa, modifikavimo rezultatai

Kai programa baigia vertinti modelį, duomenų išvesties lange galime matyti siūlomas modifikacijas (*View – Text output*) (97 pav.). Visi kiti indeksai (modelio tinkamumo) lieka tie patys, kaip ir buvo.

Modifikacijos indeksai siūlo, kad pridėjus koreliaciją tarp x_1 ir x_3 (kintamųjų p_1 ir p_3 liekamųjų paklaidų), modelis gali geriau tikti turimiems duomenims (98 pav.).



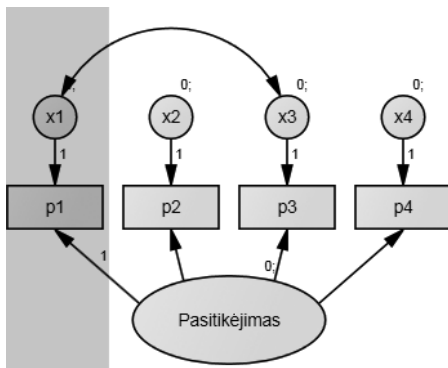
97 pav. Duomenų išvesties lango atidarymas




98 pav. Modifikacijos indeksų pasiūlymai

Norėdami tai patikrinti, diagramoje galime tiesiog nupiešti koreliacijos rodyklę tarp x1 ir x3, naudodamiesi \leftrightarrow grafine išraiška (99 pav.).

Tai atlikę, galime dar kartą įvertinti modelį naudodamiesi meniu įrankiais (*Analyze – Calculate Estimates*). Diagramoje gauname šiek tiek kitokius faktorių svorius, palyginti su ankstesniu modeliu, ir taip pat geresnį modelį (100 pav.).

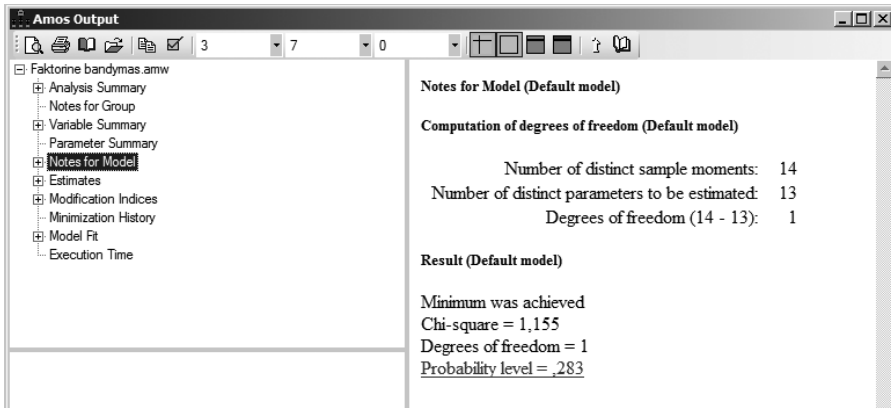


99 pav. Modifikuotas modelis



100 pav. Modifikuoto modelio rezultatai

Bet klausimas, ar šis modelis tikrai geresnis, palyginti su ankstesniu, kur nebuvo naudota koreliacija. Duomenų išvesties lange matome, kad chi kvadratas gerokai mažesnis nei buvo ankstesniame modelyje (101 pav.).



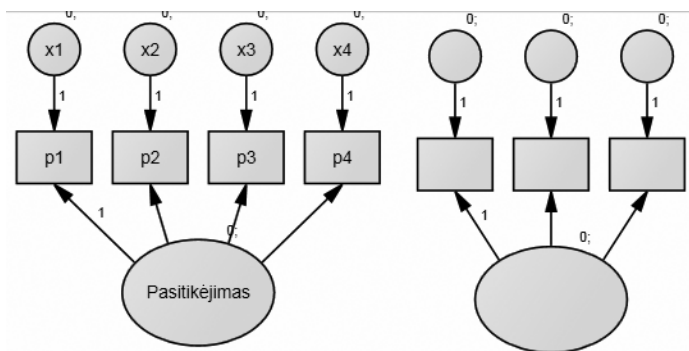
101 pav. Modifikuoto modelio chi kvadratas duomenų išvesties lange

O ar šie du modeliai (modifikuotas ir nemodifikuotas) statistiškai reikšmingai skiriasi? Pirmojo modelio chi kvadratas lygus 8,1 ir $df = 2$, o antrojo $\chi^2 = 1,2$ ir $df = 1$. Tai $\Delta \chi^2 = 8,1 - 1,2 = 6,9$, $\Delta df = 2 - 1 = 1$. Turėdami šiuos skaičius, žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 1 laisvės laipsnį. Pagal lentelę, kad modeliai būtų statistiškai reikšmingai skirtingi, esant 1 laisvės laipsniui, chi kvadrato skirtumas turėtų būti 3,841 ir daugiau. Mūsų gautas chi kvadrato skirtumas yra 6,9. Tad du modeliai statistiškai skiriasi ir reikėtų rinktis tą, kuris jau pataisytas pagal modifikacijos indeksų pasiūlymus, bet turėtume žinoti, kaip teoriškai pagrįsti padarytus pakeitimus.

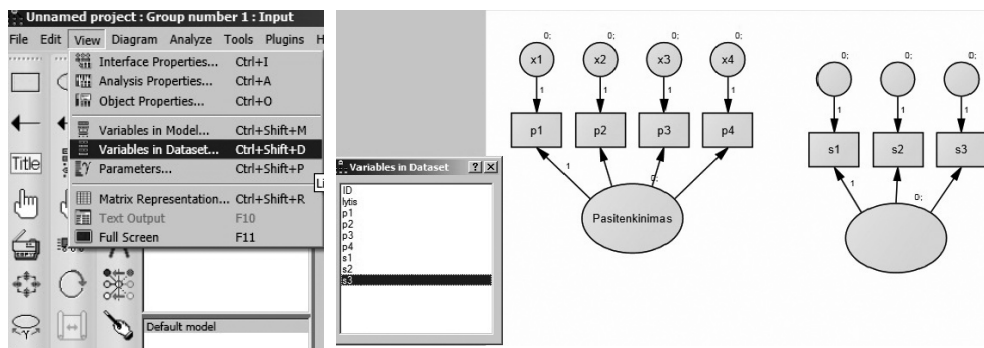
5.2.13. Modelio, naudojantis AMOS programa, papildymas

Norėdami papildyti turimą modelį, pridėti naujų kintamųjų ar ką nors pašalinti, viską galime daryti toje pačioje rinkmenoje, kurioje piešėme pirmąją diagramą, arba naujoje vėl viską piešti iš naujo, jei norime tikrinti visai kitą modelį. Tarkime, prie turimų p1–p4 kintamųjų norime pridėti s1–s3 kintamuosius, kurie turėtų sudaryti kitą latentinį kintamąjį – santykiai su draugais. Latentinių kintamųjų pavadinimas priklauso nuo tyrėjo. Kadangi naujame modelyje paliekame kintamuosius p1–p4, kurie sudaro latentinį faktorių, ir pridėdami kitus kintamuosius, diagramą galime piešti jau turimoje rinkmenoje. Naudodamiesi piešimo įrankiais nupiešiame naują latentinį kintamąjį, kuris turi tris matavimų kintamuosius (102 pav.).

Papildžius esamą diagramą, vėl reikia įkelti į modelį kintamuosius (matavimų), kuriuos naudosime, iš savo duomenų rinkmenos (*View – Variables in Dataset*). Tuomet atsidaro naujas mažesnis langelis su kintamųjų pavadinimais (103 pav.).

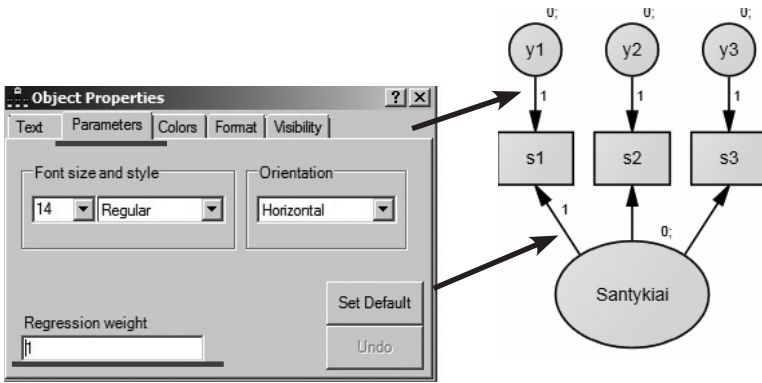


102 pav. Modelio su dviem latentiniais kintamaisiais vaizdas



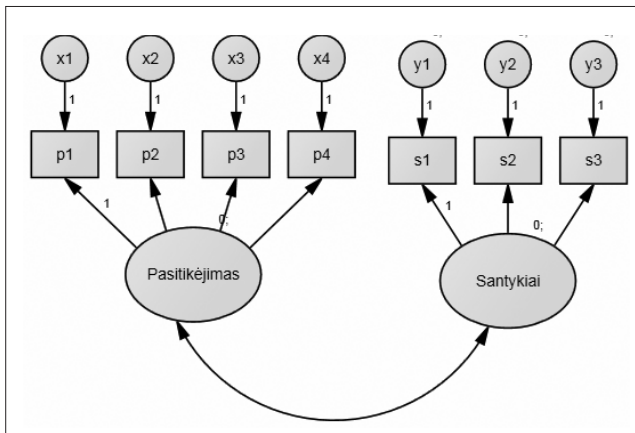
103 pav. Modelio su dviem latentiniais kintamaisiais kintamųjų pavadinimų įrašymas

Kintamąjį, paspaudę jo pavadinimą, galime tiesiog perkelti į paveiksluką (į tą stačiakampį, kuriame jis turėtų būti). Kai visi matavimų kintamieji sudėlioti į vietas, galima uždaryti kintamųjų lentelę – paspausti x dešiniajame jos kampe. Tuomet reikia pavadinti naują latentinį kintamąjį. Latentinio kintamojo pavadinimas įrašomas užėjus ant latentinio kintamojo su pele ir du kartus ją paspaudus. Atsiradusiame kintamojo pavadinimo langelyje reikia įrašyti sugalvotą naujo latentinio kintamojo pavadinimą. Tokiu pat būdu reikia pavadinti, sužymėti ir naujų kintamųjų paklaidas (pavaizduotas rutuliukais, kurie turi rodykles į matavimų kintamuosius) diagramoje. Paklaidas galima pavadinti kaip patinka, tarkim, y_1 – y_3 . Visi kintamieji turi turėti pavadinimus. Naudojant kai kurias AMOS programos versijas reikia įkelti latentinių kintamųjų matavimo skalę. Norint įkelti šią skalę, latentiniams kintamiesiems dažniausiai vienas faktoriaus svoris yra prilyginamas vienetui. Užėjus ant pirmos ar bet kurios kitos faktoriaus svorio rodyklės latentinio kintamojo ir paspaudus dešinįjį pelės klavišą arba pelę du kartus, atsiras ta pati objekto savybės lentelė. Joje prie parinkties „Parametrai“, kur yra langelis „Regresijos svoris“, įrašoma 1 (104 pav.). Naudojant ankstesnes AMOS programos versijas, dažnai ir visos liekamosios paklaidos tokiu pat būdu prilyginamos vienetui.



104 pav. Matavimų skalės fiksavimas

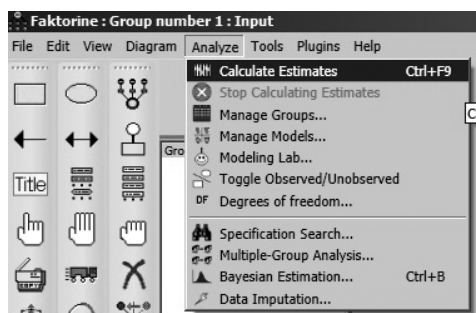
Kai turime du ir daugiau latentinių faktorių, paprastai jie būna susiję koreliaciniais ryšiais. Tad diagramoje svarbu tai parodyti – nupiešti koreliaciją tarp faktorių. Tam naudojames dvipuse rodykle iš grafinių išraiškų ir sujungiame abu faktorius (105 pav.).



105 pav. Dviejų latentinių kintamųjų modelis

Susitvarkius modelį reikėtų išsaugoti rinkmeną, kuria dirbame. Galime ją išsaugoti tuo pačiu pavadinimu, bet visuomet geriau kitu, nes, panorėjus palyginti du panašius modelius, nereikės perdaryti diagramų iš naujo. Meniu eilutėje pasirenkame „Išsaugoti rinkmeną“ (*File – Save as*). Išsaugoję rinkmeną patikriname, ar likusi ta pati anksčiau pažymėta informacija, kurią norime matyti duomenų išvesties lange. Tam meniu eilutėje pasirenkame „Analizės savybės“ (*View – Analysis Properties*). Paspaudus nuorodą, atsiranda lentelė. Prie įvertinimo, jei kintamuosiuose yra pra-

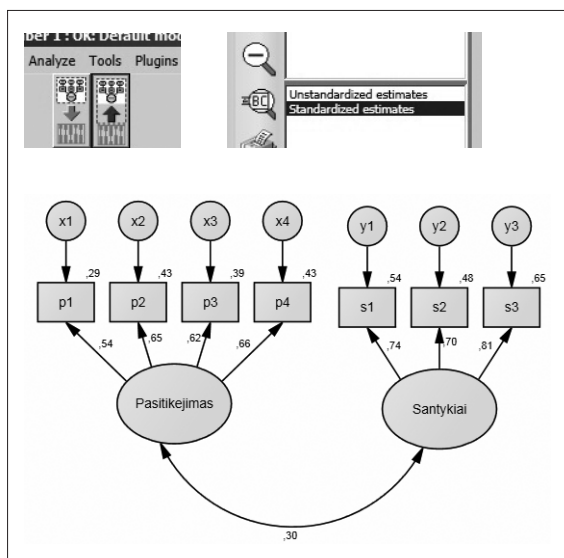
leistų reikšmių, būtina reikia pažymėti įvertinti vidurkius ir laisvuosius narius. Kita tos pačios lentelės dalis yra skirta duomenų išvesties rezultatams. Turėtų likti jau pažymėti (jei dirbame ta pačia rinkmena) standartizuoti įverčiai, daugialypių koreliacijų kvadratai. Pasirinkę norimą informaciją, lentelę uždarome ir jau galime pradėti modelio įvertinimą naudodamiesi meniu įrankiais (*Analyze – Calculate Estimates*) (106 pav.).




106 pav. Modelio įvertinimo paleidimas

5.2.14. Modelio, naudojantis AMOS programa, papildymo rezultatai

Kai programa baigia vertinti modelį, diagramoje jau galime pamatyti koeficientus. Tam reikia paspausti „Žiūrėti duomenų išvesties rezultatus“ grafinę išraišką (ji yra dirbamos rinkmenos viršuje per vidurį) (107 pav.). Norint matyti standartizuotus koeficientus, reikia paspausti „Standartizuoti įverčiai“ langelyje, kuris yra tarp piešimo, grafinių įrankių ir piešimo lauko. Ir modelio diagramoje bus matyti skaičiai (107 pav.).



107 pav. Modelio su dviem latentiniais kintamaisiais rezultatai diagramoje



108 pav. Modelio chi kvadratas

107 pav. pateikti faktorių svoriai (tarp latentinio ir matavimų kintamųjų), daugialypės koreliacijos kvadratu (virš matavimo kintamojo, žemiau paklaidos). Taip pat pateiktas chi kvadratas stulpelyje tarp diagramos piešimo, grafinių įrankių ir pačios diagramos (108 pav.).

107 pav. matyti, kad keturi kintamieji, p1–p4, gali atspindėti vieną latentinį kintamąjį, o kintamieji s1–s3 – kitą latentinį faktorių. Abu latentiniai faktoriai susiję, koreliacijos koeficientas tarp jų $r = 0,30$. Norėdami pamatyti daugiau rezultatų, turėtume atsidaryti duomenų išvesties langą naudodamiesi meniu įrankiais (*View – Text output*). Prie įverčių duomenų išvesties lange yra informacija, kuri jau buvo pateikta diagramoje. Prie modelio tinkamumo kriterijų nuorodos pateikti įvairūs modelio tinkamumo kriterijai (109 pav.). Šio modelio (turime 7 matavimų ir 2 latentinius kintamuosius) tinkamumo kriterijai rodo, kad modelis tinkamas, nes TLI = 0,982 (TLI reikšmės > 0,95, vadinasi, modelis geras), CFI = 0,992 (CFI reikšmės > 0,95, taigi modelis geras), RMSEA = 0,029 (RMSEA reikšmė mažiau negu 0,05 – modelis geras). Tad šio modelio tinkamumas geresnis nei ankstesnio, kur turėjome tik p1–p4 kintamuosius ir jis nebuvo modifikuotas.

Baseline Comparisons					
Model	NFI Delta1	RFI rho1	IFI Delta2	TLI rho2	CFI
Default model	,968	,931	,992	,982	,992
Saturated model	1,000		1,000		1,000
Independence model	,000	,000	,000	,000	,000

RMSEA				
Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	,029	,000	,063	,815
Independence model	,222	,206	,239	,000

109 pav. Modelio su dviem latentiniais faktoriais tinkamumo kriterijai

O ar šie du modeliai (modelis tik su vienu latentiniu faktoriumi ir modelis su dviem latentiniais faktoriais) statistiškai reikšmingai skiriasi? Pirmojo modelio chi kvadratas lygus 8,1 ir $df = 2$, o antrojo $\chi^2 = 17,1$ ir $df = 13$. Tai $\Delta \chi^2 = 17,1 - 8,1 = 9$, $\Delta df = 13 - 2 = 11$. Turėdami šiuos skaičius, žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 11 laisvės laipsnių. Pagal lentelę, esant 11 laisvės laipsnių, chi kvadrato skirtumas turėtų būtų 19,675 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra tik 9, tad modeliai statistiškai

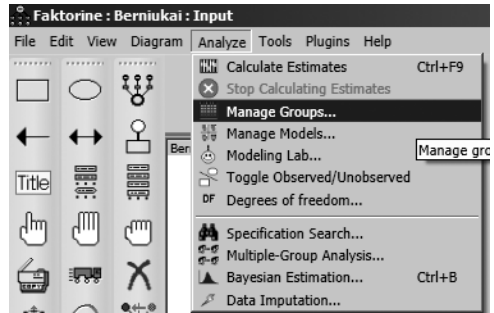
kai nesiskiria ir tuomet jau renkamės modelį, kuris geriau atspindi mūsų idėjas, turi geresnius tinkamumo kriterijus ar gali būti geriau teoriškai pagrindžiamas. Tačiau šiame modelyje netikrinome, ar gali būti tam tikrų modifikacijų. Norint jas matyti, reiktų vėl naudoti duomenų rinkmeną, kurioje nėra jokių praleistų reikšmių. Prisi-
mintina, kad visos modifikacijos, kurios paliekamos modelyje, turi būti pagrįstos.

