**Análise do impacto de perturbações
sobre medidas de qualidade de ajuste
para modelos de equações estruturais**

Renata Trevisan Brunelli

DISSERTAÇÃO APRESENTADA
AO
INSTITUTO DE MATEMÁTICA E ESTATÍSTICA
DA
UNIVERSIDADE DE SÃO PAULO
PARA
OBTENÇÃO DO TÍTULO
DE
MESTRE EM CIÊNCIAS

Programa: Estatística.

Orientadora: Profa. Dra. Lúcia Pereira Barroso

São Paulo, Maio de 2012

Análise do impacto de perturbações sobre medidas de qualidade de ajuste para modelos de equações estruturais

Esta versão da dissertação/tese contém as correções e alterações sugeridas pela Comissão Julgadora durante a defesa da versão original do trabalho, realizada em 11/05/2012. Uma cópia da versão original está disponível no Instituto de Matemática e Estatística da Universidade de São Paulo.

Comissão Julgadora:

- Prof^a. Dr^a. Lúcia Pereira Barroso (orientadora) - IME-USP
- Prof^a. Dr^a. Júlia Maria Pavan Soler - IME-USP
- Prof. Dr. Marcelo Ângelo Cirillo - UFLA

*Ao meu avô Zé Dodge,
que me encorajava com
todo o seu orgulho.*

Agradecimentos

No momento da conclusão de uma importante etapa da minha vida, gostaria de realizar os seguintes agradecimentos:

À minha orientadora Lúcia, por todo o seu apoio e compreensão.

À minha família, por se orgulhar de mim e me encher de amor, apoio, risadas e comidas gostosas.

Aos meus amigos Rafael e Fabiana, que me acompanharam nesse processo e, com isso, fizeram dele mais leve.

Ao Ivo, por ficar ao meu lado.

Aos meus amigos Ingrid, Luis Gabriel, Lucas e Hugo, por me ajudarem a ver qual era o caminho óbvio a ser seguido.

Aos meus professores e também aos meus chefes e parceiros de trabalho, por serem compreensivos com a jornada dupla que eu escolhi seguir e por viabilizarem-na.

E, por fim, a Deus, por me dar forças, como eu lhe pedi inúmeras vezes que fizesse.

Resumo

Análise do impacto de perturbações sobre medidas de qualidade de ajuste para modelos de equações estruturais

A Modelagem de Equações Estruturais (SEM, do inglês Structural Equation Modeling) é uma metodologia multivariada que permite estudar relações de causa/efeito e correlação entre um conjunto de variáveis (podendo ser elas observadas ou latentes), simultaneamente. A técnica vem se difundindo cada vez mais nos últimos anos, em diferentes áreas do conhecimento. Uma de suas principais aplicações é na confirmação de modelos teóricos propostos pelo pesquisador (Análise Fatorial Confirmatória). Existem diversas medidas sugeridas pela literatura que servem para avaliar o quão bom está o ajuste de um modelo de SEM. Entretanto, é escassa a quantidade de trabalhos na literatura que listem relações entre os valores de diferentes medidas com possíveis problemas na amostra e na especificação do modelo, isto é, informações a respeito de que possíveis problemas desta natureza impactam quais medidas (e quais não), e de que maneira. Tal informação é importante porque permite entender os motivos pelos quais um modelo pode estar sendo considerado mal-ajustado. O objetivo deste trabalho é investigar como diferentes perturbações na amostragem, especificação e estimação de um modelo de SEM podem impactar as medidas de qualidade de ajuste; e, além disso, entender se o tamanho da amostra influencia esta resposta. Simultaneamente, também se avalia como tais perturbações afetam as estimativas, dado que há casos de perturbações em que os parâmetros continuam sendo bem ajustados, mesmo com algumas medidas indicando um mau ajuste; ao mesmo tempo, há ocasiões em que se indica um bom ajuste, enquanto que os parâmetros são estimados de forma distorcida. Tais investigações serão realizadas a partir de simulações de exemplos de amostras de diferentes tamanhos para cada tipo de perturbação. Então, diferentes especificações de modelos de SEM serão aplicados a estas amostras, e seus parâmetros serão estimados por dois métodos diferentes: Mínimos Quadrados Generalizados e Máxima Verossimilhança. Conhecendo tais resultados, um pesquisador que queira aplicar a técnica de SEM poderá se precaver e, dentre as medidas de qualidade de ajuste disponíveis, optar pelas que mais se adequem às características de seu estudo.

Palavras-chave: Análise Multivariada, Análise de Equações Estruturais, Medidas de Qualidade de Ajuste, tamanho da amostra, outliers, curtose, assimetria, multicolinearidade, relações causais.

Abstract

Analysis of the impact of disturbances over the measures of goodness of fit for structural equation models

The Structural Equation Modeling (SEM) is a multivariate methodology that allows the study of cause-and-effect relationships and correlation of a set of variables (that may be observed or latent ones), simultaneously. The technique has become more diffuse in the last years, in different fields of knowledge. One of its main applications is on the confirmation of theoretical models proposed by the researcher (Confirmatory Factorial Analysis). There are several measures suggested by literature to measure the goodness of fit of a SEM model. However, there is a scarce number of texts that list relationships between the values of different of those measures with possible problems that may occur on the sample or the specification of the SEM model, like information concerning what problems of this nature impact which measures (and which not), and how does the impact occur. This information is important because it allows the understanding of the reasons why a model could be considered bad fitted. The objective of this work is to investigate how different disturbances of the sample, the model specification and the estimation of a SEM model are able to impact the measures of goodness of fit; additionally, to understand if the sample size has influence over this impact. It will also be investigated if those disturbances affect the estimates of the parameters, given the fact that there are disturbances for which occurrence some of the measures indicate badness of fit but the parameters are not affected; at the same time, that are occasions on which the measures indicate a good fit and there are disturbances on the estimates of the parameters. Those investigations will be made simulating examples of different size samples for which type of disturbance. Then, SEM models with different specifications will be fitted to each sample, and their parameters will be estimated by two different methods: Generalized Least Squares and Maximum Likelihood. Given those answers, a researcher that wants to apply the SEM methodology to his work will be able to be more careful and, among the available measures of goodness of fit, to chose those that are more adequate to the characteristics of his study.

Key-words: Multivariate Analysis, Structural Equation Modeling, measures of goodness of fit, sample size, outliers, kurtosis, skewness, multicollinearity, causal relationships.