5.2.15. Modelio, naudojantis AMOS programa, lyginimas tarp grupių


Norėdami savo turimą modelį palyginti tarp kelių grupių, pavyzdžiui, tarp berniukų ir mergaičių, viską galime daryti toje pačioje rinkmenoje, kurioje jau buvome sukūrę modelį, arba naujoje rinkmenoje vėl piešti viską iš naujo. Tarkime, norime patikrinti, ar kintamieji p1–p4 sudaro vieną latentinį kintamąjį (kartu yra ir koreliacijos tarp p1 ir p3 kintamųjų liekamųjų paklaidų) ir ar toks pat modelis tinka berniukams ir mergaitėms. Turime seną modelį, kuriame jau nupiešta diagrama, naudojames ta rinkmena, tuomet nereikia iš naujo piešti diagramos. Jei neturime, reikia nupiešti diagramą, atidaryti duomenų rinkmeną, įkelti kintamuosius, pavadinti latentinį kintamąjį ir paklaidas. Kai turime ankstesnę diagramą, atidarome tą rinkmeną ir nurodome programai, kad bus kelios grupės (*Analyze – Manage groups*) (110 pav.).

Paspaudus nuorodą, atsidaro lentelė, kurioje pavadiname pirmą grupę (pvz., *berniukai*), ir spaudžiame mygtuką „Nauja“ (angl. *new*) (111 pav.).


Tuomet atsidaro vėl toks pat langelis, bet čia jau turime įrašyti kitos grupės pavadinimą (pvz., *mergaitės*) (112 pav.). Jei grupių yra daugiau, vėl spaudžiame mygtuką „Nauja grupė“ ir ją pavadiname. Jei grupių daugiau nėra, spaudžiame mygtuką „uždaryti“ (angl. *close*).



110 pav. Grupių analizės funkcija

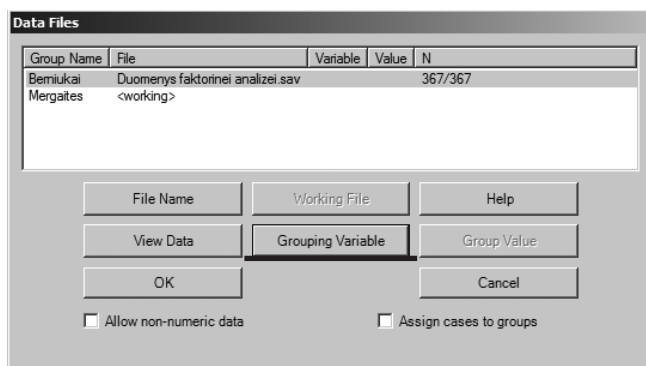


111 pav. Pirmos grupės aprašymas



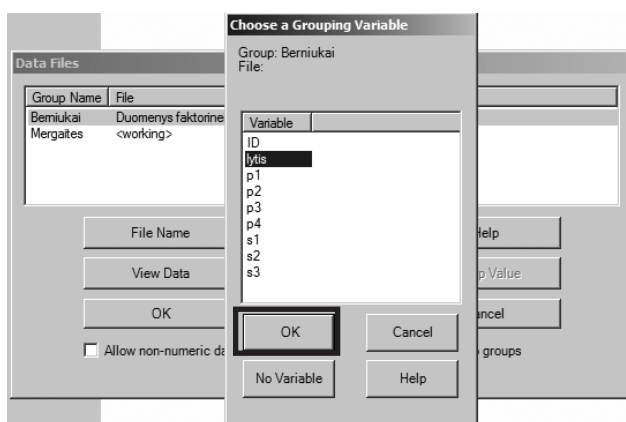
112 pav. Antros grupės aprašymas

Kai grupės jau aprašytos, svarbu programai nurodyti, kaip šias grupes atpažinti duomenų rinkmenoje. Per meniu įrankius programai buvo pateikiama duomenų rinkmena (*File – Data Files*), kurią dabar reikia detalizuoti atskiroms grupėms. Paspaudus nuorodą „Duomenų rinkmenos“ atsiranda naujas langas, kuriame jau matyti, kad prie berniukų grupės nurodyta anksčiau naudota duomenų rinkmena, kurioje yra ši diagrama. Vertinant modelį grupėms, geriau, kad duomenų rinkmenoje nebūtų jokių praleistų reikšmių, nes programa gali neteisingai įvertinti modelį. Bet, turint rinkmeną, reikia nurodyti, kaip programa gali joje atpažinti berniukus. Tuomet spaudžiame mygtuką „Grupių kintamasis“ (angl. *grouping variable*) (113 pav.).



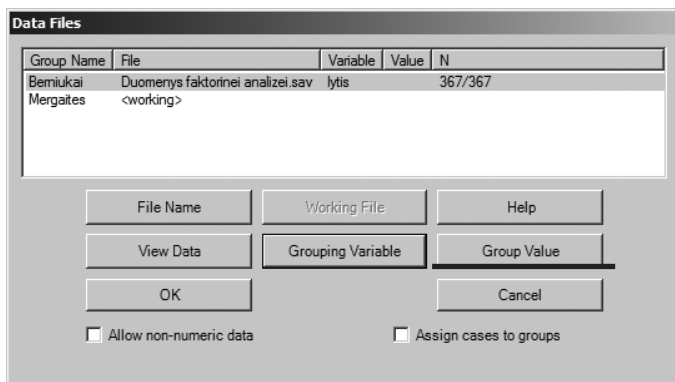
113 pav. Pirmos grupės kodavimo reikšmės nustatymas

Atsidaro naujas langas, kuriame matyti visų kintamųjų, kurie yra duomenų rinkmenoje, pavadinimai. Mūsų norimas grupės (berniukus ir mergaites) gali atskirti kintamasis „lytis“, pažymime ir spaudžiame OK (114 pav.).



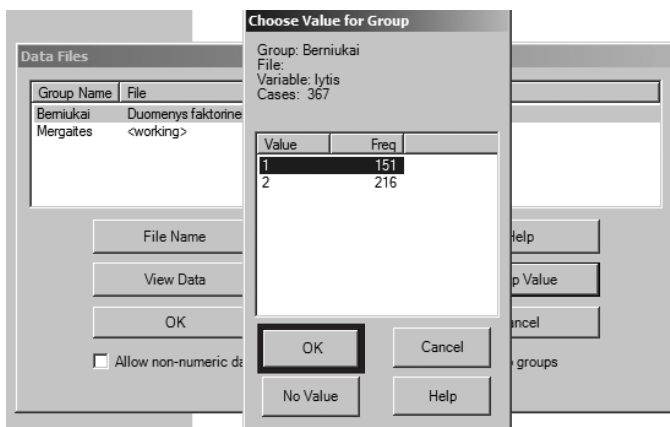
114 pav. Grupių kodavimo kintamojo pasirinkimas

Pagrindiniame lange matome savo pasirinkimą. Tada turime nurodyti, kokių skaičiumi, tai yra kintamojo reikšme, duomenų rinkmenoje yra pažymėti berniukai. Naudojamės funkcija „Grupavimo reikšmė“ (angl. *grouping value*) (115 pav.).



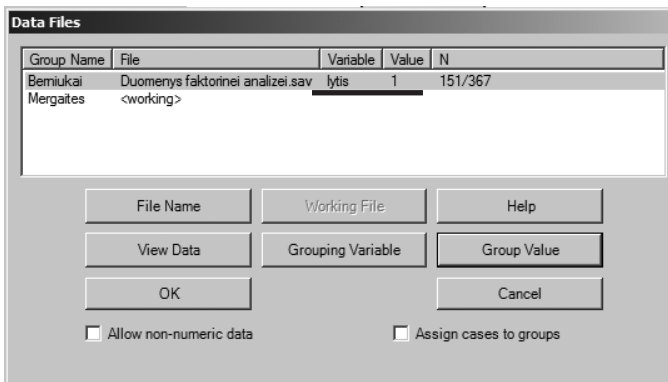
115 pav. Grupavimo kintamojo reikšmės nustatymas

Atsidarius naujam langui pasirenkame skaičių, kuris nurodo berniukus (šioje rinkmenoje tai bus 1), ir spaudžiame OK (116 pav.).



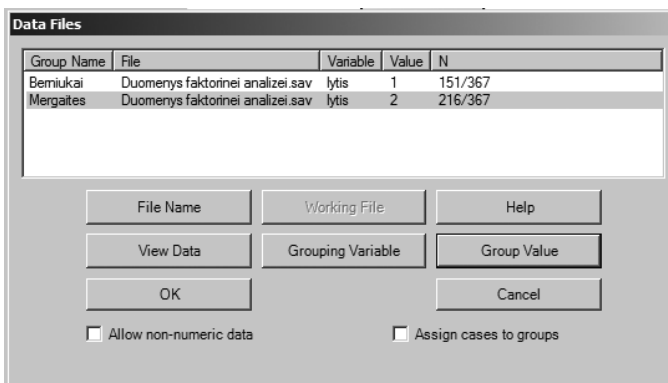
116 pav. Grupavimo kintamojo reikšmės nustatymas berniukams

Pagrindiniame lange matyti, kad pasirinkome 1 (117 pav.).



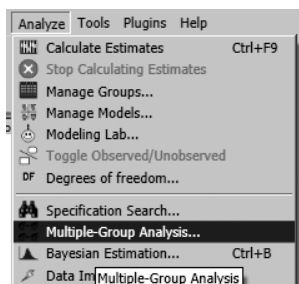
117 pav. Nustatyta grupavimo kintamojo reikšmė berniukams

Tą patį turime padaryti su mergaičių grupe. Tačiau prie mergaičių grupės reikia (pažymėjus mergaičių eilutę) nurodyti duomenų rinkmeną, kuri yra tokia pat, kaip ir berniukų. Per rinkmenos vardo funkciją surandame tą pačią rinkmeną. O tada kaip ir berniukams nurodome, kuris kintamasis žymi grupes ir kaip mergaitės yra koduojamos (koku skaičiumi) duomenų rinkmenoje. Visos grupės turi turėti nurodytas duomenų rinkmenas, grupavimo kintamąjį ir grupavimo reikšmę (skaičių). Tai nurodę, spaudžiame OK (118 pav.).




118 pav. Duomenų rinkmenos ir grupių kodavimo nustatymas berniukams ir mergaitėms

Programai jau pateikta, kad bus dvi grupės, nurodyta, kaip jos užkoduotos duomenų rinkmenoje. Turime nurodyti programai, kokių modelių norime, naudodamiesi meniu įrankiais (*Analyze – Multiple group analysis*) arba įrankiu, esančiu kairėje pusėje (119 pav.).



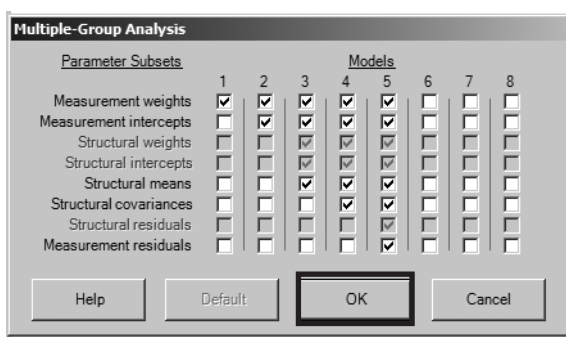
119 pav. Modelio, lyginamo tarp grupių, pasirinkimas

Tuomet atsidaro lentelė, tiksliau, įspėjimas, kad modelis gali modifikuotis, kai bus pradėta analizė. Sutikdami su įspėjimu, turėtume paspausti OK (120 pav.).



120 pav. Įspėjimas apie modelio modifikavimą

Tada atsidaro dar viena lentelė, į kurią programa jau sudėjusi, kokie bus modeliai. Ji siūlo bent penkis modelius, kuriuose grupės bus lyginamos skirtingais aspektais. Pirmame modelyje bus nurodoma, kad lygūs tik grupių faktorių svoriai (angl. *measurement weights*), o paskutiniame – kad visi parametrai programai bus nurodomi kaip lygūs berniukų ir mergaičių. Nieko netaisydami galime spausti OK (121 pav.).



121 pav. Modelių, lyginamų tarp grupių, variantai

Prie modelio įvertinimo langelių (viduryje) atsiranda galimi penki modeliai ir prie jų XX (122 pav.).


Programa jau turi visą informaciją, reikiamą įvertinti atskirai berniukų ir mergaičių imties modelį ir šiuos modelius palyginti. Tad galime pradėti modelio įvertinimą naudodamiesi meniu įrankiais (*Analyze – Calculate Estimates*).

5.2.16. Modelio, naudojantis AMOS programa, lyginimo tarp grupių rezultatai


Kai programa baigia vertinti modelį, diagramoje jau galime matyti koeficientus. Tam reikia paspausti grafinę išraišką „Žiūrėti duomenų išvesties rezultatus“. Ši išraiška, yra rinkmenos, su kuria dirbama, viršuje per vidurį. Norint matyti standartizuotus koeficientus, reikia paspausti „Standartizuoti įverčiai“ langelyje, kuris yra tarp piešimo įrankių ir piešimo lauko. Modelio diagramoje bus matyti skaičiai. Kai yra lyginamos grupės, svarbu pažymėti modelį, kurio tuos skaičius norime matyti. Galime pažymėti modelį, kuris berniukų ir mergaičių modelių neprilygina vieno kitam (angl. *unconstrained*) (123 pav.). Tai yra programa traktuoja, kad berniukų ir mergaičių modelis skirtingas. Po įvertinimo prie visų modelių pavadinimų priekyje turi atsirasti raidės OK. Tik tuomet galime pasitikėti gautais rezultatais.

Matyti, kad mergaičių ir berniukų faktorių svoriai šiek tiek skiriasi (124 pav.). Tuos pačius rezultatus galime matyti ir duomenų išvesties lange, tik, norėdami matyti duomenis, turime pasirinkti mergaites ar berniukus.

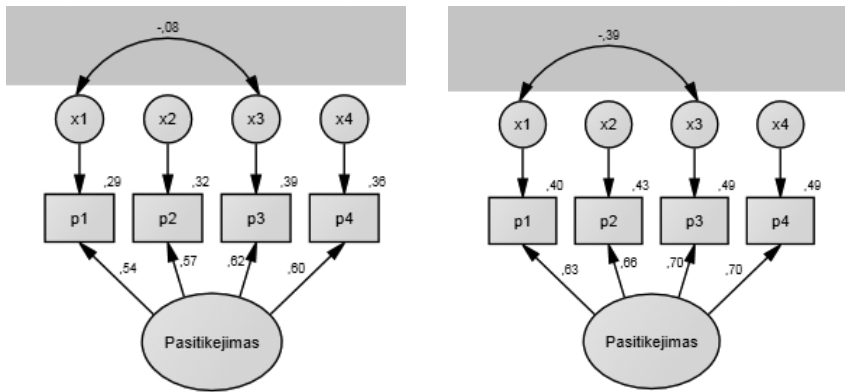
Lyginant modelį tarp grupių svarbus chi kvadratas, kurį reikėtų išsirašyti, nes jis bus lyginamas su vėliau gautais chi kvadratais. Čia jis 1,23 (df = 2). Kol kas tikriname modelį, kuris grupių nėra lygus. Tačiau svarbu išsiaiškinti, ar atskiri berniukų ir mergaičių faktorių svoriai vienodi. Vienas iš vertintų modelių yra matavimų svorių modelis (angl. *measurement weights*), kuriame visi faktorių svoriai sulyginami tarp berniukų ir mergaičių. Šio modelio chi kvadratą galime palyginti su pirmu gautu chi kvadratu ir sužinoti, ar bent vienas berniukų ir mergaičių faktorių svoris gali skirtis. Šio modelio chi kvadratas pateiktas duomenų išvesties lange (125 pav.).



122 pav. Tikrinami atskirų grupių modeliai



123 pav. Modelio, besiskiriančio tarp atskirų grupių, pažymėjimas



- Berniukai
- Mergaitės
- Unconstrained
- Measurement weights
- Measurement intercepts
- Structural covariances
- Measurement residuals

Standardized Regression Weights: (Mergaites - Measurement weights)

	Estimate
p1 <--- Pasitikejimas	,538
p2 <--- Pasitikejimas	,567
p3 <--- Pasitikejimas	,624
p4 <--- Pasitikejimas	,602

Intercepts: (Mergaites - Measurement weights)

	Estimate	S.E.	C.R.	P	Label
p1	3,039	,040	76,183	***	il_2

124 pav. Berniukų ir mergaičių faktorių svoriai

Amos Output

3 7 0

Faktorine.amw

- Analysis Summary
 - Notes for Group
- Variable Summary
- Parameter Summary
- Notes for Model
- Estimates
- Modification Indices
 - Notes for Group/Model
 - Minimization History
- Pairwise Parameter Comparisons
- Model Fit
- Model Comparison
 - Execution Time

Notes for Model (Measurement weights)

Computation of degrees of freedom (Measurement weights)

Number of distinct sample moments: 28
 Number of distinct parameters to be estimated: 23
 Degrees of freedom (28 - 23): 5

Result (Measurement weights)

Minimum was achieved
 Chi-square = 8,794
 Degrees of freedom = 5
 Probability level = ,118

125 pav. Modelio, sulyginančio grupių faktorių svorius, chi kvadratas

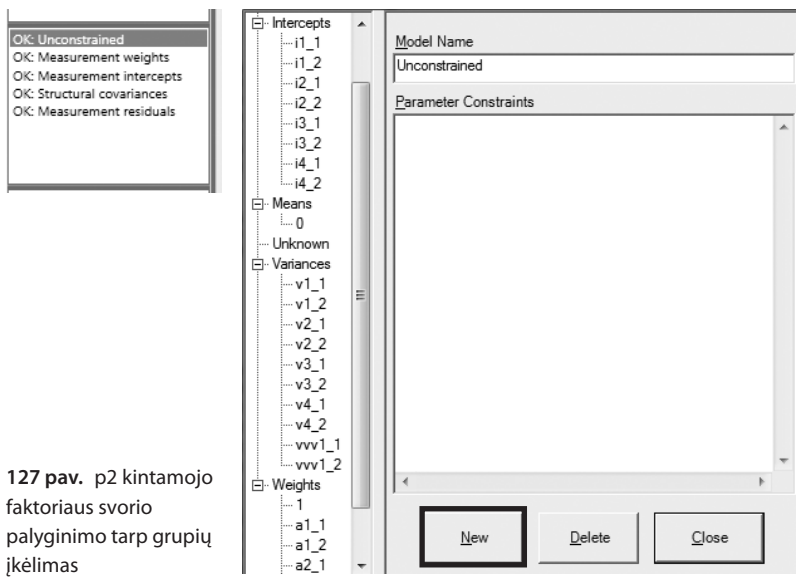
Chi kvadratas yra 8,79 (df = 5). Pirmo modelio (kur niekas nesulyginta tarp berniukų ir mergaičių) chi kvadratas lygus 1,23 ir df = 2, o antrojo (kur visi grupių faktorių svoriai sulyginami) $\chi^2 = 8,79$ ir df = 5. Tai $\Delta \chi^2 = 8,79 - 1,23 = 7,56$; $\Delta df = 5 - 2 = 3$. Žiūrime į chi kvadrato lentelę (126 pav.), surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 3 laisvės laipsnius. Pagal lentelę, esant 3 laisvės laipsniams, chi kvadrato skirtumas turėtų būtų 7,82 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra šiek tiek mažesnis, vadinasi, modeliai nesiskiria, o tai reiškia, kad grupių faktorių svoriai yra vienodi tarp grupių.