Sumário

Agradecimentos	i
Resumo	ii
Abstract	iii
Lista de Figuras	vii
Lista de Tabelas	xi
1 Introdução	1
2 Fundamentos da modelagem de equações estruturais	3
2.1 Histórico	6
2.2 Diagrama de caminhos	8
2.2.1 Efeitos direto, indireto e total	13
2.3 Notação matemática	14
2.3.1 Equações de mensuração	15
2.3.2 Equações estruturais	15
2.3.3 Estrutura de correlação e suposições	16
2.4 Validade e confiabilidade	20
2.5 Identificabilidade	21
2.5.1 Regra t	22
2.5.2 Regra dois-passos	22
3 Estimação e qualidade de ajuste do modelo	24
3.1 Métodos de estimação	24
3.1.1 Método de máxima verossimilhança (ML)	25

3.1.2	Método de mínimos quadrados generalizados (GLS)	26
3.1.3	Método de mínimos quadrados não-ponderados (ULS)	27
3.1.4	Outros métodos	27
3.1.5	Suposições sobre a distribuição dos dados	28
3.1.6	Suposições sobre as relações entre os fatores e seus indicadores . . .	30
3.2	Qualidade de ajuste	30
3.2.1	Avaliação dos parâmetros estimados	31
3.2.2	Avaliação do ajuste geral do modelo	32
3.3	Outras suposições e cuidados	39
4	Simulações	40
4.1	Exemplo 1	41
4.2	Exemplo 2	59
5	Conclusão e sugestões de trabalhos futuros	74
	Apêndice	76
	Apêndice	83
	Apêndice	103
	Referências	121

Lista de Figuras

2.1	Possibilidades de representação pictórica de variáveis de modelos de SEM em diagramas de caminho	8
2.2	Possibilidades de representação pictórica das relações entre variáveis de modelos de SEM em diagramas de caminho	9
2.3	Diagrama de caminhos para o Exemplo 2.1 (Veraszto et al., 2009)	10
2.4	Diagrama de caminhos no instante t para o Exemplo 2.2 (Ferguson et al., 2009).	11
2.5	Diagrama de caminhos para o Exemplo 2.4 (Vieira, 2006).	13
2.6	Diagrama de caminhos para o Exemplo 2.5 (Raminelli et al., 2010).	19
4.1	Diagramas de caminho para os modelos ajustados no Exemplo 1	42
4.2	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "coutliers1" com tamanho N=1000, e os valores simulados, no Exemplo 1.	49
4.3	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "coutliers2" com tamanho N=1000, e os valores simulados, no Exemplo 1.	49
4.4	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "coutliers1", "coutliers2" e "normal", com tamanho N=1000, no Exemplo 1.	50
4.5	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "cassim1" com tamanho N=1000, e os valores simulados, no Exemplo 1.	51
4.6	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "cassim2" com tamanho N=1000, e os valores simulados, no Exemplo 1.	51
4.7	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "cassim1", "cassim2" e "normal", com tamanho N=1000, no Exemplo 1.	52

4.8	Comparação entre os valores mínimo, médio e máximo das medidas de qualidade do ajuste para o Modelo 2, estimados por Máxima Verossimilhança para as situações "cassim1", "cassim2" e "normal", com tamanho N=1000, no Exemplo 1.	53
4.9	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "ccorrel1" com tamanho N=1000, e os valores simulados, no Exemplo 1.	54
4.10	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "ccorrel1" e "normal", com tamanho N=1000, no Exemplo 1.	55
4.11	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "relac", com tamanho N=1000, e os valores simulados, no Exemplo 1.	56
4.12	Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "relac" e "normal", com tamanho N=1000, no Exemplo 1.	56
4.13	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1, com ajuste por Máxima Verossimilhança e N=1000, no Exemplo 1.	58
4.14	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2, com ajuste por Máxima Verossimilhança e N=1000, no Exemplo 1.	59
4.15	Diagramas de caminho para os modelos ajustados no Exemplo 2	60
4.16	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccurt" com tamanho N=1000, e os valores simulados, no Exemplo 2.	64
4.17	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "ccurt" e "normal", com tamanho N=1000, no Exemplo 2.	65
4.18	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccorrelx" com tamanho N=1000, e os valores simulados , no Exemplo 2.	66
4.19	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "ccorrelx" e "normal", com tamanho N=1000, no Exemplo 2.	66
4.20	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccorrely" com tamanho N=1000, e os valores simulados, no Exemplo 2.	67

4.21	Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situação "ccorrely" e "normal", com tamanho N=1000, no Exemplo 2.	68
4.22	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "icausa1" com tamanho N=1000, e os valores simulados, do Exemplo 2.	69
4.23	Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "icausa1" e "normal", com tamanho N=1000, no Exemplo 2.	69
4.24	Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "icausa2" com tamanho N=1000, e os valores simulados, no Exemplo 2.	70
4.25	Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "icausa2" e "normal", com tamanho N=1000, no Exemplo 2.	71
4.26	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1 do Exemplo 2, estimado por Máxima Verossimilhança, com N=1000.	72
4.27	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2 do Exemplo 2, estimado por Máxima Verossimilhança, com N=1000.	72
A.1	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "coutliers1", "coutliers2" e "normal", com tamanho N=1000, no Exemplo 1. . . .	77
A.2	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "cassim1", "cassim2" e "normal", com tamanho N=1000, no Exemplo 1.	78
A.3	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorre11" e "normal", com tamanho N=1000, no Exemplo 1.	78
A.4	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "relac" e "normal", com tamanho N=1000, no Exemplo 1.	79
A.5	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccurt" e "normal", com tamanho N=1000, no Exemplo 2.	79
A.6	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorre1x" e "normal", com tamanho N=1000, no Exemplo 2.	80

A.7	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorrely" e "normal", com tamanho N=1000, no Exemplo 2.	80
A.8	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "icausa1" e "normal", com tamanho N=1000, no Exemplo 2	81
A.9	Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "icausa2" e "normal", com tamanho N=1000, no Exemplo 2.	81
A.10	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1 do Exemplo 2, ajustado por Mínimos Quadrados Generalizados, com N=1000.	82
A.11	Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2 do Exemplo 2, ajustado por Mínimos Quadrados Generalizados, com N=1000.	82

Lista de Tabelas

4.1	Descrição das situações aplicadas sobre as amostras nas quais foram ajustados os Modelos 1 a 3 do Exemplo 1.	44
4.2	Estimativas dos parâmetros do ajuste do Modelo 1 para a situação "normal", por Máxima Verossimilhança, no Exemplo 1.	46
4.3	Medidas de qualidade de ajuste para a aplicação do Modelo 1 para a situação "normal", por Máxima Verossimilhança, no Exemplo 1.	47
4.4	Correlação entre os indicadores do modelo para uma das simulações da situação "ccorre1", com N=1000, no Exemplo 1.	54
4.5	Resumo dos resultados obtidos para o Exemplo 1.	57
4.6	Descrição das situações nas quais foram simuladas as amostras sobre as quais foram ajustados os Modelos 1 e 2 do Exemplo 2.	63
4.7	Resumo dos resultados obtidos para o Exemplo 2.	72
A.1	Estimativas dos parâmetros do ajuste do Modelo 1 sobre a situação "normal", por Mínimos Quadrados Generalizados, no Exemplo 1.	76
A.2	Medidas de qualidade de ajuste para a aplicação do Modelo 1 sobre a situação "normal", por Mínimos Quadrados Generalizados, no Exemplo 1.	77
C.1	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Mínimos Quadrados Generalizados, no Exemplo 1.	104
C.2	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Máxima Verossimilhança, no Exemplo 1.	105
C.3	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Mínimos Quadrados Generalizados, no Exemplo 1.	106
C.4	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Máxima Verossimilhança, no Exemplo 1.	107
C.5	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Mínimos Quadrados Generalizados, no Exemplo 1.	108