df	$\chi^2_{.995}$	$\chi^2_{.990}$	$\chi^2_{.975}$	$\chi^2_{.950}$	$\chi^2_{.900}$	$\chi^2_{.100}$	$\chi^2_{.050}$	$\chi^2_{.025}$	$\chi^2_{.010}$	$\chi^2_{.005}$
1	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
2	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
3	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
4	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
5	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
6	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
7	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
8	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
9	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
10	2.156	2.558	3.247	3.940	4.865	15.987	18.307	20.483	23.209	25.188
11	2.603	3.053	3.816	4.575	5.578	17.275	19.675	21.920	24.725	26.757
12	3.074	3.571	4.404	5.226	6.304	18.549	21.026	23.337	26.217	28.300
13	3.565	4.107	5.009	5.892	7.042	19.812	22.362	24.736	27.688	29.819
14	4.075	4.660	5.629	6.571	7.790	21.064	23.685	26.119	29.141	31.319
15	4.601	5.229	6.262	7.261	8.547	22.307	24.996	27.488	30.578	32.801

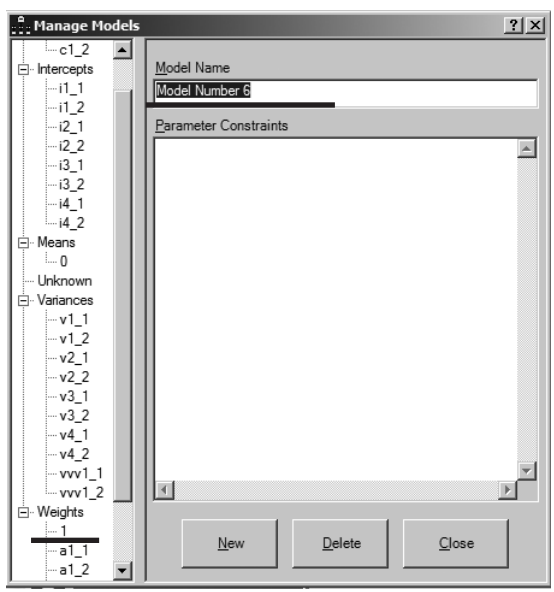
126 pav. Chi kvadrato lentelė (iš Howell, 1997)

Visada galime patikrinti atskirų grupių kintamųjų faktorių svorius, jei tik pirmas modelis (kur nėra jokio sulyginimo tarp grupių) ir antras (kur visi faktoriai sulyginti tarp grupių) skiriasi. Tarkime, norime palyginti p2 kintamojo faktoriaus svorį tarp grupių. Tada turime programai tarsi nurodyti dar savo modelį (be jos pasiūlytų modelių). Užename ant bet kurio modelio pavadinimo ir du kartus paspaudžiame, kad atsidarytų langas (127 pav.). Atsidarius naujam langui turime pasirinkti naują modelį (spaudžiame mygtuką „Naujas“) ir jau tada sudėliojame, ką norime palyginti.

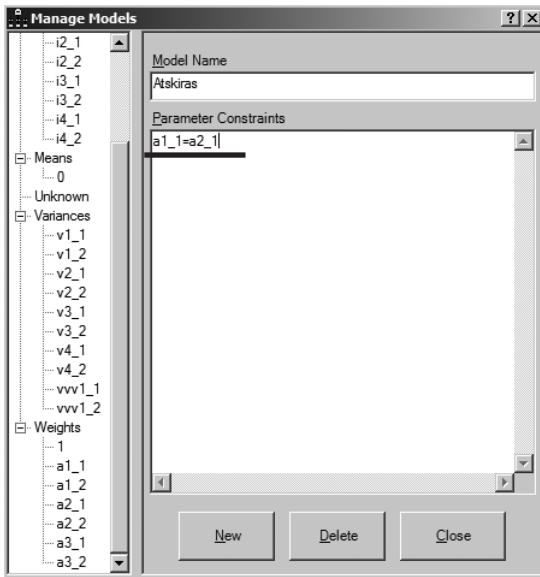
Naują modelį turime pavadinti. Jei norime palyginti faktorių svorius, renkamės parametrus iš faktorių svorių aprašymų, esančių kairėje pusėje (128 pav.).



127 pav. p2 kintamojo faktoriaus svorio palyginimo tarp grupių įkėlimas



128 pav. Naujo modelio, kuris sulygina vieną p2 kintamojo faktoriaus svorį, pavadinimas



129 pav. Antrojo kintamojo faktoriaus svorio palyginimas

Notes for Model (Atskiras)	
Computation of degrees of freedom (Atskiras)	
Number of distinct sample moments:	28
Number of distinct parameters to be estimated:	25
Degrees of freedom (28 - 25):	3
Result (Atskiras)	
Minimum was achieved	
Chi-square =	1,324
Degrees of freedom =	3
Probability level =	,723

130 pav. Modelio, lyginančio antrojo kintamojo faktoriaus svorį, chi kvadratas

Tarkime, norime palyginti p2 kintamojo faktorių svorį tarp abiejų grupių. Faktorių svoriai pažymėti raide a. Skaičius po raidės rodo grupę, skaičius po brūkšnelio – kintamąjį. Pirmas faktorių svoris nelyginamas, nes jis prilyginamas 1 ir nežymimas skaičiumi. Visi kiti kintamieji, pradedant antruoju, žymimi skaičiais nuo vieneto. Tai lentelė, kurioje yra sulyginami tam tikri įverčiai (angl. *parametre constrained*), sudedami abiejų grupių šio kintamojo svoriai (jie bus a1_1 ir a2_1). Tarp jų dedame lygybės ženklą (129 pav.).

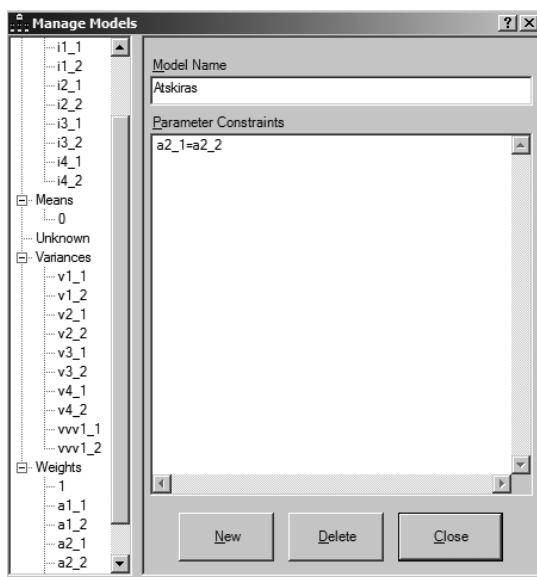
Uždarome lentelę ir leidžiame programai vėl iš naujo vertinti modelį (*Analyze – Calculate Estimates*). Tada duomenų išvesties lange ieškome šio modelio chi kvadrato (130 pav.).

Ir ankstesnį (kur nebuvo jokių lyginimų tarp grupių), ir šį modelį (kur lyginamas tik vienas faktoriaus svoris) palyginame, atsižvelgdami į chi kvadrato skirtumus. Tai $\Delta \chi^2 = 1,32 - 1,23 = 0,09$; $\Delta df = 3 - 2 = 1$. Žiūrime į chi kvadrato

lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 1 laisvės laipsnį. Pagal lentelę, esant 1 laisvės laipsniui, chi kvadrato skirtumas turėtų būti 3,841 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra gerokai mažesnis, vadinasi, modeliai nesiskiria, o tai reiškia, kad p2 kintamojo faktoriaus svoris abiejų grupių yra vienodas. Tada galima lyginti ir kitus (likusius faktorių svorius). Pavyzdžiui, p3 kintamojo. Užeiname ant prieš tai buvusio modelio pavadinimo ir du

kartus paspaudžiame, kad atsida-rytų langas, tada pakeičiame a1_1 ir a2_1 į a1_2 ir a2_2 (131 pav.). Tai rodo, kad lyginsime abiejų grupių trečiojo kintamojo faktoriaus svorį.

Taip galima patikrinti visų kintamųjų faktorių svorius. Visuomet naudojames chi kvadrato skirtumais. Tik svarbu prisiminti, kad dirbdami su AMOS programiniu paketu turėtume duomenų rinkmenoje sutvarkyti praleistas kintamųjų reikšmes.

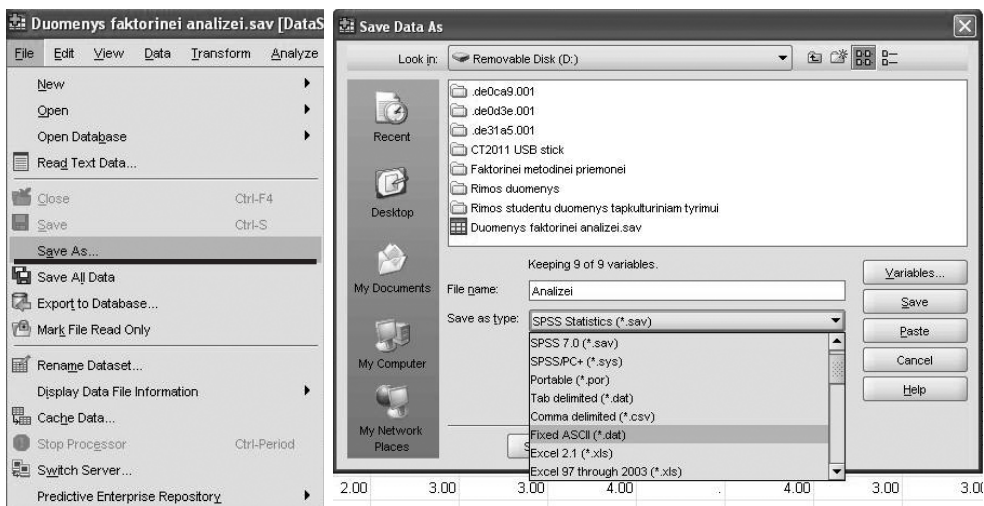


131 pav. Trečiojo kintamojo faktoriaus svorių palyginimas tarp grupių

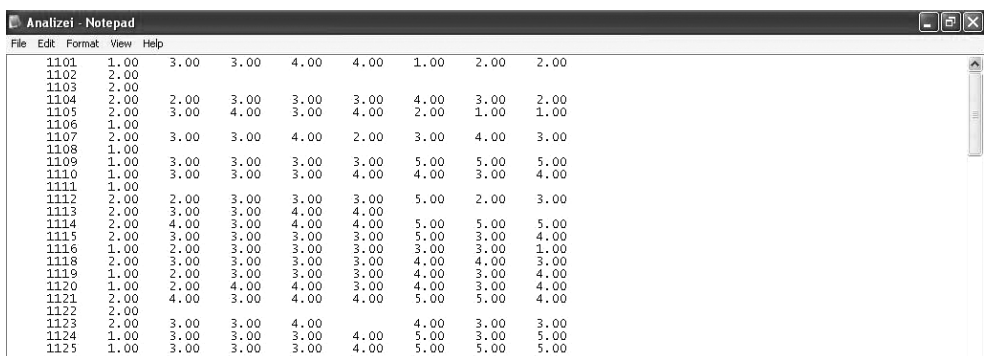
5.2.17. Patvirtinamosios faktorių analizės atlikimas, naudojantis „Mplus“ programa

„Mplus“ programa yra viena iš struktūrinių lygčių programų. Ši programa skiriasi nuo AMOS programos. „Mplus“ programa nepateikia grafinio patvirtinamosios faktorių analizės vaizdo, tai yra negalima piešti ar gauti nupieštų diagramų. Taip pat negalima tiesiogiai įkelti duomenų iš SPSS programos. Tad AMOS programa tarsi geresnė pradedant naudoti struktūrinių lygčių modeliavimą. Tačiau „Mplus“ programa turi kitų pranašumų, pavyzdžiui, dirba su praleistomis reikšmėmis, kurių nereikia pakeisti vidurkiu ar ką nors su jomis daryti. Dirbant „Mplus“ programa, visos duomenų rinkmenos turi būti perdarytos į tekstines rinkmenas, dažniausiai į .dat rinkmenas (geriausia ASCII rinkmenos). ASCII rinkmenos padaromos naudojant SPSS programą, tai yra norima duomenų rinkmena išsaugoma kaip .dat rinkmena. Turint sutvarkytą savo duomenų rinkmeną, meniu juostoje reikia pasirinkti „Rinkmenos išsaugojimas“ (*File – Save as*), paspaudus nuorodą „Išsaugoti“ norimoje vietoje, tik pasirinkti, kad programa išsaugotų .dat (Fixed ASCII) rinkmenos tipą (132 pav.).

Išsaugojus duomenis .dat formatu, svarbu tokią rinkmeną atidaryti ir patikrinti, ar joje nėra likę kablelių vietoje taškų. Tokia (.dat) duomenų rinkmena atidaroma



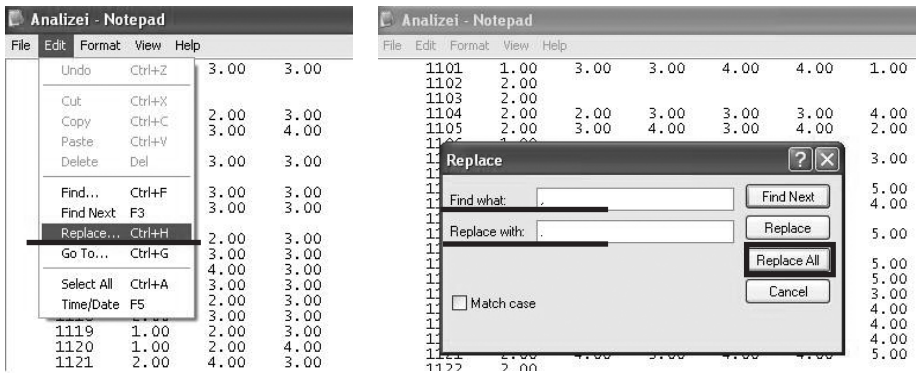
132 pav. Tekstinės rinkmenos išsaugojimas



133 pav. Atidaryta tekstinė rinkmena

„Wordpad“ arba „Notepad“ programomis. Jei duomenų rinkmenoje liks kablelių, „Mplus“ programa nuskaitys rinkmenos ir negalės patikrinti modelio. Tad svarbu atidaryti išsaugotą rinkmeną (133 pav.).

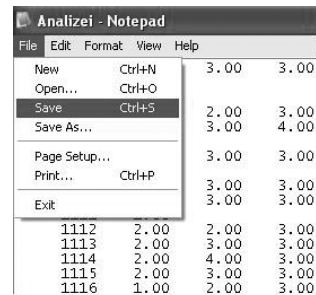
Tuščios vietos atidarytoje rinkmenoje – tai praleistos reikšmės, kurios nepakeistos skaičiumi. Jei rinkmenoje vietoje taškų matyti kableliai, juos būtina pakeisti. Gerai būtų šiuos žingsnius atlikti tiesiog profilaktiškai. Eiti į meniu, pasirinkti „Redaguoti“ (angl. *edit*), tada „Keisti“ (angl. *replace*), kur prie „Rasti“ (angl. *find what*) parašyti kablelį, o prie „Keisti į“ (angl. *replace with*) tašką ir paspausti „Keisti viską“ (angl. *replace all*) mygtuką (134 pav.).




134 pav. Kabelių pakeitimas

Atlikus šiuos veiksmus būtina išsaugoti pakeitimus toje pačioje rinkmenoje (angl. *save*) (135 pav.).

Kai duomenų rinkmena sutvarkyta, galime pradėti rašyti sintaksę. Sintaksė – tai komandos programai, informacija, ką norime daryti, nes naudojantis šia programa negalima nupiešti modelio – viską reikia aprašyti. „Mplus“ programinis paketas turi savo sintaksės (arba komandų) kalbą. Atidarius programą, atsidaro naujas sintaksės langas, kuriame ir rašome komandas, t. y. programai pasakome, ką norime padaryti, kokį modelį įvertinti (136 pav.).

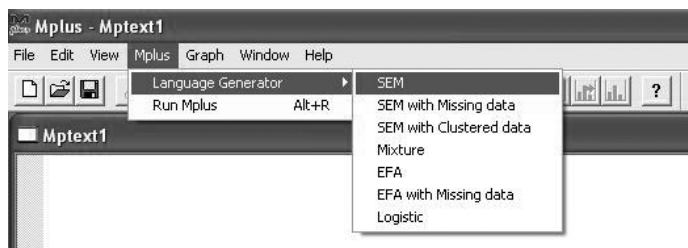


135 pav. Pakeitimų išsaugojimas



136 pav. „Mplus“ programos langas

Nenorint rašyti sintaksės, visada galima naudotis kalbos generatoriumi, kurį galima rasti meniu juostoje (*Mplus – Language generator*) (137 pav.). O tada jau renkamės modelį, kurį norime įvertinti. Atliekant patvirtinamąją faktorių analizę naudojamosi SEM nuoroda arba SEM *with missing data*, ji skirta modeliams, kurie duomenyse turi praleistų reikšmių.



137 pav. Kalbos generatoriaus atidarymas

Patartina pirmiausia išmokti rašyti sintaksę, o tik tada naudotis kalbos generatoriumi. Nes, rašant sintaksę, visuomet galima kontroliuoti, kas padaryta ne taip, lengviau pamatyti padarytas klaidas. Tad čia bus pateikiamos gairės sintaksės rašymui, o ne kalbos generatoriaus funkcijoms. „Mplus“ programos pagrindinės komandos turi atskiras dalis, kurios gali šiek tiek skirtis sudėtingėjant modeliams.

Patvirtinamosios faktorių analizės modelių sintaksė gana paprasta. Standartinės visų modelių, kaip ir patvirtinamosios faktorių analizės modelių, sintaksės dalys yra: TITLE, DATA, VARIABLE, MODEL, OUTPUT. Rašyti didžiosiomis raidėmis nebūtina, „Mplus“ programai tai nėra svarbu. Tiesiog išskyrimo sumetimais pateiksiu didžiosiomis raidėmis.

Komanda TITLE: rašomas pavadinimas, kuris gali būti bet kokio ilgio. Tai pavadinimas dirbančiajam, o ne programai.