C.6	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Máxima Verossimilhança, no Exemplo 1.	109
C.7	Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Mínimos Quadrados Generalizados, no Exemplo 1.	110
C.8	Medidas de qualidade de ajuste dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Máxima Verossimilhança, no Exemplo 1.	111
C.9	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Mínimos Quadrados Generalizados, no Exemplo 1.	112
C.10	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Máxima Verossimilhança, no Exemplo 1.	113
C.11	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Mínimos Quadrados Generalizados, no Exemplo 1.	114
C.12	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Máxima Verossimilhança, no Exemplo 1.	115
C.13	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Mínimos Quadrados Generalizados, no Exemplo 1.	116
C.14	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Máxima Verossimilhança, no Exemplo 1.	117
C.15	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Mínimos Quadrados Generalizados, no Exemplo 1.	118
C.16	Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Máxima Verossimilhança, no Exemplo 1.	119

Capítulo 1

Introdução

A Modelagem de Equações Estruturais (SEM, sigla em inglês para *Structural Equation Modeling*) é uma técnica estatística multivariada que permite analisar as relações de causa e efeito e correlação num conjunto de variáveis.

Por permitir que sejam estudadas diversas relações simultaneamente, inclusive envolvendo variáveis não-observáveis, nas últimas décadas a técnica vem ganhando popularidade em diversas áreas do conhecimento.

Uma das etapas mais importantes do emprego desta técnica é a especificação do modelo. Nesta etapa são feitas diversas suposições que afetarão o resultado final, como quais variáveis afetam ou não outras, e quais são correlacionadas entre si. É muito importante que o pesquisador aplique todo o seu conhecimento teórico para especificar o modelo da maneira mais fidedigna possível à realidade. Um modelo mal-especificado pode levar a conclusões de existência de relações falsas entre diferentes variáveis.

Existem diversas medidas de qualidade de ajuste do modelo de SEM propostas na literatura, mas não existe uma unanimidade acerca de qual delas é mais adequada a cada estudo (dependendo das características das variáveis e do tamanho da amostra, por exemplo), ou de como elas são impactadas caso o modelo seja mal especificado ou que suas suposições não sejam respeitadas.

O objetivo deste trabalho é estudar como estas medidas de qualidade refletiriam possíveis problemas no estudo, impactando a amostra e a especificação de diferentes maneiras

para tentar compreender quais são as medidas impactadas, e como. Tal resultado irá facilitar, futuramente, a identificação de quais são os possíveis problemas com um estudo que apresenta alguns resultados relacionados a medidas de qualidade de ajuste alterados.

No Capítulo 2, é feita uma descrição da técnica de SEM e seus principais pontos: especificação do modelo e de suas equações componentes em diagramas de caminhos e em notação matemática, suas suposições, e definição de elementos como validade, confiabilidade e identificabilidade.

O Capítulo 3 apresenta uma revisão das mais importantes técnicas de estimação dos parâmetros do modelo e também das principais medidas de qualidade de ajuste.

No Capítulo 4, são realizadas simulações de dois exemplos de ajuste de SEM com diferentes perturbações, para avaliar como as medidas apresentadas no Capítulo 3 respondem a elas dependendo também do tamanho da amostra e do método de estimação utilizado.

Finalmente, no Capítulo 5 são apresentadas as conclusões do estudo e também algumas sugestões de estudos futuros.

Capítulo 2

Fundamentos da modelagem de equações estruturais

A Modelagem de Equações Estruturais (SEM) é uma metodologia utilizada para desenvolver e validar hipóteses multivariadas de correlação e linearidade acerca de conjuntos de variáveis, tanto mensuráveis quanto não-mensuráveis (constructos ou variáveis latentes).

Segundo Bollen (1989a), a SEM é um caso geral de diversas técnicas estatísticas, dentre elas: Análise de Regressão, Sistema de Equações Lineares, Análise Fatorial Confirmatória, Análise de Painel, Análise de Variância (ANOVA), dentre outras. Também poderiam ser citadas a Análise Fatorial Exploratória e a Análise de Correlação Canônica.

Tal generalização pode ser feita porque todas estas são técnicas em que são supostas e/ou estimadas relações entre variáveis (em alguns casos apenas variáveis observadas, e em outros também variáveis latentes).

Sanches (2005) menciona que o fato de SEM ser considerada uma técnica mais geral que as demais ocorre também pela possibilidade de se mensurar relações de causa-efeito entre variáveis não mensuráveis e entre as variáveis dependentes de diferentes equações num mesmo sistema (enquanto que num sistema de regressão linear múltipla, existe a suposição de que elas são não-correlacionadas). Suas restrições também são mais flexíveis com relação à existência de multicolinearidade entre as variáveis, por exemplo. Acrescenta-se a vantagem de se distinguir entre efeitos diretos e indiretos de uma variável sobre outra. Segundo Goldberger (1972), a técnica é indicada no caso das variáveis observadas

apresentarem interdependência ou erros de medida, ou ainda no caso da suposição da existência de variáveis latentes. A possibilidade de se confirmar o bom ajuste do modelo como um todo, em detrimento de parâmetros isolados, também é uma vantagem da utilização desta técnica (empregada, por exemplo, na Análise Fatorial Confirmatória, para confirmar a validade de questionários).

Para a aplicação da SEM, são utilizados, juntamente com os dados coletados, conhecimentos teóricos do pesquisador, que estabelece qual será a relação causal aplicada aos dados. Isso possibilita confirmar hipóteses, mas também pode representar uma limitação, dado que a escolha das variáveis e relações causais realizada pelo pesquisador influenciam a estrutura preditiva do modelo (por exemplo: Sanches (2005) discute o que ocorre com o ajuste do modelo quando é especificada uma relação causal invertida entre duas variáveis). Desta forma, é importante que toda a construção do modelo seja fortemente embasada e fundamentada em elementos teóricos. Um exemplo prático de trabalho que lista e toma uma série de cuidados a este respeito é o de Veraszto et al. (2011). Pilati e Laros (2007) também lista uma série de questões que precisam ser respondidas pelo pesquisador ao começar a utilizar a técnica (como sugestões do que deve ser levado em conta ao se realizar a fundamentação teórica das medidas, o desenho do modelo, etc.). Ademais, o autor recomenda que, por ser esta uma técnica de caráter confirmatório (Kaplan, 2000), em casos de estudos exploratórios talvez seja interessante utilizar outras técnicas multivariadas; e também que este caráter confirmatório aumenta a importância de ser realizado um bom embasamento das relações de causa-efeito supostas pelo modelo em pressupostos teóricos e relações empíricas anteriores.

Seguem abaixo alguns exemplos, de diversas áreas do conhecimento, nos quais foi aplicada de alguma forma a técnica de Modelagem de Equações Estruturais.

Exemplo 2.1: Análise Fatorial Confirmatória - Veraszto et al. (2009)

Para estudar como a evolução nas tecnologias causada pela interação do homem com o meio e com a sociedade provocava uma mudança recíproca nos mesmos, o pesquisador entrevistou alunos de graduação, questionando-lhes suas concepções (CON) acerca

da tecnologia, suas atitudes e expectativas frente ao desenvolvimento tecnológico (ATI) e as influências da dimensão social (DSO). Para observar tais constructos, ele contou com um questionário com doze a dezessete itens por constructo. O pesquisador possuía duas teorias: 1- a validade dos três questionários utilizados para configurar cada um dos constructos; e 2- a de que a dimensão social exerceria uma influência sobre os fatores concepção e atitude.

Exemplo 2.2: Modelo recursivo de regressão linear - Ferguson et al. (2009)

Neste exemplo, para estudar a relação entre a quantidade de clorofila com algumas variáveis explicativas (temperatura da água, nível de fósforo e de nitrato-nitrogênio e a quantidade de um pequeno crustáceo chamado Daphnia) mensuradas num lago na Escócia, além de supor também que a temperatura da água e a própria quantidade de clorofila impactavam a presença do crustáceo Daphnia, os pesquisadores utilizaram um modelo de SEM recursivo (ou seja: a variável resposta de uma das equações do sistema era variável explicativa em outra equação), apenas com variáveis observáveis. Além disso, foi apresentada uma evolução da técnica SEM que permitiu que os parâmetros estimados fossem indexados no tempo, de forma a considerar as mudanças no comportamento da água que os pesquisadores acreditavam ocorrer ao longo dos meses.

Exemplo 2.3: Análise fatorial exploratória com grupos - Asparouhov e Muthén (2009)

A fim de identificar comportamentos agressivos em crianças de uma escola, neste trabalho os pesquisadores avaliaram os estudantes amostrados com um questionário que os classificava em 13 itens (avaliando a frequência com que determinados comportamentos eram apresentados). São comparados os resultados obtidos com a Análise Fatorial Exploratória e com um modelo de SEM cuja estrutura de correlações seja análoga à da primeira técnica (ou seja, supondo os fatores independentes). A discussão é expandida também para quais seriam as diferenças caso tivesse sido utilizada uma Análise Fatorial Confirmatória.

A técnica de SEM é bastante difundida em outras áreas do conhecimento. Apenas para mencionar alguns exemplos, MacCallum e Austin (2000) fazem um apanhado da utilização da técnica na área de psicologia; e Iriondo et al. (2003), na de ciências biológicas.

2.1 Histórico

Para repassar o histórico da modelagem de SEM, é necessário passar pelos seus três componentes principais: 1- a análise de caminhos, 2- a síntese conceitual entre variáveis latentes e modelos de mensuração, e 3- os procedimentos de estimação usuais (Bollen, 1989a). Cada um desses três elementos será estudado posteriormente neste trabalho.

Com relação aos diagramas de caminho, atribui-se sua criação a Wright (1918, 1921, 1934, 1960). Ele não associa o diagrama de caminhos à notação matricial empregada hoje em dia, senão que às próprias equações de regressão presentes no diagrama.

O emprego de variáveis latentes em modelos de mensuração foi iniciado por Spearman (1904), ao descrever modelos de Análise Fatorial, preocupando-se principalmente com aquilo que hoje são conhecidas por Equações de Mensuração (ver Seção 2.3.1). Estes modelos foram ganhar uma maior base estatística em meados da década de 40 (Lawley, 1940), mas a falta de recursos computacionais adiou sua popularização até a década de 60. Com auxílio da ferramenta desenvolvida por Wright, nessa década e durante o início da década de 70 estes modelos puderam ser melhor desenvolvidos.

Assim, na década de 60 Lawley e Maxwell (1962) resumem tópicos de estimação e teste de hipóteses, já com notação matricial, mas apenas no âmbito da análise fatorial; Blalock (1963) menciona o uso das covariâncias das variáveis observadas para estimar modelos em que também há variáveis latentes; enquanto que começaram a ser desenvolvidos algoritmos computacionais para estimar tais modelos (Jöreskog, 1967, e Jöreskog e Lawley, 1968). Jöreskog (1969) apresenta uma abordagem para estimar modelos por Análise Fatorial Confirmatória a partir da técnica de Máxima Verossimilhança. Diversos outros exemplos podem ser mencionados para ilustrar o desenvolvimento de técnicas e algoritmos para estimar modelos envolvendo variáveis latentes.

No início da década de 70, os trabalhos de Jöreskog (1973), Keesing (1972) e Wiley (1973) finalmente conseguiram trazer um modelo geral, que pudesse ser aplicado a diferentes situações, como é hoje o modelo de SEM. Aqui o modelo começou a ser visto como divisível em duas partes (as Equações de Mensuração e as Equações Estruturais). O desenvolvimento do programa LISREL (Jöreskog e Sorbom, 1986) ajudou tanto a popularizar os modelos de SEM que ainda hoje muitas vezes os termos Modelo de Equações Estruturais e LISREL são tratados por alguns como sinônimos. Entretanto, algumas notações alternativas para os modelos de SEM foram posteriormente desenvolvidas, como em Bentler e Weeks (1980).

Finalmente, o terceiro ângulo da modelagem de SEM que deve ser observado é a utilização de técnicas usuais de estimação, cujo desenvolvimento não necessariamente está ligado à utilização de equações estruturais. Mas, especificamente referindo-se a metodologias aplicadas para esta técnica, podem-se mencionar os trabalhos de Lawley (1940), Anderson e Rubin (1956) e Jöreskog (1969), que ajudaram a definir testes de hipóteses a serem utilizados para o modelo; Goldberger (1964), Bock e Bargmann (1966), Jöreskog e Goldberger (1972), Jöreskog (1973), Browne (1974, 1982) que sugeriram estimadores para diferentes situações em que se pode aplicar SEM; Muthén (1978, 1984), Johnson e Creech (1983) e Muthén e Kaplan (1985), que sugeriram análises a serem realizadas quando há no modelo variáveis categóricas; dentre outras inúmeras contribuições.

Com o desenvolvimento das técnicas computacionais, a modelagem de SEM tornou-se mais difundida, principalmente em áreas nas quais é interessante aplicar modelos com variáveis latentes (como psicologia, ciências sociais, econometria, biologia, etc). Além do já mencionado LISREL, pode-se citar ainda o AMOS (Arbuckle, 1999), o EQS (Bentler, 1985), o proc calis e o proc tcalis do SAS (SAS Institute Inc., 2010) e o pacote SEM do R (R-project, 2011).

2.2 Diagrama de caminhos

Conforme mencionado no item anterior, comumente associa-se à aplicação da Modelagem de Equações Estruturais a construção de um diagrama de caminhos. Esta ferramenta gráfica é utilizada para facilitar o entendimento e visualização das relações de causa-efeito entre as variáveis (observáveis e latentes) do modelo de SEM estudado.

No diagrama de caminhos, as variáveis latentes e observáveis são representadas no interior de formas geométricas (retângulos para as observadas e elipses para as latentes), as variáveis de erro são representadas diretamente (sem estarem dentro de formas) ou então no interior de círculos, e as relações causais (todas supostas lineares) são representadas por flechas.