Pavyzdžiui:

TITLE: cfa testuojamas modelis

Komanda DATA: ji turi kelias subkomandas: FILE IS, FORMAT IS, TYPE IS.

Subkomanda FILE IS pasako, kur yra duomenų rinkmena. Jei sintaksės rinkmena nebus išsaugota tame pačiame aplanke kaip ir duomenų rinkmena (kuri jau paruošta kaip .dat rinkmena), reikia nurodyti visą katalogą – c:\stat\cfa\cfaduomenys.dat. O jei rinkmena bus išsaugota tame pačiame aplanke, nurodomas tik jos pavadinimas – cfaduomenys.dat. Prisimintina, kad nuo komandos DATA kiekviena eilutė

būtinai turi baigtis kabliataškiu (;). Jei nebus kabliataško, programa nenuskaitys tos eilutės.

Pavyzdžiui: jei sintaksės rinkmena bus kitame aplanke nei duomenų rinkmena

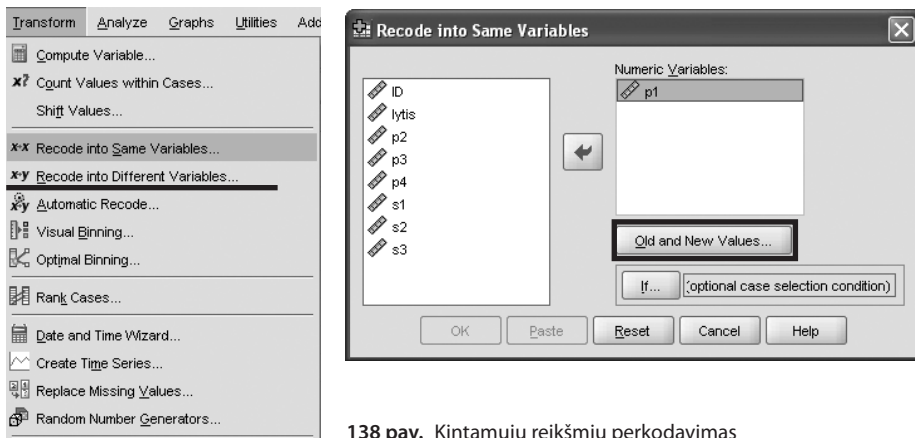
```
DATA: FILE IS c:\temp\cfa\cfaduomenys.dat;
```

arba jei sintaksė bus tame pačiame aplanke kaip ir duomenų .dat rinkmena

```
DATA: FILE IS cfaduomenys.dat;
```

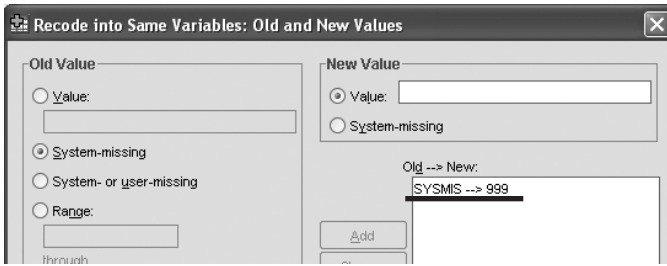
Kita atskira subkomanda yra FORMAT IS. Ji nurodo duomenų rinkmenos formatą. Šios subkomandos reikia tam, kad programa galėtų perskaityti duomenų rinkmeną, kuri .dat formatu yra kaip tekstinė rinkmena. Todėl turime nurodyti, kur prasideda atskirų kintamųjų stulpeliai, kur baigiasi ir kiek pozicijų užima. Duomenų rinkmenos formatas gali būti laisvas (angl. *free*) arba fiksuotas (angl. *fixed*).

Laisvas formatas galimas tik tada, kai praleistos duomenų rinkmenos reikšmės nėra tuščios vietos, bet toms reikšmėms priskiriama reikšmė, tai yra koks nors skaičius (pvz., 999). Priskyrimas turėtų būti padarytas naudojant SPSS programą. Perkodavimas atliekamas jau dirbant pačia SPSS programa (*Transform – Recode into same variables*) (138 pav.). Paspaudus šią nuorodą, atsidaro lentelė, kurioje nurodome, kurį kintamąjį perkoduosime (pvz., p1), jį ir perkeliame į kintamųjų langelį. Tuomet spaudžiame mygtuką „Senos ir naujos reikšmės“.



138 pav. Kintamųjų reikšmių perkodavimas

Atsidarius naujai lentelei, prie senų reikšmių reikšmių langelyje pasirenkame „Praleistos reikšmės“. O naujų reikšmių pusėje įrašome perkodavimą, pavyzdžiui, 999, ir spaudžiame mygtuką „Pridėti“ (139 pav.).



139 pav. Buvusios ir naujos kintamųjų reikšmės ir jų keitimas

Norint turėti laisvą formatą, taip reikėtų padaryti su visais kintamaisiais, kuriuos naudosime modelyje. Jei praleistų reikšmių neperkoduojame, formatas turi būti fiksuotas. Abu būdai geri ir tik nuo tyrėjo priklauso, kurį naudoti dirbant su duomenimis.

```
DATA: FILE IS cfaduomenys.dat;
FORMAT IS free;
```

Norint duomenų rinkmenoje praleistas reikšmes turėti kaip tuščias vietas (kaip ir parodyta anksčiau), turi būti fiksuotas duomenų formatas.

```
DATA: FILE IS cfaduomenys.dat;
FORMAT IS 1F9.0 8F8.2;
```

Toks parašymas reiškia, kad pirmiausia duomenų rinkmenoje yra vienas kintamasis, kuris užima devynias pozicijas (todėl pirmas skaičius 9), iš tų devynių nėra vienos nėra po kablelio (todėl skaičius 0). Tada duomenų rinkmenoje yra aštuoni iš eilės einantys tokio pat formato kintamieji (skaičius prieš raidę F) – užima aštuonias pozicijas ir iš jų dvi po kablelio. Skaičius prieš raidę F visada nurodo, kiek iš eilės bus vienodo formato kintamųjų, pirmas skaičius po raidės F nurodo, kiek pozicijų užima kintamasis, skaičius po taško – kiek tame kintamajame yra skaičių po kablelio. Iš kur gaunamas kintamųjų formatas? Iš SPSS duomenų rinkmenos (paspaudus *Variable view*, stulpeliai *Width* ir *Decimals* nurodo formatą) (140 pav.).

	Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
1	ID	Numeric	9	0		None	None	8	Right	Scale
2	lytis	Numeric	8	2		None	None	8	Right	Scale
3	p1	Numeric	8	2		None	None	8	Right	Scale
4	p2	Numeric	8	2		None	None	8	Right	Scale
5	p3	Numeric	8	2		None	None	8	Right	Scale
6	p4	Numeric	8	2		None	None	8	Right	Scale
7	s1	Numeric	8	2		None	None	8	Right	Scale

140 pav. Kintamųjų formatas duomenų rinkmenoje

Kai išsaugome savo duomenis .dat formatu, SPSS duomenų išvesties lange randame prie kiekvieno kintamojo nurodytą formatą (stulpelis *Format*) (141 pav.).

Write will generate the following				
Variable	Rec	Start	End	Format
ID	1	1	9	F9.0
lytis	1	10	17	F8.2
p1	1	18	25	F8.2
p2	1	26	33	F8.2
p3	1	34	41	F8.2
p4	1	42	49	F8.2
s1	1	50	57	F8.2
s2	1	58	65	F8.2
s3	1	66	73	F8.2
EXECUTE.				

141 pav. Kintamųjų formatas duomenų išvesties lange

Dar viena subkomanda yra TYPE IS. Ji nurodo duomenų tipą. Kiekviena duomenų eilutė reiškia skirtingą žmogų, o stulpeliai – kintamuosius. Tai bus: TYPE IS individual. Jei turime tokius duomenis, net nebūtina tai rašyti. Jei neparašysime, „Mplus“ programa supras, kad duomenys paprasti, nėra, pavyzdžiui, diadiniai ar tokie, kur vienam žmogui duomenų rinkmenoje priskiriamos kelios eilutės.

Pavyzdžiui:

```
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
```

Komanda VARIABLE: turi kelias subkomandas: NAMES ARE, USEVARIABLES ARE, MISSING ARE. Subkomandos NAMES ARE reikia norint nurodyti visų kintamųjų, kurie yra mūsų turimoje duomenų rinkmenoje, vardus. Nurodomi visi kintamieji, net ir tie, kurie modelyje nebus naudojami (pvz., duomenų rinkmenoje galime turėti palikę kintamąjį „lytis“, o analizei tokio kintamojo nenaudosime). Geriausia naudoti tokius pat kintamųjų pavadinimus, kokie buvo SPSS duomenų rinkmenoje. Kintamieji surašomi ta pačia tvarka, kokia išdėstyti SPSS duomenų rinkmenoje.

Pavyzdžiui:

```
VARIABLE: NAMES ARE lytis p1 p2 p3 p4 s1 s2 s3;
```

Subkomanda USEVARIABLES ARE pasako, kurie kintamieji iš visų turimų ir jau programai pristatytų bus naudojami tikrinamame modelyje. Rinkmenoje gali būti daug daugiau kintamųjų, negu jų bus panaudota modelyje (pvz., galime turėti net kelias dešimtis, o panaudosime tik aštuonis). Visų rinkmenoje esamų kintamųjų vardus aprašome prie NAMES ARE, o čia (USEVARIABLES ARE) aprašome tik tų kintamųjų vardus, kurie bus naudojami modelyje.

Pavyzdžiui: modelyje nenaudosiu kintamojo ID, lytis ir s1–s3 kintamųjų, kurie yra mano duomenų rinkmenoje.

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;
```

Subkomandos MISSING ARE reikia aprašyti praleistas rinkmenoje reikšmes (jei tokių buvo). Praleistos reikšmės dažnai žymimos tokiu pat skaičiumi (geriausia, kad visuose kintamuosiuose praleistas reikšmes žymėtų tas pats skaičius), kaip ir SPSS duomenų rinkmenoje. Gerai pasirinkti tokį skaičių, kuris nebus nė vieno turimo kintamojo reikšmė, pavyzdžiui, 999 ar pan. Praleistos reikšmės taip pat gali būti ir tuščias langelis, kuriame neįrašytas joks skaičius. Prie šios subkomandos parašome, kaip duomenų rinkmenoje žymimos praleistos reikšmės.

Pavyzdžiui: jei praleistos reikšmės žymėtos skaičiumi (tuo pačiu visuose kintamuosiuose),

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;  
MISSING ARE all (999);
```

Arba jei kur reikšmės praleistos, paliktas tuščias langelis

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;  
MISSING ARE all blank;
```

Jei mūsų kintamieji būtų kategoriniai (šiuose duomenyse to nėra, bet pateikiama tik kaip pavyzdys, kaip rašyti), tai po praleistų reikšmių juos turėtume aprašyti. Ir pridėtume kitą eilutę. Kategorinius duomenis, jei tik jų turime, galime naudoti ir atlikdami patvirtinamąją faktorių analizę „Mplus“ programa.

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;  
MISSING ARE all blank;  
CATEGORICAL ARE p1 p2;
```

Komanda ANALYSIS: ši komanda nurodo, koks analizės metodas bus taikomas. Visiems paprastesniems metodams (taip pat ir patvirtinamajai faktorių analizei) naudojamas GENERAL.

Pavyzdžiui:

```
ANALYSIS TYPE = general;
```


Davę komandą ANALYSIS taip pat galime rinktis modelio įvertinimo metodą. Didžiausiojo tikėtinumo metodas (ML) tinka normaliai pasiskirsčiusiems duomenims ir, kai nėra praleistų reikšmių, taikomas pačios programos. Jei sintaksėje aprašytos praleistos reikšmės, programa automatiškai taiko išsamios informacijos didžiausiojo tikėtinumo metodą (FIML). Bet jei mūsų duomenys nėra normaliai pasiskirstę (viena iš faktorių analizės prielaidų pažeista), geriau rinktis MLR įvertinimo metodą, kuris ir pritaikytas duomenims, nukrypusiems nuo normalumo. Įvertinimo metodas rašomas tik tada, kai renkamasi ne ML ar FIML (tai automatiškai priskiria pati programa).

Pavyzdžiui:

```
ANALYSIS: TYPE = general;
```

```
ESTIMATOR = MLR;
```

Komanda MODEL: „Mplus“ programa neturi grafinio vaizdavimo, todėl savo modelį turime aprašyti žodžiais ir negalime jo pavaizduoti kaip naudodami AMOS programą. Visiems modeliams aprašyti vartojami tik trys žodžiai: BY, WITH ir ON. Atlikdami tiriamąją faktorių analizę naudosimės tik BY ir WITH. Žodis BY vartojamas latentiniams kintamiesiems aprašyti, jis nurodo, kad matavimų kintamieji sudaro latentinį kintamąjį. Latentinių kintamųjų pavadinimas neturėtų būti keli atskiri žodžiai, geriausia vienas žodis ar trumpinys iš daugiausia 8 simbolių.

Pavyzdžiui: pasitikėjimo savimi latentiniam kintamajam aprašyti (jei latentinių kintamųjų turėtume daugiau, tai jie būtų aprašomi taip pat tik kitose eilutėse – kiekvienam latentiniam kintamajam atskira eilutė, o kiekviena eilutė baigiasi kabliataškiu)

```
MODEL: pasit BY p1 p2 p3 p4;
```

Tokia komanda rodo, kad pasitikėjimo savimi latentinis kintamasis sudaromas iš keturių matavimo kintamųjų. Jei modelyje būtų keli latentiniai kintamieji, tai koreliaciniai ryšiai tarp jų būtų aprašomi vartojant žodį WITH.

Pavyzdžiui:

```
pasit WITH draug;
```

Paklaidų modelyje aprašyti nereikia, programa jas skaičiuoja be mūsų prašymo. Žodis ON vartojamas, kai modelyje yra priežastiniai ryšiai. Patvirtinamosios faktorių analizės modeliuose tokie ryšiai nenaudojami ir nėra traktuojami kaip regresiniai (nors ir yra vienpusės rodyklės tarp latentinio ir matavimų kintamųjų). Tačiau jei

vienas latentinis kintamasis nuspėtų kitą, tada ir vartotume žodį ON, tik modelis jau vadintųsi Kelių analizė. Apie kelių analizę galima daugiau sužinoti V. Čekanavičiaus ir G. Murausko bei kitose struktūrinės lygtis pristatančiose knygose.

Komanda OUTPUT: čia nurodome, ką norime gauti iš programos, kokie skaičiaiavimai mums įdomūs ar reikalingi. SAMP arba SAMPSTAT parašymas reikš, kad norime matyti imties aprašomąją statistiką (pvz., vidurkiai, dispersija). STAND arba STANDARDIZED nurodo, kad norime matyti standartizuotus koeficientus (kurie paprastai ir skelbiami). MOD(4) arba MODINDICES(4) sako, kad norime matyti modifikacijos indeksus, kurie didesni už 4 (tik tokio dydžio modifikacijos indeksai gali pagelbėti koreguojant modelį). Modifikacijos indeksai rodo, kiek sumažėtų modelio chi kvadrato reikšmė, jei padarytume siūlomus pakeitimus. Nurodomas 4, mat tik tokio dydžio modifikacija prasminga, nes vieno laisvės laipsnio chi kvadratas yra 3,84. Taigi čia tarsi būtų mažiausias pokytis ir pakeitimas mažiau nei 4 nebūtų prasmingas. Jei rašome PAT arba PATTERNS, vadinasi, norime matyti praleistų reikšmių išklotines ir profilius. CINT arba CINTERVAL nurodo, kad norime matyti pasikliautinuosius intervalus. Programa perskaito tiek visus žodžius, tiek jų sutrumpinimus. Tad kaip rašyti, kiekvienas gali pasirinkti pats.

Pavyzdžiui:

```
OUTPUT: SAMPSTAT; STANDARDIZED; MODINDICES(4); PATTERNS; CINTERVAL;
```

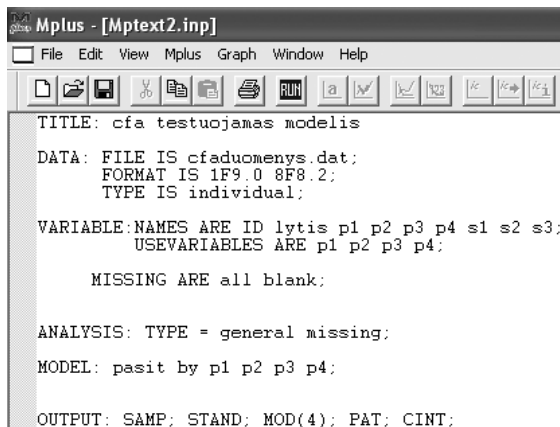
Arba jei vartojame sutrumpinimus

```
OUTPUT: SAMP; STAND; MOD(4); PAT; CINT;
```

Tad visa mūsų sintaksė testuojant, ar p1–p4 kintamieji tikrai sudaro vieną latentinį faktorių, galėtų būti tokia:

```
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
          USEVARIABLES ARE p1 p2 p3 p4;
          MISSING ARE all blank;
ANALYSIS: TYPE = general;
MODEL: pasit BY p1 p2 p3 p4;
OUTPUT: SAMP; STAND; MOD(4); PAT; CINT;
```

Pačioje „Mplus“ programoje ji atrodo taip (142 pav.).



```
Mplus - [Mptext2.inp]
File Edit View Mplus Graph Window Help

TITLE: cfa testuojamas modelis

DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;

VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
           USEVARIABLES ARE p1 p2 p3 p4;

           MISSING ARE all blank;

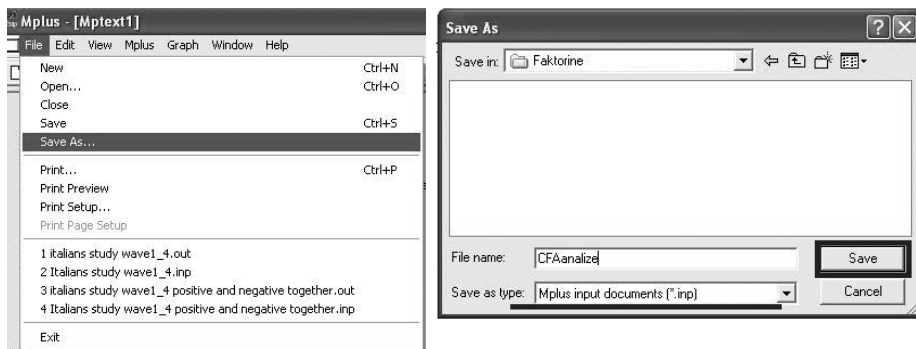
ANALYSIS: TYPE = general missing;

MODEL: pasit by p1 p2 p3 p4;

OUTPUT: SAMP; STAND; MOD(4); PAT; CINT;
```

142 pav. „Mplus“ programos sintaksė

Sintaksės rinkmena turi būti išsaugoma (geriausia – tame pačiame aplanke, kaip ir duomenų rinkmena). „Mplus“ programos sintaksės rinkmenos išsaugomos taip pat, kaip ir visos kitos (143 pav.). Meniu eilutėje pasirenkame „Išsaugoti rinkmeną“ (*File – Save as*). Tada nurodome programai, kurioje vietoje išsaugoti, ir tą rinkmeną išsaugome. „Mplus“ programos sintaksės rinkmenos baigiasi .inp.