Desta forma, a Figura 2.1 ilustra as possibilidades de representação das variáveis num diagrama de caminhos.

Figura 2.1: Possibilidades de representação pictórica de variáveis de modelos de SEM em diagramas de caminho

Com relação às flechas, elas podem indicar causa, causa mútua ou correlação. Flechas saindo de uma variável e apontando em direção a uma outra indicam que a primeira causa a segunda; caso sejam duas flechas apontando em sentidos distintos, isso significa que a primeira variável causa a segunda mas também é causada por ela. Finalmente, quando uma única flecha aponta para duas ou mais variáveis ela representa que as mesmas são correlacionadas.

Estas convenções valem tanto para variáveis observáveis quanto para as latentes, variáveis de erro e interações entre um tipo e outro, sem distinções.

A Figura 2.2 ilustra as possíveis relações de causa entre variáveis num diagrama de

caminhos.

Figura 2.2: Possibilidades de representação pictórica das relações entre variáveis de modelos de SEM em diagramas de caminho

Utilizando-se as definições acima, é construído então um diagrama de caminhos que esquematiza todas as relações supostas no modelo de SEM (para as quais serão fixados valores ou ajustados parâmetros). Estes efeitos são também representados no modelo, a partir de letras gregas (sendo que o usual é separar os efeitos em conjuntos e utilizar letras diferentes para representá-los; ou seja, efeitos de uma variável latente sobre variáveis observadas podem ser representados por uma letra adicionada de índices, enquanto que, no mesmo diagrama, para representar efeitos de uma outra variável observada sobre determinado conjunto de variáveis latentes pode ser usada outra letra, e para as correlações entre as variáveis observadas uma terceira).

Todas as relações supostas pelo modelo devem estar representadas no diagrama, mesmo que o seu ajuste indique uma estimativa igual a zero ao parâmetro correspondente. Caso uma relação não esteja especificada, isso significa que se parte da suposição de que ela vale 0; por exemplo, que duas variáveis são não-correlacionadas. Assim, o modelo de SEM fica completamente determinado pelo diagrama de caminhos, e a partir deste é possível especificar matematicamente o modelo (conforme explicado na Seção 2.3) de forma completa.

Por isso, Bollen (1989a) comenta que uma das principais vantagens da utilização do diagrama de caminhos é que ele representa graficamente as relações supostas pelo modelo,

de uma forma que pode ser mais clara para a maioria dos pesquisadores do que as equações da notação matemática. Para melhor ilustrar o conceito de diagrama de caminhos, seguem os diagramas construídos para os Exemplos 2.1 e 2.2, descritos no início deste capítulo.

Figura 2.3: Diagrama de caminhos para o Exemplo 2.1 (Veraszto et al., 2009)

Na Figura 2.3, observa-se que o problema possui a seguinte estrutura de suposições:

- DSO, CON e ATI são variáveis latentes;
- As variáveis D_1 a D_{12} , A_1 a A_{17} e C_1 a C_{15} são observadas;
- As variáveis ϵ_{D1} a ϵ_{D12} , ϵ_{C1} a ϵ_{C15} e ϵ_{A1} a ϵ_{A17} são variáveis de erro;
- DSO causa D_1 , D_2 , ..., D_{12} , e também causa CON e ATI;
- ATI causa A_1 , A_2 , ..., A_{17} ;
- CON causa C_1 , C_2 , ..., C_{15} ;
- As variáveis nos três conjuntos de variáveis D_1 a D_{12} , A_1 a A_{17} e C_1 a C_{15} podem apresentar correlação com as outras variáveis do respectivo conjunto, mas as variáveis de um conjunto são não-correlacionadas com as de outro.

A Figura 2.4 representa o diagrama de caminhos do Exemplo 2.2 no instante t , lembrando que, neste trabalho, as variáveis foram observadas ao longo de vários meses e o modelo foi indexado no tempo. O problema possui então, para um instante t , a seguinte estrutura de suposições:

Figura 2.4: Diagrama de caminhos no instante t para o Exemplo 2.2 (Ferguson et al., 2009).

- As variáveis temperatura, clorofila, Daphnia, NO_3N e Fósforo são observadas;
- As variáveis ϵ_1 a ϵ_3 e δ_1 a δ_2 são variáveis de erro;
- A temperatura causa a clorofila e Daphnia;
- NO_3N e Fósforo causam a clorofila;
- Clorofila e Daphnia possuem uma relação de causa recíproca;
- As variáveis temperatura, NO_3N e Fósforo são supostamente não-correlacionadas.

As variáveis mensuráveis que possuem alguma relação de causa com variáveis latentes são chamadas **indicadores**. Os indicadores podem ser tanto variáveis latentes como observadas, mas é necessário que pelo menos um dos indicadores de uma variável latente seja uma variável observada, para que seja possível construir o modelo.

Quando a variável observada é causada pelo constructo, ela é chamada de **indicador reflexivo** deste constructo. Isso ocorre, por exemplo, no modelo usual de Análise Fatorial. Já quando o indicador causa o constructo, ele é chamado **indicador formativo**.

A maioria dos modelos possui indicadores reflexivos para os constructos; mas, dependendo da interpretação deles, em alguns momentos o mais correto seria que eles fossem formativos. Considerar na especificação do modelo de SEM um indicador como formativo ou reflexivo pode alterar completamente o resultado do ajuste, impactando inclusive os efeitos de outras variáveis. Sanches (2005) faz uma extensiva análise sobre o assunto, comparando modelos em que um indicador foi especificado como formativo com o mesmo modelo, mas especificando-o como reflexivo. Esta diferença será explorada também neste trabalho, para avaliar quais medidas de ajuste do modelo são mais sensíveis a esta diferença. O Exemplo 2.4 abaixo ilustra um estudo em que foram utilizados indicadores tanto formativos quanto reflexivos.

Exemplo 2.4: Modelo com variáveis latentes e observadas - Vieira (2006)

O foco deste estudo é a reação do mercado ao fato de uma empresa realizar splits (emissão e distribuição de ações aos seus acionistas de forma proporcional ao valor dos papéis que eles já possuem). Apesar de que aparentemente tal atitude não deveria representar uma mudança, o autor aponta diversos trabalhos da literatura que indicam que há uma reação positiva do mercado a tal atitude. Cada trabalho levanta diferentes possíveis causas para tal acontecimento, e, aqui, o autor utiliza SEM para integrar todas elas num único modelo.

Assim, o modelo é composto pelos constructos Preço, Tamanho da Empresa, Tipo de Negociação e Spread, que, juntamente aos seus indicadores, influenciariam a variável "Reação do Mercado". A Figura 2.5 mostra o diagrama de caminhos sugerido pelo pesquisador.

Figura 2.5: Diagrama de caminhos para o Exemplo 2.4 (Vieira, 2006).

2.2.1 Efeitos direto, indireto e total

A partir do diagrama de caminhos, fica simples observar que uma variável pode influenciar outra de duas maneiras: 1- diretamente ou 2- influenciando uma outra variável que influencie aquela.

Como todas as relações supostas no diagrama de caminhos são lineares, é possível decompor o efeito total de uma variável v_1 sobre outra variável v_2 como sendo a soma dos efeitos direto e indireto de v_1 sobre v_2 .

Bollen (1989a) ressalta que este efeito é relativo à estrutura do modelo considerada; ou seja, se um novo modelo estrutural é ajustado alterando-se por exemplo a estrutura de correlações ou o conjunto de covariáveis, os efeitos são re-estimados.

Para calcular o efeito total, procede-se da seguinte forma:

Seja x uma variável que causa outra variável y diretamente, e que também causa uma terceira variável z , que por sua vez também exerce uma relação de causa sobre y .

Supondo-se que o efeito de x sobre y seja $\mathbf{a}$, o de x sobre z seja $\mathbf{b}$ e o de z sobre y seja

c , obtém-se que:

- O efeito direto de x sobre y será igual a a .
- O efeito indireto de x sobre y será igual ao produto dos efeitos que compõem o caminho de uma até outra, ou seja, o produto entre o efeito de x sobre z (b) e o de z sobre y (c). Neste caso, o efeito indireto será bc .
- Portanto, o efeito total da variável x sobre a variável y , no exemplo considerado, será correspondente a:

$$\text{Efeito total} = \text{Efeito direto} + \text{Efeito indireto}$$

$$\text{Efeito total} = a + bc.$$

Desta forma, o efeito total da variável temperatura sobre a variável clorofila, apresentadas na Figura 2.4, é dado por:

$$\text{Efeito total} = \text{Efeito direto} + \text{Efeito indireto}$$

$$\text{Efeito total} = \beta_{3t} + \beta_{5t} \cdot \beta_{4t}.$$

Se uma variável latente sofre efeito de alguma outra variável latente, ela é chamada de **variável endógena ou dependente**. Caso contrário, ela recebe o nome de **variável exógena ou independente**.

2.3 Notação matemática

É possível observar num diagrama de caminhos dois tipos de relação entre as variáveis:

- As **Equações de Mensuração** são aquelas que envolvem as variáveis observadas, relacionando-as entre si e também com as variáveis latentes;
- As **Equações Estruturais** são aquelas que especificam a relação entre as variáveis latentes do modelo.

Assim, o sistema de relações de causa-efeito do modelo de SEM é decomposto nestas duas partes, e cada uma possui uma notação matemática específica.

2.3.1 Equações de mensuração

A notação utilizada neste texto será a empregada por Bollen (1989a). Sejam $\mathbf{x}_{(q \times 1)}$ o vetor de q variáveis observadas que são indicadores das n variáveis latentes exógenas, e $\mathbf{y}_{(p \times 1)}$ o vetor de p variáveis observadas que são indicadores das m variáveis latentes endógenas; além disso, sejam os vetores $\boldsymbol{\eta}_{(m \times 1)}$ e $\boldsymbol{\xi}_{(n \times 1)}$ compostos pelas variáveis latentes endógenas (ou dependentes) e exógenas (ou independentes), respectivamente.

Têm-se que as equações de mensuração do modelo de SEM podem ser escritas na seguinte forma:

$$\mathbf{y} = \Lambda_y \boldsymbol{\eta} + \boldsymbol{\epsilon} \quad (2.3.1.1)$$

$$\mathbf{x} = \Lambda_x \boldsymbol{\xi} + \boldsymbol{\delta}, \quad (2.3.1.2)$$

em que:

- (2.3.1.1) é a equação de mensuração das variáveis latentes endógenas, e (2.3.1.2), a das variáveis latentes exógenas;
- $\Lambda_{y(p \times m)}$ e $\Lambda_{x(q \times n)}$ são matrizes de parâmetros, que representam os efeitos das variáveis latentes (respectivamente endógenas e exógenas) sobre seus respectivos indicadores;
- $\boldsymbol{\epsilon}_{(p \times 1)}$ e $\boldsymbol{\delta}_{(q \times 1)}$ são, nesta ordem, os vetores de erros de mensuração para $\mathbf{y}$ e $\mathbf{x}$.

2.3.2 Equações estruturais

As equações estruturais são aquelas que relacionam as variáveis latentes entre si.

Sendo os vetores $\boldsymbol{\eta}_{(m \times 1)}$ e $\boldsymbol{\xi}_{(n \times 1)}$ de variáveis latentes os mesmos definidos no Item 2.3.1, então a equação estrutural do modelo de SEM pode ser escrita como:

$$\boldsymbol{\eta} = \mathbf{B}\boldsymbol{\eta} + \mathbf{\Gamma}\boldsymbol{\xi} + \boldsymbol{\zeta}, \quad (2.3.2.1)$$

em que:

- $B_{(m \times m)}$ é uma matriz de parâmetros que representa os efeitos das variáveis latentes endógenas sobre os outros constructos. Verifica-se que a diagonal principal desta matriz será sempre identicamente nula, pois um fator nunca será escrito como função dele mesmo.
- $\Gamma_{(m \times n)}$ é uma matriz de parâmetros que representa o efeito das variáveis latentes exógenas sobre os outros constructos;
- $\zeta_{(m \times 1)}$ é um vetor aleatório com erros das equações estruturais.

2.3.3 Estrutura de correlação e suposições

Conjuntamente, as equações de mensuração no Item 2.3.1 e as equações estruturais no Item 2.3.2 refletem todas as suposições de causa-efeito que podem ser representadas num diagrama de caminhos. Entretanto, ficam faltando ainda as relações de correlação que se supõe existirem entre as variáveis.

Para completar a representação matemática do modelo, é necessário ainda fazer algumas suposições a respeito dos parâmetros e definir a estrutura de correlação dos mesmos.

Desta forma, no conjunto de equações (2.3.1.1), (2.3.1.2) e (2.3.2.1) supõe-se que (Bollen, 1989a):

Suposições das equações de mensuração:

- ϵ é não-correlacionado com δ , ξ e η ;
- δ é não-correlacionado com ϵ , ξ e η ;
- $E(\eta) = 0$;
- $E(\epsilon) = 0$;
- $E(\xi) = 0$;
- $E(\eta) = 0$;

Suposições das equações estruturais:

- ζ é não-correlacionado com ξ ;
- $E(\eta) = 0$;
- $E(\zeta) = 0$;
- $E(\xi) = 0$;
- $(I - B)$ é uma matriz não-singular, de forma que $(I - B)^{-1}$ existe.

As matrizes de covariância dos parâmetros do modelo são as seguintes:

- $\Phi_{(n \times n)} = E(\xi\xi')$;
- $\Psi_{(m \times m)} = E(\zeta\zeta')$;
- $\Theta_{\epsilon(p \times p)} = E(\epsilon\epsilon')$;
- $\Theta_{\delta(q \times q)} = E(\delta\delta')$;

Chamando de θ o vetor de parâmetros livres do modelo, é possível extrair para a matriz de covariância de $z = (y', x')'$ a seguinte expressão:

$$\Sigma(\theta) = \begin{bmatrix} \Lambda_y(I - B)^{-1}(\Gamma\Phi\Gamma' + \Psi)(I - B')^{-1}\Lambda'_y + \Theta_\epsilon & \Lambda_y(I - B)^{-1}\Gamma\Phi\Lambda'_x \\ \Lambda_x\Phi\Gamma'(I - B')^{-1}\Lambda'_y & \Lambda_x\Phi\Lambda'_x + \Theta_\delta \end{bmatrix}$$

É possível reescrever as equações de SEM nas suas formas particulares (Análise Fatorial Exploratória e Confirmatória, Regressão Linear sem variáveis latentes, modelo de comparação de médias em duas populações, etc). Como o objetivo deste capítulo é apenas introduzir os principais conceitos da modelagem de SEM, tais itens serão considerados fora do escopo deste trabalho. Para mais detalhes, ver Bollen (1989a) ou Melhado (2004).