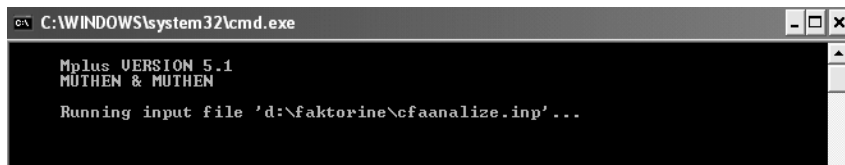
143 pav. Sintaksės rinkmenos išsaugojimas

Išsaugoję rinkmeną galime leisti programai vertinti mūsų modelį (spaudžiame mygtuką *run*) (144 pav.).



144 pav. „Mplus“ programos sintaksės rinkmenos paleidimas

Programai pradėjus apdoroti duomenis, ekrane pasirodo juoda lentelė (145 pav.). Ji ekrane matoma trumpą laiką, o paskui atsiranda duomenų išvesties langas, jei tik nepadarėme jokių klaidų rašydami sintaksę ar duomenų rinkmenoje nepalikome kablelių vietoje taškų.

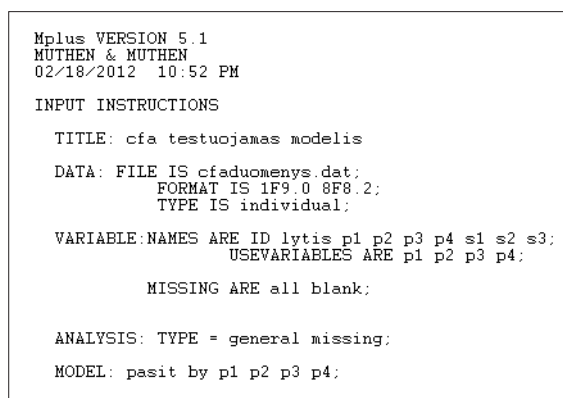


```
C:\WINDOWS\system32\cmd.exe
Mplus VERSION 5.1
MUTHEN & MUTHEN
Running input file 'd:\faktorine\cfaanalyze.inp'...
```

145 pav. „Mplus“ programos sintaksės skaičiavimas

5.2.18. Patvirtinamosios faktorių analizės, naudojantis „Mplus“ programa, rezultatai

Pirmoje duomenų išvesties lango dalyje visuomet rasime tą pačią sintaksės rinkmeną, kurią patys surašėme (146 pav.).



```
Mplus VERSION 5.1
MUTHEN & MUTHEN
02/18/2012 10:52 PM

INPUT INSTRUCTIONS

TITLE: cfa testuojamas modelis

DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;

VARIABLE NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
USEVARIABLES ARE p1 p2 p3 p4;

MISSING ARE all blank;

ANALYSIS: TYPE = general missing;

MODEL: pasit by p1 p2 p3 p4;
```

146 pav. Duomenų išvesties lange pristatoma sintaksės rinkmena

Toliau eina imties dydis, priklausomieji, nepriklausomieji kintamieji, duomenų rinkmenos aprašymas (147 pav.). Čia nurodome, kiek tiriamųjų yra mūsų imtyje (angl. *number of observations*), kiek turime priklausomųjų (angl. *number of dependent variables*), kiek nepriklausomųjų (angl. *number of independent variables*), kiek latentinių kintamųjų (angl. *number of continuous latent variables*), kokie matavimų priklausomųjų kintamųjų pavadinimai (angl. *observed dependent variables*) ir koks latentinio kintamojo pavadinimas (angl. *continuous latent variable*).

```

cfa testuojamas modelis
SUMMARY OF ANALYSIS
Number of groups                1
Number of observations          331
Number of dependent variables   4
Number of independent variables 0
Number of continuous latent variables 1
Observed dependent variables
Continuous
P1          P2          P3          P4
Continuous latent variables
PASIT

```

147 pav. Duomenų aprašymas

Jei rašydami sintaksę prie OUTPUT komandos buvome pažymėję PAT, tai tuomet ir rasime praleistų reikšmių išsklotines, profilius (148 pav.). Matysime, kiek tiriamųjų turi reikšmes visuose kintamuosiuose, kiek tiriamųjų turi trūkstamų reikšmių. Kartais tai gali būti svarbu, jei norime, kad visi mūsų tiriamieji turėtų tam tikro kintamojo reikšmes. Taigi žiūrėdami į išsklotinę galime matyti, ar taip yra, ar kelių tiriamųjų duomenų nereikėtų įtraukti į analizę. Šiame pavyzdyje (148 pav.) yra 4 praleistų reikšmių profiliai (angl. *number of missing data pattern*). Todėl pateikiama, kaip jie atrodo. X žymi turimas reikšmes. Tad pateikti duomenys rodo, kad 322 žmonės (šis skaičius yra prie dažnių (angl. *missing data pattern frequencies*)) turi reikšmes visuose kintamuosiuose, nes jie visi priklauso pirmam profilui, o pirmas profilis turi reikšmes p1–p4 kintamuosiuose (žiūrėti prie profilių (angl. *missing data patterns*)). Keturi tiriamieji priklauso antram profilui, tai šie tiriamieji neturi p4 kintamojo reikšmių. Trečią profilį turi tik vienas tiriamasis, jis neturi p3 ir p4 kintamųjų reikšmių. Ketvirtam profilui priklauso keturi tiriamieji ir jie neturi p2 kintamojo reikšmių. Tad šie profiliai leidžia geriau įvertinti duomenis. Jei norime atlikti analizę naudodami išsamius tiriamųjų duomenis, tai rinkmenoje turėtume pasilikti tik 322 tiriamuosius, o kitus, kurie priklauso kitiems profilams, ištrinti. Visada svarbu apgalvoti, kokių duomenų reikia, ir tik tada daryti pakeitimus.

```

SUMMARY OF DATA
Number of missing data patterns      4
SUMMARY OF MISSING DATA PATTERNS
MISSING DATA PATTERNS (x = not missing)
P1  1  2  3  4
    x  x  x  x
P2  x  x  x
P3  x  x  x
P4  x          x
MISSING DATA PATTERN FREQUENCIES
Pattern  Frequency  Pattern  Frequency
  1      322        3          1
  2          4        4          4

```

148 pav. Praleistų reikšmių profiliai ir dažniai

Po praleistų reikšmių profilių eina kovariacijos padengimas (angl. *covariance coverage*) (149 pav.). Minimali reikšmė pateiktoje lentelėje turėtų būti 0,100, norint įvertinti modelį, tačiau tokia reikšmė vengtina ir gana pavojinga skaičiavimui ir rezultatų vertinimui. Skaičiai lentelėje turėtų būti kuo didesni ir artimesni 1. Ši lentelė parodo, kiek yra stebėjimų, dviejų kintamųjų duomenų. Pavyzdžiui, p1 ir p4 stebėjimų, tai yra tiriamųjų, turinčių duomenis abiejuose kintamuosiuose, yra 0,985, vadinasi, 98,5 proc. tiriamųjų atsakė į tuos abu klausimus.

COVARIANCE COVERAGE OF DATA				
Minimum covariance coverage value 0.100				
PROPORTION OF DATA PRESENT				
	Covariance Coverage P1	P2	P3	P4
P1	1.000			
P2	0.988	0.988		
P3	0.997	0.985	0.997	
P4	0.985	0.973	0.985	0.985

149 pav. Kovariacijos padengimas

Toliau eina aprašomoji statistika: kintamųjų, naudotų modelyje, vidurkiai, koreliacijos ir kovariacijos tarp kintamųjų (150 pav.).

SAMPLE STATISTICS				
ESTIMATED SAMPLE STATISTICS				
	Means P1	P2	P3	P4
1	2.927	3.055	3.143	3.203
	Covariances P1	P2	P3	P4
P1	0.430			
P2	0.138	0.362		
P3	0.120	0.179	0.443	
P4	0.164	0.145	0.173	0.381
	Correlations P1	P2	P3	P4
P1	1.000			
P2	0.350	1.000		
P3	0.275	0.448	1.000	
P4	0.406	0.391	0.420	1.000

150 pav. Aprašomoji statistika

Kiek toliau pateikiami modelio tinkamumo kriterijai: chi kvadratas, p reikšmė, CFI, TLI ir RMSEA (151 pav.). Tai ir parodo modelio tinkamumą esamiems duomenims.

TESTS OF MODEL FIT		
Chi-Square Test of Model Fit		
Value	8.092	
Degrees of Freedom	2	
P-Value	0.0175	
Chi-Square Test of Model Fit for the Baseline Model		
Value	234.103	
Degrees of Freedom	6	
P-Value	0.0000	
CFI/TLI		
CFI	0.973	
TLI	0.920	
RMSEA (Root Mean Square Error Of Approximation)		
Estimate	0.096	
90 Percent C.I.	0.034	0.169
Probability RMSEA <= .05	0.098	

151 pav. Modelio tinkamumo kriterijai

Pateikti tinkamumo kriterijai siūlo išvadą, kad modelis nėra pats geriausias, jis galėtų būti tobulinamas (rezultatai labai panašūs į gautuosius vertinant šį modelį AMOS programa), nes TLI = 0,920 (TLI reikšmės > 0,95 rodo, kad modelis geras), CFI = 0,973 (CFI reikšmės > 0,95, vadinasi, modelis geras), RMSEA = 0,096 (RMSEA reikšmė nuo 0,08 iki 0,10, taigi modelis galimas, tačiau reikėtų patikrinti, ar negalimi geresni modeliai). Tad reikėtų peržiūrėti modelį, nes RMSEA kriterijus nėra geras. Modelio tinkamumo kriterijai ir jų tinkamumo ribos pristatomos daugumos autorių struktūrinių lygčių modeliavimo knygoje. Autorių pristatomos modelio tinkamumo kriterijų ribos gali skirtis. Čia pristatomos T. Raykov ir G. A. Marcoulides (2006) knygoje pateiktos tinkamumo kriterijų ribos. Žinant, kad modelis nėra labai tinkamas duomenims, reikėtų atsižvelgti į modifikacijos indeksus. Gali būti, kad modifikacijos indeksai (čia jau programa juos skaičiuoja ir esant praleistų reikšmių) pasiūlys pakeitimų.

Modelio rezultatai (angl. *model results*) – tai dalis, kurioje nurodomi visi modelio parametrai. Mums svarbiausi faktorių svoriai. Stulpelis „Įverčiai“ (angl. *estimate*) ir yra parametrų koeficientai, o p reikšmė (angl. *p-value*) yra reikšmingumo lygmuo (152 pav.). Skelbiami standartizuoti koeficientai, kurie yra pateikiami prie STDYX *Standardization* (žemiau nei modelio rezultatų dalis). Tad čia ir nagrinėjame

rezultatus ir randame visus modeliui reikiamus skaičius. Pirmiausia prie kiekvieno kintamojo p1–p4 pateikiami faktorių svoriai pradedant nuo PASIT BY. Visų 152 pav. pristatomų kintamųjų faktorių svoriai labai panašūs (svyruoja nuo 0,536 iki 0,663). Apačioje pateikiamos liekamosios paklaidos (angl. *R square*). Kaip minėta 5.2.3 skyriuje, liekamosios paklaidos parodo variacijos kiekį, kurio matavimų kintamasis nepaaiškina būdamas tam tikro latentinio kintamojo dalimi, tai tarsi rodo, kas lieka nepaaiškinta šiuo kintamuoju. Liekamosios paklaidos svarbios ir skelbiamos sudarant naują matavimo įrankį, testą ar klausimyną ir vertinant to įrankio struktūrą. Tada labai svarbu žinoti, ar atskiri klausimai tikrai geri, ar jie turi mažas paklaidas, tai yra tai, kas lieka nepaaiškinta tuo klausimu. Tačiau dažniausiai skelbiant rezultatus svarbiausi yra modelio tinkamumo kriterijai ir faktorių svoriai.

STDYX Standardization					
		<u>Estimate</u>	S. E.	Est./S. E.	<u>Two-Tailed P-Value</u>
PASIT	BY				
	P1	0.536	0.053	10.160	0.000
	P2	0.647	0.050	13.027	0.000
	P3	0.629	0.049	12.769	0.000
	P4	0.663	0.049	13.474	0.000
Intercepts					
	P1	4.465	0.182	24.529	0.000
	P2	5.081	0.207	24.570	0.000
	P3	4.721	0.192	24.625	0.000
	P4	5.187	0.210	24.702	0.000
Variances					
	PASIT	1.000	0.000	999.000	999.000
Residual Variances					
	P1	0.713	0.057	12.610	0.000
	P2	0.582	0.064	9.070	0.000
	P3	0.605	0.062	9.769	0.000
	P4	0.561	0.065	8.596	0.000
R-SQUARE					
Observed Variable		Estimate	S. E.	Est./S. E.	Two-Tailed P-Value
	P1	0.287	0.057	5.080	0.000
	P2	0.418	0.064	6.513	0.000
	P3	0.395	0.062	6.384	0.000
	P4	0.439	0.065	6.737	0.000

152 pav. Parametrų koeficientai, reikšmingumo lygmuo ir liekamosios paklaidos

Ar gali tikrinamas modelis būti geresnis? Rezultatų išvesties lango apačioje pateikiami modifikacijos indeksai (153 pav.). Pirmiausia reikėtų žiūrėti į didžiausią skaičių, pateiktą M. I. stulpelyje apačioje žodžio WITH. WITH rodo, kad modelyje pridėta naujų korelacijų. 153 pav. didžiausi skaičiai būtų 6,380 arba 6,379. Programa siūlo, kad jei pridėsime koreliacijas tarp p3 ir p1 arba p4 ir p2, tai chi kvadratas sumažės 6,380 arba 6,379 vieneto. Šios koreliacijos reiškia koreliacijas

tarp liekamųjų paklaidų, tarsi kas buvo nepaaiškinta viename kintamajame, tas susiję su nepaaiškinta kito kintamojo dalimi. Visada turime galvoti, ar galime logiškai pagrįsti pridėdamas koreliacijas (gali būti, kad tie kintamieji labai panašūs ir todėl koreliacijos – prasmingos).

MODEL MODIFICATION INDICES					
Minimum M.I. value for printing the modification index					4.000
		M.I.	E.P.C.	Std E.P.C.	StdYX E.P.C.
WITH Statements					
P3	WITH P1	6.380	-0.059	-0.059	-0.206
P3	WITH P2	5.341	0.059	0.059	0.249
P4	WITH P1	5.340	0.052	0.052	0.204
P4	WITH P2	6.379	-0.064	-0.064	-0.301

153 pav. Modifikacijos indeksai

5.2.19. Modelio, naudojantis „Mplus“ programa, modifikavimas

Jei norime patikrinti, ar modelis gali būti geresnis, galime sintaksės rinkmenoje pridėti koreliaciją tarp p1 ir p3. Šią koreliaciją pridėdame prie MODEL komandos (154 pav.).

```
MODEL: pasit BY p1 p2 p3 p4;
       P1 WITH p3;
```

```
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
          USEVARIABLES ARE p1 p2 p3 p4;
          MISSING ARE all blank;
ANALYSIS: TYPE = general missing;
MODEL: pasit by p1 p2 p3 p4;
       p1 WITH p3;
OUTPUT: SAMP; STAND; MOD(4); PAT; CINT;
```

154 pav. Modifikacijos indekso nuoroda pridėta nauja koreliacija sintaksės rinkmenoje

Sintaksės rinkmeną vėl išsaugome (kaip naują arba tą pačią) ir galime leisti programai vertinti mūsų modelį (spaudžiame mygtuką *run*).

5.2.20. Modelio, naudojantis „Mplus“ programa, modifikavimo rezultatai

Pirmoje duomenų išvesties lango dalyje visuomet rasime tą pačią informaciją, tai yra sintaksės rinkmeną, imties dydį, priklausomuosius, nepriklausomuosius kintamuosius, duomenų rinkmenos aprašymą. Nurodome, kiek turime tiriamųjų savo imtyje, kiek priklausomųjų, nepriklausomųjų ir latentinių kintamųjų, kokie matavimų priklausomųjų kintamųjų pavadinimai ir koks latentinio kintamojo pavadinimas. Po praleistų reikšmių profilių eina kovariacijos padengimas ir aprašomoji statistika: kintamųjų, naudotų modelyje, vidurkiai, koreliacijos ir kovariacijos tarp kintamųjų. Padarius pakeitimus sintaksės rinkmenoje pagal modifikacijos indeksus svarbiausi mums yra modelio tinkamumo kriterijai: chi kvadratas, p reikšmė, CFI, TLI ir RMSEA (155 pav.).

Chi-Square Test of Model Fit		
Value	1.325	
Degrees of Freedom	1	
P-Value	0.2498	
Chi-Square Test of Model Fit for the Baseline Model		
Value	234.103	
Degrees of Freedom	6	
P-Value	0.0000	
CFI/TLI		
CFI	0.999	
TLI	0.991	
RMSEA (Root Mean Square Error Of Approximation)		
Estimate	0.031	
90 Percent C.I.	0.000	0.154
Probability RMSEA <= .05	0.424	

155 pav. Modelio tinkamumo kriterijai modifikavus modelį

155 pav. pateikti tinkamumo kriterijai rodo, kad modelis, kai padarytas pataisymas, pagal modifikacijos indeksus tinka duomenims, nes TLI = 0,991 (TLI reikšmės > 0,95 rodo, kad modelis geras), CFI = 0,999 (CFI reikšmės > 0,95, vadinasi, modelis geras), RMSEA = 0,031 (RMSEA reikšmė mažiau negu 0,05, taigi modelis geras). Tad modelis tikrai geresnis, kai yra koreliacija tarp p1 ir p3. Žemiau prie *STDYX Standardization* (žemiau nei modelio rezultatų dalis) yra visi modeliui reikiami faktorių svoriai (156 pav.). Visų kintamųjų faktorių svoriai labai panašūs ir šiek tiek didesni nei buvusio modelio (kur nėra koreliacijos tarp p1 ir p3) faktorių svoriai. Žemiau faktorių svorių pateikiama ir koreliacija tarp p1 ir p3 ($r = -0,250$).