Segue abaixo a especificação algébrica do Exemplo 2.1, além de outro exemplo que permite visualizar como fica o modelo quando não há variáveis latentes.

Equações de Mensuração e Estruturais para o Exemplo 2.1

O Exemplo 2.1 corresponde a um modelo composto tanto da parte de equações de mensuração quanto da de equações estruturais.

Desta forma, suas equações de mensuração podem ser escritas algebricamente conforme segue:

$$D1 = \delta_1 DSO + \epsilon_{D1}$$

$$D2 = \delta_2 DSO + \epsilon_{D2}$$

...

$$D12 = \delta_{12} DSO + \epsilon_{D12}$$

$$C1 = \gamma_1 CON + \epsilon_{C1}$$

$$C2 = \gamma_2 CON + \epsilon_{C2}$$

...

$$C15 = \gamma_{15} CON + \epsilon_{C15}$$

$$A1 = \alpha_1 ATI + \epsilon_{A1}$$

$$A2 = \alpha_2 ATI + \epsilon_{A2}$$

...

$$A17 = \alpha_{17} ATI + \epsilon_{A17}.$$

Já a parte estrutural é a seguinte:

$$CON = DSO + \xi_2$$

$$ATI = DSO + \xi_3.$$

Exemplo 2.5: Modelo apenas com variáveis observadas - Raminelli et al. (2010).

Neste exemplo, deseja-se testar uma estrutura de causa-efeito para as variáveis de um questionário com critérios da OMS para medir a qualidade de vida. O questionário possui 9 itens com respostas de 1 a 5, em que 1 significa que a resposta para o item em questão é "Nada", e 5, "Completamente".

A suposição dos pesquisadores é a de que 3 dos itens do questionário não sofrem efeito de nenhum outro (e suas notas serão denominadas X_1 , X_2 e X_3), enquanto os demais sim ($Y_1, \dots, Y_6$). Além disso, é suposto que as variáveis X são conhecidas, e portanto não possuem erro associado.

A estrutura de correlações proposta pelos pesquisadores está representada no diagrama de caminhos na Figura 2.6.

Figura 2.6: Diagrama de caminhos para o Exemplo 2.5 (Raminelli et al., 2010).

Este modelo é um caso especial do modelo de SEM, pois não possui variáveis latentes. Especificam-se ϵ e δ nas equações (2.3.1.1) e (2.3.1.2) como matrizes de zeros, e Λ_x e Λ_y como matrizes identidade; então, x e y passam a ser medidas exatas de η e ξ .

(respectivamente). Assim, obtém-se um modelo estrutural com variáveis observadas. A forma matricial de (2.3.2.1) fica assim:

$$\mathbf{y} = \mathbf{B}\mathbf{y} + \mathbf{\Gamma}\mathbf{x} + \boldsymbol{\zeta} \quad (2.3.4.1)$$

Sanches(2005) menciona que, apesar de este modelo ser semelhante aos modelos de regressão usuais, ele é muito mais geral por permitir relações entre as variáveis dependentes. Para recair no caso do modelo usual de regressão linear multivariada (ou regressão linear múltipla, caso o vetor $\mathbf{y}$ possua apenas 1 elemento), basta especificar a matriz $\mathbf{B}$ como sendo a matriz nula. Detalhes sobre estes e outros casos específicos podem ser vistos em Sanches(2005) e também em Bollen(1989a).

Algebricamente, (2.3.4.1) fica conforme segue:

$$Y_1 = \gamma_{11}X_1 + \gamma_{12}X_2 + \zeta_1$$

$$Y_2 = \gamma_{21}X_1 + \gamma_{23}X_3 + \beta_{21}Y_1 + \zeta_2$$

$$Y_3 = \beta_{31}Y_1 + \beta_{32}Y_2 + \zeta_3$$

$$Y_4 = \gamma_{41}X_1 + \beta_{41}Y_1 + \beta_{42}Y_2 + \zeta_4$$

$$Y_5 = \gamma_{53}X_3 + \beta_{53}Y_3 + \beta_{56}Y_6 + \zeta_5$$

$$Y_6 = \gamma_{61}X_1 + \gamma_{62}X_2 + \gamma_{63}X_3 + \beta_{61}Y_1 + \beta_{63}Y_3 + \zeta_6.$$

2.4 Validade e confiabilidade

O conceito de validade serve para avaliar, nas equações de mensuração, se determinado indicador realmente é uma medida daquilo que se supõe.

Bollen (1989a) apresenta algumas medidas para se tentar medir a validade de um indicador, mas afirma que nenhuma delas é capaz de medir seu valor real. Neste caso, estas medidas são utilizadas como suporte para a suposição da existência de validade.

Já o conceito de confiabilidade ou consistência reflete o quão confiável é a estimativa do modelo (dada a validade dos indicadores). Sanches(2005) a define como a parte da

medida que é livre de erro aleatório. O estimador usual para a confiabilidade é o Alfa de Cronbach. Ele avalia a confiabilidade geral do modelo (e não específica de cada indicador), e é calculado por:

$$\rho_{HH} = \frac{q}{q-1} \left(1 - \frac{\sum_{i=1}^q \text{var}(X_i)}{\text{var}(\sum_{i=1}^q X_i)} \right),$$

em que q é a quantidade de indicadores.

Pedhazur (1991) traz mais detalhes sobre os conceitos de validade e confiabilidade.

2.5 Identificabilidade

Bollen (1989a) define um parâmetro "conhecido" num modelo de SEM quando ele provém de informações populacionais da distribuição das variáveis observadas, que possuem estimadores consistentes; enquanto que parâmetros "desconhecidos" vêm do modelo estrutural, e para eles é necessário definir se eles possuem um único valor possível.

Caso o parâmetro seja função de parâmetros que podem ser estimados e possuam uma solução única, diz-se que o parâmetro é **identificável**. Caso a solução não seja única, o parâmetro é definido como **sub-identificável**; finalmente, caso haja informação excessiva para a estimação de um parâmetro, ele é definido como **superidentificável**.

Caso o modelo possua algum parâmetro sub-identificável, ele é definido também como **sub-identificável**; analogamente, caso alguma variável seja superidentificável o modelo será definido como **superidentificável**. Se todas as variáveis forem identificáveis, o modelo será considerado **identificável**.