STDYX Standardization					
		Estimate	S. E.	Est./S. E.	Two-Tailed P-Value
PASIT	BY				
P1		0.605	0.058	10.370	0.000
P2		0.618	0.049	12.702	0.000
P3		0.692	0.055	12.577	0.000
P4		0.633	0.048	13.118	0.000
P1	WITH				
P3		-0.250	0.114	-2.185	0.029

156 pav. Kintamųjų parametrai modifikavus modelį

Šis modelis tikrai geras ir modifikacijos indeksai jau nėra pateikiami (157 pav.).

MODEL MODIFICATION INDICES					
M.I.	E.P.C.	Std E.P.C.	StdYX	E.P.C.	
Minimum M.I. value for printing the modification index 4.000					
No modification indices above the minimum value.					

157 pav. Modelio modifikacijos indeksai modifikavus modelį

Kurį modelį naudoti – pirmąjį be jokių liekamųjų paklaidų koreliacijos ar antrąjį? Tai priklauso nuo tyrėjo ir teorinių svarstymų bei sugebėjimo pagrįsti, ar pakeitimai, remiantis modifikacijos indeksais, tikrai yra tinkami. Taip pat gerai pasitelkti chi kvadrato skirtumo testą. Pirmojo modelio (be modifikacijos) chi kvadratas lygus 8,092 ir $df = 2$, o modelio su modifikacija (pridėjus koreliaciją tarp p1 ir p3) – $\chi^2 = 1,325$ ir $df = 1$. Tad $\Delta \chi^2 = 8,092 - 1,325 = 6,767$; $\Delta df = 2 - 1 = 1$. Turėdami šiuos skaičius, žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 1 laisvės laipsnį. Pagal lentelę, esant 1 laisvės laipsniui, chi kvadrato skirtumas turėtų būtų 3,841 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Mūsų gautas chi kvadrato skirtumas yra 6,767, tad modeliai statistiškai skiriasi ir turėtume rinktis tą, kuris jau būtų pataisytas pagal modifikacijos indeksų pasiūlymus, bet turime žinoti, kaip teoriškai pagrįsime padarytus pakeitimus.

5.2.21. Modelio, naudojantis „Mplus“ programa, papildymas

Jei norime papildyti savo turimą modelį, pridėti naujų kintamųjų ar ką nors pašalinti, viską galime daryti toje pačioje sintaksės rinkmenoje arba naujoje rinkmenoje rašyti iš naujo, jei norime tikrinti visai kitą modelį. Tarkime, prie turimų p1–p4 kintamųjų norime pridėti s1–s3 kintamuosius, kurie turėtų sudaryti kitą latentinį kintamąjį, kurį galime pavadinti „santykiai su draugais“ arba „draugystė“. Kadangi

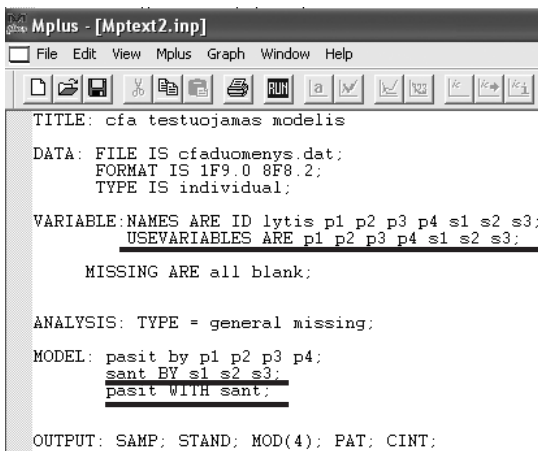
naujame modelyje paliekame p1–p4 kintamuosius, kurie sudaro latentinį faktorių, ir pridėdame kitus kintamuosius, galima papildyti turimą sintaksės rinkmeną ir ją naudoti. Svarbu, kad tie kintamieji būtų duomenų rinkmenoje (.dat). Jei jų nėra duomenų rinkmenoje, tai reiktų iš naujo susikurti duomenų rinkmeną, kurioje būtų visi naujam modeliui reikalingi kintamieji. Jei duomenų rinkmenoje jau buvo visi reikiami kintamieji, jos perdaryti iš naujo nereikia. Turime tik papildyti sintaksės rinkmeną. Papildymai daromi tik keliose vietose.

Prie subkomandos USEVARIABLES ARE pridėdame s1–s3 kintamuosius, nes čia nurodomi visi kintamieji, kurie bus naudojami modelyje. Nepamirština, kad kintamieji surašomi ta pačia tvarka, kokia jie buvo išdėstyti SPSS duomenų rinkmenoje. Visų rinkmenoje esamų kintamųjų vardai aprašomi prie NAMES ARE. Čia taip pat svarbu eiliškumas, koks ir buvo SPSS duomenų rinkmenoje. Pavyzdžiui: Modelyje nenaudosiu kintamojo ID ir lytis, kurie yra mano duomenų rinkmenoje

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
USEVARIABLES ARE p1 p2 p3 p4 s1 s2 s3;
```

Pakeitimus taip pat darome aprašydami modelį, prie komandos MODEL. Prieš tai vartojome vieną žodį BY, sudarydami latentinį kintamąjį, šioje analizėje vartosime ir žodį WITH, nurodantį koreliaciją tarp dviejų latentinių kintamųjų. Žodį BY vartosime ir antrą kartą, sudarydami antrą latentinį kintamąjį (santykiai su draugais).

```
MODEL: pasit BY p1 p2 p3 p4;
      sant BY s1 s2 s3;
      pasit WITH sant;
```



The screenshot shows the Mplus software interface with the following syntax file content:

```
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
           USEVARIABLES ARE p1 p2 p3 p4 s1 s2 s3;
MISSING ARE all blank;
ANALYSIS: TYPE = general missing;
MODEL: pasit by p1 p2 p3 p4;
      sant BY s1 s2 s3;
      pasit WITH sant;
```

158 pav. Sintaksės rinkmena, turinti du latentinius kintamuosius

Tokios komandos rodo, kad pasitikėjimo savimi latentinis kintamasis sudaromas iš keturių matavimo kintamųjų, o santykių su draugais kintamasis – iš trijų kintamųjų. Be to, yra koreliaciniai ryšiai tarp dviejų latentinių kintamųjų, jie tarpusavyje susiję. Daugiau pakeitimų sintaksės rinkmenoje nereikia daryti. Galutinė sintaksės rinkmena atrodo kaip ir pirmoji, tik papildyta keliomis eilutėmis (158 pav.).

Sintaksės rinkmena turi būti išsaugoma (geriausia tame pačiame aplanke, kaip ir duomenų rinkmena), prieš pradėdant modelio įvertinimą. Jei sintaksės rinkmenos neišsaugojome, programa pati prašys tai padaryti. Geriausia pataisytą sintaksės rinkmeną išsaugoti kaip naują, o ne tą pačią, nes jei norėsime palyginti modelius, geriau juos aprašyti skirtingose sintaksės rinkmenose. „Mplus“ programos sintaksės rinkmenos išsaugomos taip pat, kaip ir visos kitos. Meniu eilutėje pasirenkame „Išsaugoti rinkmeną“ (*File – Save as*), nurodome programai, kurioje vietoje išsaugoti, ir tą rinkmeną išsaugome. Tada jau galima leisti programai vertinti mūsų modelį (spaudžiame mygtuką *Run*).

5.2.22. Modelio, naudojantis „Mplus“ programa, papildymo rezultatai

Programai pradėjus apdoroti duomenis, ekrane pasirodo juoda lentelė ir atsida-
ro duomenų išvesties langas. Pirmoje duomenų išvesties lango dalyje visuomet rasi-
me tą pačią sintaksės rinkmeną, kurią patys surašėme – kaip ir buvo vertinant pirmą
modelį. Tada eina imties dydis, priklausomieji, nepriklausomieji kintamieji, duo-
menų rinkmenos aprašymas (159 pav.). Čia nurodoma, kiek tiriamųjų turime savo
imtyje – 331, kiek turime priklausomųjų kintamųjų – 7, kiek nepriklausomųjų – 0,
kiek latentinių – 2, kokie matavimų priklausomųjų kintamųjų pavadinimai – p1, p2,
p3, p4, s1, s2, s3, ir kokie latentinių kintamųjų pavadinimai – *pasit*, *sant*.

SUMMARY OF ANALYSIS						
Number of groups						1
Number of observations						331
Number of dependent variables						7
Number of independent variables						0
Number of continuous latent variables						2
Observed dependent variables						
Continuous						
P1	P2	P3	P4	S1	S2	
S3						
Continuous latent variables						
PASIT	SANT					

159 pav. Duomenų aprašymas turint du latentinius kintamuosius

Jei rašydami sintaksę prie OUTPUT komandos buvo pažymėję PAT, tai tuomet
ir rasime praleistų reikšmių išsklotines, profilius (160 pav.).

Šiame pavyzdyje yra jau 7 praleistų reikšmių profiliai. Pateikti duomenys rodo,
kad 301 tiriamasis turi reikšmes visuose kintamuosiuose, nes jie visi priklauso pir-

SUMMARY OF MISSING DATA PATTERNS							
MISSING DATA PATTERNS (x = not missing)							
	1	2	3	4	5	6	7
P1	x	x	x	x	x	x	x
P2	x	x	x	x	x	x	
P3	x	x	x	x	x		x
P4	x	x	x				x
S1	x	x		x		x	x
S2	x			x		x	x
S3	x	x		x		x	x
MISSING DATA PATTERN FREQUENCIES							
Pattern	Frequency	Pattern	Frequency	Pattern	Frequency		
1	301	4	3	7	4		
2	5	5	1				
3	16	6	1				

160 pav. Praleistų reikšmių profiliai turint modelyje du latentinius kintamuosius

nam profiliui. Net 16 tiriamųjų, kurie neturi s1–s3 kintamųjų reikšmių, priklauso trečiam profiliui. Profiliai svarbūs, jei norime turėti išsamius duomenis, tai yra manome, jog reikėtų, kad visi tiriamieji turėtų atsakymus į visus klausimus. Tuomet iš čia galime matyti, kiek neteiktume žmonių, kiek žmonių yra neatsakę į tam tikrus klausimus. Jei dirbsime su visais duomenimis, praleistų profilių reikės tik susipažinti su duomenimis. Kartais, skelbiant duomenis mokslinėse publikacijose, recenzantai paprašo plačiau pakomentuoti praleistas reikšmes ir kiek kokių reikšmių tiriamieji praleido. Po praleistų reikšmių profilių eina kovariacijos padengimas.

Toliau pateikiama aprašomoji statistika: kintamųjų, naudotų modelyje, vidurkiai, koreliacijos ir kovariacijos tarp kintamųjų ir modelio tinkamumo kriterijų: chi kvadratas, p reikšmė, CFI, TLI ir RMSEA. Tai ir parodo modelio tinkamumą esamiems duomenims (161 pav.).

TESTS OF MODEL FIT			
Chi-Square Test of Model Fit			
Value		17.177	
Degrees of Freedom		13	
P-Value		0.1913	
Chi-Square Test of Model Fit for the Baseline Model			
Value		535.113	
Degrees of Freedom		21	
P-Value		0.0000	
CFI/TLI			
CFI		0.992	
TLI		0.987	
RMSEA (Root Mean Square Error Of Approximation)			
Estimate		0.031	
90 Percent C.I.		0.000	0.067
Probability RMSEA <= .05		0.776	

161 pav. Modelio tinkamumo kriterijai turint du latentinius kintamuosius

161 pav. pateikti tinkamumo kriterijai rodo, kad modelis yra tinkamas duomenims (labai panašūs rezultatai buvo gauti vertinant šį modelį AMOS programa), nes TLI = 0,987 (TLI reikšmės > 0,95 rodo, kad modelis geras), CFI = 0,992 (CFI reikšmės > 0,95, vadinasi, modelis geras), RMSEA = 0,031 (RMSEA reikšmė mažiau negu 0,05, taigi modelis geras).

Standartizuoti koeficientai, kurie ir yra skelbiami, pateikiami prie STDYX *Standardization*. Pirmiausia pateikiami pasitikėjimo savimi latentinio kintamojo faktorių svoriai, prie kiekvieno kintamojo p1–p4, pradedant nuo PASIT BY (162 pav.). Tada pateikiami santykių su draugais latentinio kintamojo faktorių svoriai, prie kiekvieno kintamojo s1–s3, pradedant nuo SANT BY. Visų kintamųjų vieno latentinio kintamojo faktorių svoriai labai panašūs – pasitikėjimo savimi faktoriuje svyruoja nuo 0,542 iki 0,656, o santykių su draugais faktoriuje – nuo 0,695 iki 0,806. Koreliacija tarp latentinių kintamųjų pateikiama prie PASIT WITH SANT. Koreliacijos koeficientas yra 0,301 ($p < 0,001$). Apačioje pateikiamos liekamosios paklaidos. Skelbiant tokio modelio rezultatus svarbiausi yra modelio tinkamumo kriterijai, faktorių svoriai ir koreliacijos tarp latentinių kintamųjų koeficientas.

STDYX Standardization				
	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
PASIT BY				
P1	0.542	0.052	10.413	0.000
P2	0.655	0.049	13.469	0.000
P3	0.621	0.049	12.757	0.000
P4	0.656	0.048	13.585	0.000
SANT BY				
S1	0.736	0.038	19.348	0.000
S2	0.695	0.040	17.394	0.000
S3	0.806	0.036	22.168	0.000
PASIT WITH SANT				
	0.301	0.071	4.262	0.000
R-SQUARE				
Observed Variable	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
P1	0.294	0.056	5.207	0.000
P2	0.429	0.064	6.735	0.000
P3	0.386	0.060	6.379	0.000
P4	0.431	0.063	6.793	0.000
S1	0.542	0.056	9.674	0.000
S2	0.483	0.056	8.697	0.000
S3	0.649	0.059	11.084	0.000

162 pav. Standartizuoti koeficientai modelyje su dviem latentiniais kintamaisiais

Nors modelis tinkamas duomenims, gali būti pagerintas. Rezultatų išvesties lango apačioje pateikiami modifikacijos indeksai (163 pav.).

MODEL MODIFICATION INDICES					
Minimum M.I. value for printing the modification index					4.000
		M.I.	E.P.C.	Std E.P.C.	StdYX E.P.C.
WITH Statements					
P3	WITH P1	6.050	-0.056	-0.056	-0.195
P3	WITH P2	4.774	0.053	0.053	0.222
P4	WITH P1	4.713	0.048	0.048	0.185
P4	WITH P2	5.941	-0.058	-0.058	-0.273

163 pav. Modifikacijos indeksai modelyje su dviem latentiniais kintamaisiais

Ar pasinaudoti modifikacijos indeksų teikiama informacija ar ne, priklauso nuo tyrėjo. Pirmiausia reikėtų žiūrėti į didžiausią skaičių, pateiktą M. I. stulpelyje (163 pav.). Čia būtų 6,050. Programa siūlo, kad jei pridėsime koreliaciją tarp p3 ir p1 (vartojamas žodis WITH), tai chi kvadratas sumažės 6,050 vieneto. Ši koreliacija reiškia koreliaciją tarp liekamųjų paklaidų, tarsi tai, kas buvo nepaaiškinta viename kintamajame, susiję su nepaaiškinta kito kintamojo dalimi. Ar tai verta daryti, kai modelis tinka duomenims, priklauso nuo tyrėjo. Jei norime patikrinti, ar modelis gali būti geresnis, galime pridėti sintaksės rinkmenoje koreliaciją tarp p1 ir p3. Ją aprašome prie MODEL komandos (164 pav.).

```
MODEL: pasit BY p1 p2 p3 p4;
        p1 WITH p3;
```

The screenshot shows the Mplus software window titled 'Mplus - [Mptext2.inp]'. The menu bar includes File, Edit, View, Mplus, Graph, Window, and Help. The toolbar contains icons for file operations and running the model. The main text area displays the following content:

```
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
          USEVARIABLES ARE p1 p2 p3 p4 s1 s2 s3;
MISSING ARE all blank;
ANALYSIS: TYPE = general missing;
MODEL:  pasit by p1 p2 p3 p4;
        sant BY s1 s2 s3;
        pasit WITH sant;
        p1 WITH p3;
OUTPUT: SAMP; STAND; MOD(4); PAT: CINT;
```

164 pav. Modifikacijos indeksų pateikiamos koreliacijos aprašymas modelio su dviem latentiniais kintamaisiais sintaksės rinkmenoje

Sintaksės rinkmeną vėl išsaugome (kaip naują arba tą pačią) ir galime leisti programai vertinti mūsų modelį. Pirmoje duomenų išvesties lango dalyje visuomet rasime tą pačią informaciją, kuri buvo ankstesniuose modeliuose. Padarius pakeitimus sintaksės rinkmenoje pagal modifikacijos indeksus, mums svarbiausi modelio tinkamumo kriterijai: chi kvadratas, p reikšmė, CFI, TLI ir RMSEA (165 pav.).

TESTS OF MODEL FIT			
Chi-Square Test of Model Fit			
Value		10.753	
Degrees of Freedom		12	
P-Value		0.5502	
Chi-Square Test of Model Fit for the Baseline Model			
Value		535.113	
Degrees of Freedom		21	
P-Value		0.0000	
CFI/TLI			
CFI		1.000	
TLI		1.000	
RMSEA (Root Mean Square Error Of Approximation)			
Estimate		0.000	
90 Percent C.I.		0.000	0.051
Probability RMSEA <= .05		0.944	

165 pav. Modelio tinkamumo kriterijai pritaikius modifikaciją modelyje su dviem latentiniais kintamaisiais

Pateikti tinkamumo kriterijai rodo, kad modelis, kai padarytas pataisymas, pagal modifikacijos indeksus tinka duomenims, nes TLI = 1,000 (TLI reikšmės > 0,95 rodo, kad modelis geras), CFI = 1,000 (CFI reikšmės > 0,95, vadinasi, modelis geras), RMSEA = 0,000 (RMSEA reikšmė mažiau negu 0,05, taigi modelis geras). Tad modelis dar tinkamesnis duomenims padarius modifikaciją, tai yra koreliaciją tarp p1 ir p3. Žemiau prie *STDYX Standardization* (žemiau nei modelio rezultatų dalis) yra visi modeliui reikiami faktorių svoriai (166 pav.). Visų kintamųjų faktorių svoriai labai panašūs ir šiek tiek didesni nei buvusio modelio (kur nėra koreliacijos tarp p1 ir p3) faktorių svoriai, ypač pasitikėjimo savimi latentinio faktoriaus. Žemiau faktorių svorių taip pat pateikiama koreliacija tarp p1 ir p3 ($r = -0,230$).

STDYX Standardization					
		Estimate	S. E.	Est./S. E.	Two-Tailed P-Value
PASIT	BY				
P1		0.605	0.056	10.739	0.000
P2		0.628	0.048	13.163	0.000
P3		0.676	0.053	12.838	0.000
P4		0.636	0.046	13.716	0.000
SANT	BY				
S1		0.736	0.038	19.293	0.000
S2		0.694	0.040	17.350	0.000
S3		0.807	0.036	22.167	0.000
PASIT	WITH				
SANT		0.289	0.069	4.186	0.000
P1	WITH				
P3		-0.230	0.103	-2.225	0.026

166 pav. Faktorių svoriai ir koreliacijos pritaikius modifikaciją modelyje su dviem latentiniais kintamaisiais

Šis modelis tikrai geras ir modifikacijos indeksai jau nepateikiami (167 pav.).

MODEL MODIFICATION INDICES					
Minimum M.I. value for printing the modification index 4.000					
M. I.	E.P.C.	Std E.P.C.	StdYX	E.P.C.	
No modification indices above the minimum value.					

167 pav. Modifikacijos indeksai pritaikius modifikaciją modelyje su dviem latentiniais kintamaisiais

Įvertinome modelį su vienu ir dviem latentiniais kintamaisiais. Kuris iš jų geresnis? Ar naudoti modifikuotus, ar ne? Pats tyrėjas turi spręsti, ar naudoti modelius su modifikacijos indeksais ir jų rezultatus skelbti, ar ne. Abu variantai yra tinkami. O du vertinti modeliai (pirmasis, kur turėjome tik p1–p4 kintamuosius ir vieną latentinį kintamąjį be jokių modifikacijų, ir antrasis, kur pridėjome ir s1–s3 kintamuosius, kurie sudarė naują latentinį kintamąjį be jokių modifikacijų) statistiškai reikšmingai skiriasi? Pirmojo modelio chi kvadratas lygus 8,092 ir $df = 2$, o antrojo $\chi^2 = 17,177$ ir $df = 13$. Tai $\Delta \chi^2 = 17,177 - 8,092 = 9,085$; $\Delta df = 13 - 2 = 11$. Turėdami šiuos skaičius, žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 11 laisvės laipsnių. Pagal lentelę, esant 11 laisvės laipsnių, chi kvadrato skirtumas turėtų būtų 19,675 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra tik 9,085, tad modeliai statistiškai nesiskiria ir tuomet jau renkamės modelį (su vienu ar dviem latentiniais faktoriais be jokių modifikacijų), kuris geriau atspindi mūsų idėjas, turi geresnius tinkamumo kriterijus ar geriau gali būtų teoriškai pagrindžiamas.

Jei ir antrame modelyje darėme pakeitimus pagal modifikacijos indeksus, tai šį modelį geriau lyginti su pirmu modeliu, kuris jau buvo pakeistas pagal modifikacijos indeksus. Pirmojo modelio atsižvelgus į modifikacijos indeksus ir padarius pakeitimus (pridėjus koreliaciją tarp p1 ir p3) chi kvadratas lygus 1,325 ir $df = 1$, o antrojo $\chi^2 = 10,753$ ir $df = 12$. Tad $\Delta \chi^2 = 10,753 - 1,325 = 9,428$; $\Delta df = 12 - 1 = 11$. Vėl žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 11 laisvės laipsnių. Pagal lentelę, esant 11 laisvės laipsnių, chi kvadrato skirtumas turėtų būtų 19,675 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi ($p < 0,05$). Bet mūsų gautas chi kvadrato skirtumas yra tik 9,428, todėl abu modeliai (kuriuose buvo darytos modifikacijos) statistiškai nesiskiria ir tuomet jau renkamės modelį, kuris geriau atspindi mūsų idėjas, turi geresnius tinkamumo kriterijus ar geriau teoriškai pagrindžiamas.

5.2.23. Modelio, naudojantis „Mplus“ programa, lyginimas tarp grupių

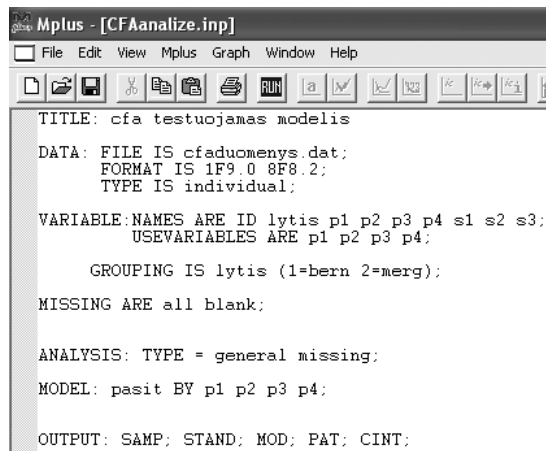
Gali būti, kad, analizuodami duomenis, norime turimą modelį palyginti tarp grupių, tai yra pažiūrėti, ar skirtingų tiriamųjų grupių faktorių svoriai vienodi. Tarkime, norime palyginti, ar modelis, kuriame p1–p4 kintamieji sudaro vieną latentinį faktorių pasitikėjimas savimi (pristatytas 5.2.17 ir 5.2.18 skyriuose), panašus berniukų ir mergaičių. Grupių skaičiaus apribojimo nėra, jų gali būti ir 2, ir 20. Tačiau svarbu, kad mūsų tyrimo klausimai ir modelio lyginimas tarp grupių būtų susiję. Lyginti tarp grupių turimą modelį galima naudojantis pirmine modelio sintakse, tik reikėtų pridėti vieną eilutę ir šiek tiek koreguoti modelio aprašymą. Po subkomandos MISSING ARE, kurios reikia norint aprašyti praleistas reikšmes (jei tokių buvo) jūsų rinkmenoje, prieš komandą ANALYSIS programai turime duoti žinoti, kad norėsime lyginti modelį tarp grupių ir pridėdame viena naują eilutę GROUPING IS. Tuomet nurodome grupių kintamąjį, tai gali būti lytis, klasė, amžius ar koks kitas kintamasis, kuris tiriamuosius grupuotų, tai dažniausiai kategoriniai kintamieji. O tuomet skliausteliuose nurodome, ką kiekviena kategorija reiškia. Tik čia nereikėtų lietuviškų raidžių. Neturėtume pamiršti kabliataškio eilutės gale.

Pavyzdžiui:

```
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;  
MISSING ARE all blank;  
GROUPING IS lytis (1=berniukai, 2=mergaites);  
ANALYSIS: TYPE = general;
```

Visos kitos sintaksės dalys išlieka nepakitusios. Toks sintaksės parašymas programai nurodo, kad palygintų patvirtinamosios faktorių analizės modelius tarp dviejų grupių ir kad abiejų grupių modeliai lygūs (168 pav.).

Sintaksės rinkmena turi būti išsaugoma (geriausia tame pačiame aplanke, kaip ir duomenų rinkmena). Tuomet jau galima leisti programai vertinti mūsų modelį (spaudžiame mygtuką *run*).



```
TITLE: cfa testuojamas modelis  
DATA: FILE IS cfaduomenys.dat;  
FORMAT IS 1F9.0 8F8.2;  
TYPE IS individual;  
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;  
USEVARIABLES ARE p1 p2 p3 p4;  
GROUPING IS lytis (1=bern 2=merg);  
MISSING ARE all blank;  
ANALYSIS: TYPE = general missing;  
MODEL: pasit BY p1 p2 p3 p4;  
OUTPUT: SAMP; STAND; MOD; PAT; CINT;
```

168 pav. Sintaksės rinkmena lyginant modelį tarp dviejų grupių

5.2.24. Modelio, naudojantis „Mplus“ programa, lyginimo tarp grupių rezultatai

Atsidarius duomenų išvesties langui, pirmoje jo dalyje visuomet rasime sintaksės rinkmeną, kurią patys surašėme. Toliau eina imties dydis, priklausomieji, nepriklausomieji kintamieji, duomenų rinkmenos aprašymas (169 pav.). Čia nurodoma, kiek grupių turime – 2, kiek berniukų ir mergaičių yra mūsų imtyje – 136 ir 195, kiek turime priklausomųjų kintamųjų – 4, kiek nepriklausomųjų – 0, kiek latentinių – 1, kokie matavimų priklausomųjų kintamųjų pavadinimai – p1, p2, p3, p4, koks latentinio kintamojo pavadinimas – *pasit* ir koks yra grupavimo kintamasis – *lytis*.

SUMMARY OF ANALYSIS				
Number of groups				2
Number of observations				
Group BERNIUKAI				136
Group MERGAITES				195
Number of dependent variables				4
Number of independent variables				0
Number of continuous latent variables				1
Observed dependent variables				
Continuous				
P1	P2	P3	P4	
Continuous latent variables				
PASIT				
Variables with special functions				
Grouping variable		LYTIS		

169 pav. Duomenų aprašymas lyginant modelį tarp dviejų grupių

Jei rašydami sintaksę prie OUTPUT komandos buvome pažymėję PAT, tai tuomet ir rasime praleistų reikšmių išsklotines, profilius. Čia jau jie pateikiami atskirai grupėms – šiame pavyzdyje atskirai berniukams ir mergaitėms (170 pav.).

SUMMARY OF MISSING DATA PATTERNS					
MISSING DATA PATTERNS FOR BERNIUKAI (x = not missing)					
	1	2	3		
P1	x	x	x		
P2	x	x			
P3	x	x	x		
P4	x		x		
MISSING DATA PATTERN FREQUENCIES FOR BERNIUKAI					
Pattern	Frequency	Pattern	Frequency	Pattern	Frequency
1	132	2	2	3	2
SUMMARY OF MISSING DATA PATTERNS					
MISSING DATA PATTERNS FOR BERNIUKAI (x = not missing)					
	1	2	3		
P1	x	x	x		
P2	x	x			
P3	x	x	x		
P4	x		x		
MISSING DATA PATTERN FREQUENCIES FOR BERNIUKAI					
Pattern	Frequency	Pattern	Frequency	Pattern	Frequency
1	132	2	2	3	2
MISSING DATA PATTERNS FOR MERGAITES (x = not missing)					
	1	2	3	4	
P1	x	x	x	x	
P2	x	x	x		
P3	x	x		x	
P4	x			x	
MISSING DATA PATTERN FREQUENCIES FOR MERGAITES					
Pattern	Frequency	Pattern	Frequency	Pattern	Frequency
1	190	3	1		
2	2	4	2		

170 pav. Praleistų reikšmių profiliai berniukams ir mergaitėms

170 pav. yra 3 berniukų ir 4 mergaičių praleistų reikšmių profiliai. Pateikti duomenys rodo, kad 132 berniukai ir 190 mergaičių turi reikšmes visuose kintamuosiuose, nes jie visi priklauso pirmam profiliui. Po praleistų reikšmių profilių eina kovariacijos padengimas, atskirai berniukų ir mergaičių imčiai. Tuomet yra aprašomoji statistika: kintamųjų, naudotų modelyje, vidurkiai, koreliacijos ir kovariacijos tarp kintamųjų (atskirai berniukų ir mergaičių) ir modelio tinkamumo kriterijai: chi kvadratas, p reikšmė, CFI, TLI ir RMSEA (171 pav.).

TESTS OF MODEL FIT		
Chi-Square Test of Model Fit		
Value	26.975	
Degrees of Freedom	10	
P-Value	0.0026	
Chi-Square Contributions From Each Group		
BERNIUKAI	15.384	
MERGAITES	11.591	
Chi-Square Test of Model Fit for the Baseline Model		
Value	233.313	
Degrees of Freedom	12	
P-Value	0.0000	
CFI/TLI		
CFI	0.923	
TLI	0.908	
RMSEA (Root Mean Square Error Of Approximation)		
Estimate	0.101	
90 Percent C.I.	0.056	0.148

171 pav. Modelio tinkamumo kriterijai lyginant modelį tarp atskirų grupių

Lyginant modelį tarp atskirų grupių, atsiranda naujų tinkamumo kriterijų – atskirų grupių chi kvadratas. Lyginant modelį tarp grupių chi kvadratas yra svarbus, todėl jį reikėtų išsirašyti, nes jis bus lyginamas su vėliau gautais chi kvadratais. Čia jis yra 26,975 (df = 10). Buvo minėta, jog pateikta sintaksė nurodo programai, kad modeliai nesiskiria tarp grupių. Kad taip yra, galime matyti prie rezultatų, pateiktų prie MODEL (172 pav.). Faktorių svoriai (kurie čia yra ne standartizuoti dydžiai) kiekvieno berniukų ir mergaičių kintamojo yra vienodi (pvz., p4 faktorių svoris tiek berniukų, tiek mergaičių grupėje prilyginamas 1,128). Kol kas tikriname modelį, kuris abiejų grupių yra toks pat.

MODEL RESULTS					
		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
Group BERN					
PASIT	BY				
P1		1.000	0.000	999.000	999.000
P2		1.069	0.151	7.086	0.000
P3		1.128	0.170	6.646	0.000
P4		1.128	0.148	7.607	0.000
Group MERG					
PASIT	BY				
P1		1.000	0.000	999.000	999.000
P2		1.069	0.151	7.086	0.000
P3		1.128	0.170	6.646	0.000
P4		1.128	0.148	7.607	0.000

172 pav. Modelio, lyginamo tarp grupių, nestandardizuoti indeksai, kurie ir parodo faktorių svorių lygybę tarp grupių

Standartizuoti koeficientai, kurie ir yra skelbiami, pateikiami prie *STDYX Standardization* atskirai kiekvienai grupei (173 pav.). Apačioje pateikiamos liekamosios paklaidos taip pat atskirai kiekvienai grupei.

Group BERNIUKAI					
PASIT	BY				
P1		0.585	0.063	9.357	0.000
P2		0.697	0.059	11.869	0.000
P3		0.642	0.053	12.067	0.000
P4		0.718	0.060	11.882	0.000
Group MERGAITES					
PASIT	BY				
P1		0.513	0.055	9.330	0.000
P2		0.589	0.055	10.648	0.000
P3		0.574	0.064	8.986	0.000
P4		0.604	0.053	11.306	0.000
R-SQUARE					
Group BERNIUKAI					
Observed Variable	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value	
P1	0.342	0.073	4.678	0.000	
P2	0.485	0.082	5.935	0.000	
P3	0.412	0.068	6.034	0.000	
P4	0.515	0.087	5.941	0.000	
Group MERGAITES					
Observed Variable	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value	
P1	0.263	0.056	4.665	0.000	
P2	0.347	0.065	5.324	0.000	
P3	0.330	0.073	4.493	0.000	
P4	0.364	0.064	5.653	0.000	

173 pav. Standartizuoti indeksai modelyje, kuriame lyginami dviejų grupių faktorių svoriai

Duomenys rodo, kad berniukų ir mergaičių faktorių svoriai panašūs, tačiau yra ir kai kurių skirtumų. Kol kas nežinome, ar berniukų ir mergaičių faktorių svoriai statistiškai skiriasi. Norėdami tai išsiaiškinti, turime kiekvieną berniukų ir mergaičių faktorių svorį lyginti atskirai, programai nurodę, kad grupių jis bus skirtingas. Tam atsiras nauja eilutė sintaksės rinkmenoje. Pradėsime nuo p1 kintamojo faktoriaus svorio. Visada gerai programai nurodyti, kad skiriasi tik vienas faktoriaus svoris vienu metu ir taip tikrinti visus faktorių svorius po vieną. Prie MODEL komandos atsiranda nauja eilutė, kuri taip pat vadinasi MODEL.

Pavyzdžiui:

MODEL: pasit BY p1 p2 p3 p4;

MODEL bern: pasit BY p1;

Pirmoji eilutė (pasit BY p1 p2 p3 p4) pasako, kad visi grupių faktorių svoriai vienodi. Nauja eilutė rodo, kad berniukų (galima vietoje berniukų nurodyti mergaičių) modelyje pirmas faktoriaus svoris (pasit BY p1) skiriasi nuo kitos grupės pirmo faktoriaus svorio (174 pav.).

```

Mplus - [CFAanalyze.inp]
File Edit View Mplus Graph Window Help
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
          USEVARIABLES ARE p1 p2 p3 p4;
          GROUPING IS lytis (1=bern 2=merg);
MISSING ARE all blank;
ANALYSIS: TYPE = general missing;
MODEL: pasit BY p1 p2 p3 p4;
MODEL bern: pasit BY p1;
OUTPUT: SAMP; STAND; MOD; PAT; CINT;

```

174 pav. Sintaksės rinkmena lyginant vieną skirtingų grupių faktoriaus svorį

Sintaksės rinkmena, padarius pakeitimus, turi būti išsaugoma. Tada jau galima leisti programai vertinti mūsų modelį. Atsidarius duomenų išvesties langui, pirmoje jo dalyje rasime tą pačią informaciją kaip ir ankstesniuose duomenų išvesties languose. Kad pirmas faktoriaus svoris šiame modelyje skiriasi tarp grupių, rodo ir jo rezultatai (175 pav.). Pirmasis faktorių svoris skiriasi, o kiti grupių yra vienodi.

		Estimate	S. E.	Est./S. E.	Two-Tailed P-Value
Group BERN					
PASIT	BY				
<u>P1</u>		<u>0.918</u>	0.222	4.133	0.000
P2		1.020	0.195	5.240	0.000
P3		1.073	0.219	4.899	0.000
P4		1.078	0.195	5.522	0.000
Group MERG					
PASIT	BY				
<u>P1</u>		<u>1.000</u>	0.000	999.000	999.000
P2		1.020	0.195	5.240	0.000
P3		1.073	0.219	4.899	0.000
P4		1.078	0.195	5.522	0.000

175 pav. Dviejų grupių vieno faktoriaus skirtingumas

Svarbiausias mums yra modelio tinkamumo kriterijus: chi kvadratas ir laisvės laipsniai (df) (176 pav.).

TESTS OF MODEL FIT		
Chi-Square Test of Model Fit		
Value		26.850
Degrees of Freedom		9
P-Value		0.0015

176 pav. Modelio chi kvadratas

Lyginant modelį tarp grupių, kai yra nurodoma, kad vienas faktorių svoris skiriasi tarp grupių, svarbus chi kvadratas, kurį reikėtų išsirašyti. Šis chi kvadratas bus lyginamas su prieš tai gautu chi kvadratu, kai tik lyginome modelį tarp grupių ir aptikome, kad modeliai nėra lygūs. Čia jis yra 26,850 (df = 9). Kuris modelis geresnis: ar kai visi faktorių svoriai lygūs tarp grupių (pirmas modelis), ar kai skiriasi tik pirmas faktorių svoris tarp grupių (antras modelis)? Tai gali parodyti chi kvadrato skirtumas tarp modelių. Pirmo modelio chi kvadratas lygus 26,975 ir df = 10, o antrojo $\chi^2 = 26,850$ ir df = 9. Tai $\Delta \chi^2 = 26,975 - 26,850 = 0,125$; $\Delta df = 10 - 9 = 1$. Vėl žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų 1 laisvės laipsnį. Pagal lentelę, esant 1 laisvės laipsniui, chi kvadrato skirtumas turėtų būtų 3,841 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra tik 0,125, vadinasi, pirmasis faktorius (kintamojo p1) svoris abiejų grupių nesiskiria. Tuomet turime patikrinti ir kitus faktorių svorius.

Galime palyginti p2 kintamojo faktoriaus svorius tarp grupių (177 pav.).

Sintaksės rinkmena turi būti išsaugoma, padarius šiuos pakeitimus. Kad antras faktoriaus svoris šiame modelyje skiriasi tarp grupių, rodo ir jo rezultatai (178 pav.). Antrasis faktoriaus svoris skiriasi, o kiti grupių yra vienodi.

```

Mplus - [CFAanalyze.inp]
File Edit View Mplus Graph Window Help
[Icons]
TITLE: cfa testuojamas modelis
DATA: FILE IS cfaduomenys.dat;
      FORMAT IS 1F9.0 8F8.2;
      TYPE IS individual;
VARIABLE: NAMES ARE ID lytis p1 p2 p3 p4 s1 s2 s3;
           USEVARIABLES ARE p1 p2 p3 p4;
           GROUPING IS lytis (1=bern 2=merg);
MISSING ARE all blank;
ANALYSIS: TYPE = general missing;
MODEL: pasit BY p1 p2 p3 p4;
MODEL bern: pasit BY p2;
OUTPUT: SAMP; STAND; MOD; PAT; CINT;
  
```

177 pav. Antrojo faktoriaus svorio lyginimas tarp dviejų grupių

MODEL RESULTS					
		Estimate	S. E.	Est./S. E.	Two-Tailed P-Value
Group BERN					
PASIT	EY				
P1		1.000	0.000	999.000	999.000
P2		1.194	0.205	5.810	0.000
P3		1.138	0.172	6.627	0.000
P4		1.119	0.148	7.540	0.000
Group MERG					
PASIT	EY				
P1		1.000	0.000	999.000	999.000
P2		0.949	0.176	5.382	0.000
P3		1.138	0.172	6.627	0.000
P4		1.119	0.148	7.540	0.000

178 pav. Antrojo faktoriaus svorio skirtingumas tarp grupių

Svarbiausias mums yra modelio tinkamumo kriterijus: chi kvadratas ir laisvės laipsniai (df) (179 pav.).

Chi-Square Test of Model Fit	
Value	25.818
Degrees of Freedom	9
P-Value	0.0022

179 pav. Modelio tinkamumas lyginant antrąjį faktoriaus svorį

Ir vėl lyginame pirmą modelį, kur visi faktorių svoriai lygūs tarp grupių, su šiuo modeliu ir skaičiuojame chi kvadrato skirtumą. Pirmo modelio chi kvadratas lygus 26,975 ir $df = 10$, o antrojo $\chi^2 = 25,818$ ir $df = 9$. Tai $\Delta \chi^2 = 26,975 - 25,818 = 1,157$; $\Delta df = 10 - 9 = 1$. Vėl žiūrime į chi kvadrato lentelę, surandame, kokio dydžio turi būti chi kvadrato skirtumas, kuris atitiktų laisvės laipsnį. Pagal lentelę, esant 1 laisvės laipsniui, chi kvadrato skirtumas turėtų būtų 3,841 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi. Mūsų gautas chi kvadrato skirtumas yra tik 1,157, vadinasi, pirmasis faktoriaus (kintamojo p2) svoris nesiskiria tarp abiejų grupių. Tuomet turime patikrinti ir kitus likusius faktorių svorius – kintamųjų p3 ir p4 tarp grupių, kad galėtume visiškai įvertinti modelį ir nustatyti, ar bent kuris faktorių svoris skiriasi tarp grupių.

5.2.25. Galimas patvirtinamosios faktorių analizės aprašymas

Labai dažnai pristatant struktūriniu modeliavimu paremtas analizes pateikiamos modelių diagramos ir aprašoma, konkrečiai kokie kintamieji ką sudaro. Visi keliai (rodyklės) ar latentiniai kintamieji pirmiausia turi turėti teorinį pagrindą. Kai

pateikiami paprastesni modeliai arba modeliai, kurių matavimų kintamųjų skaičius nedidelis, labai dažnai pristatomi ir koreliacijos koeficientai tarp modelyje naudotų kintamųjų (dažniausiai pateikiama lentelė). Visuomet parašoma, kokia programa analizė yra atlikta. Gauti rezultatai (faktorių svoriai, jei tai patvirtinamoji faktorių analizė) gali būti pateikiami diagramoje ar lentelėje. Būtinai pristatomi modelio tinkamumo koeficientai; dažniausiai pristatomi chi kvadratas, p reikšmė, laisvės laipsniai, TLI, CFI, RMSEA, gali būti ir keletas kitų. Jei vertiname kelis modelius ir juos lyginame tarpusavyje, modelių tinkamumo koeficientai gali būti pateikiami lentelėse ir būtinai pristatomi chi kvadrato skirtumai. Jei lyginamos grupės, tai pristatomi kiekvienos jų rezultatai. Jei modelis modifikuojamas atsižvelgiant į modifikacijos indeksus, tai svarbu teoriškai bandyti pagrįsti atliekamas modifikacijas, aiškiai pristatyti, kas buvo daroma ir keičiama. Yra nemažai medžiagos, kaip pristatyti naudojant struktūrinių lygčių modeliavimą gautus rezultatus, tad visada galima pasižiūrėti, kaip rezultatus pristato kiti tyrėjai (pvz., Hoyle and Panter, 1995).

Prie duomenų apdorojimo dalies galima pateikti: „Norėdami įvertinti, ar 20 (pavadinimas) skalės klausimų gali sudaryti du atskirus faktorius, naudojome struktūrinių lygčių modeliavimą „Mplus“ 6.0 programiniu paketu (Muthén L. K. and Muthén B. O., 2006). Testavome patvirtinamosios faktorių analizės modelį (konceptinis testuojamas modelis yra pavaizduotas X pav.). Šiame modelyje kintamieji sudaro du faktorius, kurių kiekvienas atskirai vertina skirtingus aspektus. Kintamieji (nurodoma, kurie) patenka į pirmą (pateikiamas pavadinimas) faktorių, o kintamieji (nurodoma, kurie) patenka į antrą (pateikiamas pavadinimas) faktorių. Šie faktoriai tarpusavyje susiję. Patvirtinamosios faktorių analizės modelis buvo įvertintas trimis tinkamumo kriterijais: CFI (palyginimo indeksas; Bentler, 1990); RMSEA (aproksimacijos liekanos kvadrato šaknies paklaida; Browne and Cudeck, 1993) ir TLI (Takerio ir Liuiso indeksas; Tucker and Lewis, 1973). CFI ir TLI indeksų reikšmės, didesnės kaip 0,90, rodo adekvatų modelio ir duomenų atitikimą (Bentler and Bonnett, 1980); reikšmės, didesnės nei 0,95, rodo gerą atitikimą (Hu and Bentler, 1998). RMSEA reikšmės, mažesnės kaip 0,08, reprezentuoja pakankamą aproksimacijos liekanos kvadrato šaknies paklaidą; reikšmės, mažesnės nei 0,05, rodo gerą modelio tikimą duomenims (Browne and Cudeck, 1993).“

Prie rezultatų galima pateikti: „Norėdami įvertinti, ar (pavadinimas) skalės kintamieji sudaro du atskirus faktorius, kaip ir nurodyta autorių, testavome modelį, pristatytą X pav. Modelio tinkamumo rodikliai patvirtina, kad modelis pakankamai gerai atitinka duomenis, nes TLI = 1,000 (TLI reikšmės > 0,95 rodo, kad modelis geras), CFI = 1,000 (CFI reikšmės > 0,95 vadinasi, modelis geras), RMSEA = 0,0001

(RMSEA reikšmė mažiau negu 0,05, taigi modelis geras). Faktorių svoriai pateikti x pav. Rezultatai rodo, kad kintamieji (įvardyti) patenka į pirmą (pavadinimas) faktorių, o kintamieji (nurodomi) patenka į antrą (pavadinimas) faktorių, tad galimi du faktoriai, kurie atspindi pateiktus kintamuosius. Koreliacijos koeficientas tarp šių faktorių yra $r = 0,453$ ($p < 0,001$). Tai rodo, kad abu faktoriai yra susiję, nors pristato skirtingus aspektus.“

Jei vertinate kelis modelius ir juos lyginate, prie rezultatų galima rašyti: „Šiame darbe buvo vertinti du modeliai – vienas, kur visi 20 kintamųjų sudaro vieną faktorių, ir antras, kur šie kintamieji sudaro du faktorius. Modelio tinkamumo rodikliai leidžia tvirtinti, kad dviejų faktorių modelis tinkamesnis duomenims, palyginti su vieno faktoriaus modeliu. Modelių tinkamumo kriterijai pristatyti X lentelėje. Faktorių svoriai abiem modeliams atskirai pateikti 2 ir 3 pav. Ar modeliai statistiškai skiriasi, parodo chi kvadrato skirtumas. Pirmojo modelio chi kvadratas lygus 8,092 ir $df = 2$, o antrojo $\chi^2 = 17,177$ ir $df = 13$. Tai $\Delta \chi^2 = 17,177 - 8,092 = 9,085$; $\Delta df = 13 - 2 = 11$. Pagal chi kvadrato lentelę, esant 11 laisvės laipsnių, chi kvadrato skirtumas turėtų būtų 19,675 ir daugiau, kad modeliai būtų statistiškai reikšmingai skirtingi, kai reikšmingumo lygmuo 0,05. Bet mūsų gautas chi kvadrato skirtumas yra tik 9,085, tad modeliai statistiškai nesiskiria. Vadinas, ir vieno, ir dviejų faktorių modelis tinka duomenims. Šiame darbe tolesnei analizei pasirinkome dviejų faktorių modelį ir sudarysime iš 20 klausimų dvi skales, kurios atspindi skirtingus aspektus, nes skalės autoriai taip pat rinkosi dviejų faktorių modelį.“

Galima viską pateikti ir prie rezultatų: „Patvirtinamoji faktorių analizė buvo atlikta naudojant AMOS19 programą. Patvirtinamosios faktorių analizės modelis buvo įvertintas trimis tinkamumo kriterijais: CFI (palyginimo indeksas; Bentler, 1990); RMSEA (aproksimacijos liekanos kvadrato šaknies paklaida; Browne and Cudeck, 1993) ir TLI (Takerio ir Liuiso indeksas; Tucker and Lewis, 1973). CFI ir TLI indeksų reikšmės, didesnės nei 0,90, rodo, kad modelis adekvačiai atitinka duomenis (Bentler and Bonett, 1980); reikšmės, didesnės nei 0,95, liudija apie gerą atitikimą (Hu and Bentler, 1998). RMSEA reikšmės, mažesnės nei 0,08, reprezentuoja pakankamą aproksimacijos liekanos kvadrato šaknies paklaidą; reikšmės, mažesnės kaip 0,05, gerą modelio tikimą duomenims (Browne & Cudeck, 1993). Modelio tinkamumo kriterijai patvirtino vieno faktoriaus skalės struktūrą ($\chi^2 = 17,177$, $df = 13$, $p > 0,05$; CFI = 0,99, TLI = 0,98, RMSEA = 0,03).“

Jei patvirtinamoji faktorių analizė yra mūsų tyrimo tikslas, tai šios faktorių analizės duomenys, dažnai ne vieno modelio, pateikiami „Rezultatų“ dalyje ir ji jau yra išsamesnė, nes turėtų būti nagrinėjami net ir smulkiausi niuansai. Daugiau apra-

šymo pavyzdžių iš psichologijos srities galima rasti įvairiuose moksliniuose žurnaluose, kur skelbiami moksliniai darbai. Daugiausia darbų, pristatančių struktūrinį modeliavimą, galima rasti anglų kalba leidžiamuose įvairių sričių psichologijos žurnaluose. Jau nemažai psichologijos mokslo darbų, kuriuose pristatomas struktūrinių lygčių modeliavimas, galima rasti ir mokslo žurnaluose lietuvių kalba.

5.2.26. Užduotis

Yra žinoma, kad naudojimosi internetu kintamieji sudaro vieną faktorių. Ar galite tai patvirtinti? Atlikite analizę AMOS ir „Mplus“ programomis. Pagalvokite, kaip modelius būtų galima pakeisti, atsižvelgiant į jų modifikavimo indeksus.

Literatūra

- Akaike, H. (1987). Factor Analysis and AIC. *Psychometrika*, 52, 317–332.
- Aiken, L. R. (2002). *Psychological testing and assessment* (11th ed.). Boston: Allyn and Bacon.
- Arbuckle, J. L. (2005). *Amos 6.0 User's Guide*. Chicago, IL: SPSS Inc.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107, 238–246.
- Bentler, P. M. and Bonnett, D. G. (1980). Significance tests and goodness-of-fit in the analysis of covariance structures. *Psychological Bulletin*, 88, 588–606.
- Bollen, K. A. (1989). *Structural Equations with Latent Variables*. New York: John Wiley and Sons, Inc.
- Box, G. E. P. (1976). Science and Statistics. *Journal of the American Statistical Association*, 71, 791–799.
- Brace, N., Kemp, R., and Snelgar, R. (2006). *SPSS for Psychologists: A Guide to Data Analysis using SPSS for Windows* (3rd ed.). Mahwah, New Jersey Lawrence Erlbaum Associates, Inc., Publishers.
- Browne, M. W. and Cudeck, R. (1993). Alternative ways of assessing model fit. In K. A. Bollen, and J. S. Long (Eds.), *Testing structural equation models* (pp. 136–162). London: Sage.
- Carmines, E. G. and Zeller, R. A. (1979). *Reliability and Validity Assessment*. Newbury Park, CA: Sage Publications.
- Čekanavičius, V. ir Murauskas, G. (2002). *Statistika ir jos taikymai II*. Vilnius: TEV.
- Čekanavičius, V. ir Murauskas, G. (2009). *Statistika ir jos taikymai III*. Vilnius: TEV.
- DiStefano, Ch., Zhu, M., and Mindrila, D. (2009). Understanding and using factor scores: Considerations for the applied researcher. *Practical Assessment, Research & Evaluation*, 14, 1–11.
- Hammond, S. (2000). Using psychometric tests. In G. M. Breakwell, S. Hammond, and C. Fifeshaw (Eds.), *Research methods in psychology* (2nd ed.). London: Sage.
- Hoyle, R. H. and Panter, A. T. (1995). *Writing about structural equation models*. In R. H. Hoyle (Ed.), *Structural equation modeling: Concepts, issues, and applications*. Thousand Oaks, CA: Sage Publications.
- Howell, D. C. (1997). *Statistical methods for psychology* (4th ed.). Belmont CA: Duxbury Press.
- Hu, L. and Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6 (1), 1–55.

- Hu, L. and Bentler, P. M. (1998). Fit indices in covariance structure modeling: Sensitivity to underparameterized model misspecification. *Psychological Bulletin*, 3, 424–453.
- Jöreskog, K. G. and Sörbom, D. (2004). *LISREL 8.72*. Chicago: Scientific Software International.
- Kaplan, R. M. and Saccuzzo, D. P. (2001). *Psychological Testing: Principle, Applications and Issues (5th Edition)*. Belmont, CA: Wadsworth.
- Kelloway, E. K. (1998). *Using LISREL for structural equation modeling: A researcher's guide*. Thousand Oaks, Ca: Sage Publications, Inc.
- Kline, P. (1994). *An easy guide to factor analysis*. London: Routledge.
- Kline, R. B. (2005). *Principles and Practice of Structural Equation Modeling (2nd ed.)*. New York: The Guilford Press.
- Landis, J. R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159–174.
- Meidus, L. (2004). Sporto psichologijos tyrimų metodai (metodinė priemonė). Vilnius: Vilniaus pedagoginis universitetas.
- Muthén, L. K. and Muthén, B. O. (2006). *Mplus users guide*. Los Angeles, CA: Muthén and Muthén.
- Nunnally, J. C. (1978). *Psychometric theory (2nd ed.)*. New York: McGraw-Hill.
- Pallant, J. (2003). *SPSS Survival Manual: A step by step to data analysis using SPSS for Windows (Version 10 and 11) (3rd ed.)*. Philadelphia: St Edmundsbury Press Ltd.
- Raykov, T. and Marcoulides, G. A. (2006). *A first course in structural equation modeling (2nd ed.)*. Lawrence Erlbaum Associates, Inc. Publishers.
- Raubenheimer, J. E. (2004). An item selection procedure to maximize scale reliability and validity. *South African Journal of Industrial Psychology*, 30, 59–64.
- Shapiro, A. and Browne, M. W. (1987). Analysis of covariance structures under elliptical distributions. *Journal of the American Statistical Association*, 82, 1092–1097.
- Shrout, P. E. and Fleiss, J. L. (1979) Intraclass Correlations: Uses in Assessing Rater Reliability. *Psychological Bulletin*, 2, 420–428.
- Steiger, J. H., and Lind, J. M. (1980). Statistically based tests for the number of common factors. Paper presented at the annual meeting of the Psychometric Society. Iowa City, 1980.
- Tabachnick, B. G. and Fidell, L. S. (1996). *Using multivariate statistics (3rd ed.)*. New York: Harper Collins.
- Tabachnick, B. G. and Fidell, L. S. (2006). *Using Multivariate Statistics (5th ed.)*. Boston: Allyn and Bacon.
- Tucker, L. R. and Lewis, C. (1973). The reliability coefficients for maximum likelihood factor analysis. *Psychometrika*, 3, 1–10.

Pakalniškienė, Vilmantė

Pa92 Tyrimo ir įvertinimo priemonių patikimumo ir validumo nustatymas : metodinė priemonė. – Vilnius: Vilniaus universitetas, Vilniaus universiteto leidykla, 2012. – 144 p.

ISBN 978-609-459-096-2

Šioje metodinėje priemonėje aprašomas tyrimo ir įvertinimo priemonių patikimumo ir validumo nustatymas ir statistinis įvertinimas (Cronbacho alfa, tiriamoji ir patvirtinamoji faktorių analizė ir kt.). Suprantama, čia nėra aprašyti visi galimi patikimumo ir validumo įvertinimo metodai, jų gerokai daugiau. Pristatomi metodai ir toks statistinis įvertinimas naudojami dažniausiai. Ši priemonė skirta visiems, kurie nori įvertinti tyrimo metu naudojamų priemonių patikimumą ir validumą.

UDK 001.891

VILMANTĖ PAKALNIŠKIENĖ
TYRIMO IR ĮVERTINIMO
PRIEMONIŲ PATIKIMUMO
IR VALIDUMO NUSTATYMAS

Viršelio dailininkė Audronė Uzielaitė
Kalbos redaktorė Gražina Indrišiūnienė
Maketuotoja Vida Vaidakavičienė

Tiražas 300 egz. 8,8 aut. l. 9 sp. l.

Išleido Vilniaus universitetas, Vilniaus universiteto leidykla
Universiteto g. 3, LT-01315 Vilnius

Spausdino UAB „Baltijos kopija“
Kareivių g. 13B, LT-09109 Vilnius