A função comumente usada para relacionar os parâmetros livres com valores observados é $\Sigma = \Sigma(\theta)$, em que Σ é a matriz de covariância populacional das variáveis observadas e $\Sigma(\theta)$ é uma função do vetor θ de parâmetros livres do modelo, definido na Seção 2.3.4 (o que implica em $\frac{1}{2}(p+q)(p+q+1)$ equações distintas).

Assim, para o modelo ser identificável cada elemento de θ precisa poder ser escrito como função de um ou mais parâmetros de Σ de forma única. Geralmente, para tornar um modelo identificável é necessário realizar algumas restrições com relação aos parâmetros.

Seguem abaixo algumas regras que verificam se o modelo pode ou não ser considerado identificável.

2.5.1 Regra t

Conforme mencionado anteriormente, a condição de identificabilidade implica em $\frac{1}{2}(p + q)(p + q + 1)$ equações distintas que devem possuir solução única. Assim, chamando de t o número de parâmetros livres em θ , obtém-se que uma condição necessária (mas não suficiente) para que o modelo seja identificável é que a quantidade de parâmetros livres não seja maior do que a quantidade de elementos na matriz de variância das variáveis observadas (utilizada para obter as igualdades), ou seja,

$$t \leq \frac{1}{2}(p + q)(p + q + 1).$$

2.5.2 Regra dois-passos

Segundo Bistaffa (2010), a Regra dois-passos é composta de duas partes. Na primeira, verifica-se se os parâmetros de mensuração são identificados (tratando o modelo de SEM como uma Análise Fatorial Confirmatória), e na segunda, se os parâmetros do modelo estrutural também são identificados.

Para realizar a primeira etapa, considera-se que tanto os elementos do vetor $\mathbf{x}$ quanto os do vetor $\mathbf{y}$ fazem parte apenas de $\mathbf{x}$ (e que ξ e η são variáveis de ξ). Obtém-se então apenas a seguinte equação de mensuração:

$$\mathbf{x} = \Lambda_{\mathbf{x}}\xi + \delta.$$

Com esta reformulação, é verificado se o modelo é identificável pela regra t e também pelas seguintes regras:

Regra 3 indicadores - são condições **suficientes** para que o modelo seja identificável que haja três ou mais indicadores por variável latente, que cada linha de $\Lambda_{\mathbf{x}}$ tenha exatamente um elemento diferente de 0 e que Θ_{δ} seja diagonal.

Regra 2 indicadores - são condições **suficientes** para que o modelo seja identificável se Θ_δ for diagonal, Φ possuir pelo menos 1 elemento diferente de zero fora da diagonal, existirem dois indicadores por variável latente e que um λ_{ij} seja fixado como 1 para cada ξ_j .

Caso a primeira etapa seja cumprida, parte-se para a próxima, em que serão examinadas as equações estruturais, tratando-as por equações com variáveis observadas (e portanto completamente mensuráveis). Com essa reformulação, a equação estrutural pode ser escrita da seguinte forma:

$$y = By + \Gamma x + \zeta.$$

Posteriormente, verifica-se se o modelo é identificável a partir da regra t e também dos seguintes critérios:

Regra B nula - é uma condição **suficiente, mas não necessária**, para o modelo ser identificável, que a matriz B seja nula (pois, neste caso, as matrizes Φ , Γ e Ψ podem ser escritas como função da matriz de covariância das variáveis observadas, o que garantiria sua identificabilidade).

Regra recursiva - é uma condição **suficiente, mas não necessária**, para o modelo ser identificável, que a matriz B seja triangular inferior e que Ψ seja diagonal.

Condição de ordem - é uma condição **necessária, mas não suficiente**, para o modelo ser identificável, que a matriz $C = [(I - B), -\Gamma]$ possua $(p - 1)$ ou mais zeros em cada linha.

Condição de posto - é uma condição **necessária e suficiente** para o modelo identificável que: seja a matriz C definida acima. Para definir se a i -ésima equação é identificável, verifica-se se a matriz C_i , definida retirando de C todas as colunas que não tiverem 0 na i -ésima linha, possui posto $(p - 1)$. Dado esse critério, basta verificar se todas as equações são identificáveis. Caso isso ocorra, o modelo é identificável.

Pela regra dois-passos, caso seja possível verificar que tanto as equações de mensuração (primeiro passo) quanto as estruturais (segundo passo) são identificáveis, então o modelo completo é identificável.

Capítulo 3

Estimação e qualidade de ajuste do modelo

Neste capítulo, serão listadas as principais técnicas de estimação dos parâmetros do modelo de SEM, bem como uma listagem de medidas de qualidade do ajuste. Além disso, serão listados pontos encontrados na literatura que remetem a problemas na robustez de cada medida. O objetivo disto é realizar uma comparação com os resultados verificados no Capítulo 4, em que serão simulados exemplos com amostras problemáticas para verificar a sensibilidade dos indicadores de desempenho a cada perturbação.

3.1 Métodos de estimação

Para estimar os parâmetros de um modelo de SEM, parte-se da igualdade já mencionada anteriormente $\Sigma = \Sigma(\theta)$. Como a matriz de covariâncias populacionais das variáveis observadas não é conhecida, utiliza-se neste caso a matriz S de covariâncias amostrais, chegando no sistema de equações determinado pela igualdade $S = \Sigma(\hat{\theta})$.

Para estimar os parâmetros do modelo de SEM, serão utilizadas as **funções de discrepância**. Funções de discrepância F são relações entre as matrizes S e $\Sigma(\hat{\theta})$, e que além disso possuem as seguintes propriedades:

- Para cada θ , F é um escalar.
- $F \geq 0$; sendo que $F = 0$ se e somente se $S = \Sigma(\hat{\theta})$.

- F é contínua em $\mathbf{S}$ e em $\Sigma(\boldsymbol{\theta})$.

Segundo Browne (1984), a função de discrepância definida conforme os critérios acima proporcionará estimadores consistentes para os parâmetros do modelo. Logo, são estas as funções utilizadas pelos principais métodos de estimação, conforme será comentado adiante neste capítulo.

Para ilustrar os cálculos da seguinte seção, vale observar que a matriz $\mathbf{S}$ pode ser calculada a partir da expressão abaixo:

$$\mathbf{S} = \frac{N}{(N-1)}(\mathbf{M} - \bar{\mathbf{Z}}\bar{\mathbf{Z}}'),$$

com $\bar{\mathbf{Z}} = (\frac{1}{N})\mathbf{Z}'\mathbf{1}$ (sendo $\mathbf{Z}_{(N \times k)} = (\mathbf{X}, \mathbf{Y})$ a matriz dos dados observados), $\mathbf{1}_{k \times 1}$ o vetor de um's, $k = p + q$ e $\mathbf{M} = (\frac{1}{N})\mathbf{Z}'\mathbf{Z}$.

3.1.1 Método de máxima verossimilhança (ML)

A função de verossimilhança (ML) baseia-se no princípio de máxima verossimilhança, isto é, de encontrar as estimativas dos parâmetros que maximizariam a probabilidade da amostra tomada ter realmente acontecido. Este método parte da suposição de que os vetores $\mathbf{x}$ e $\mathbf{y}$ são normais multivariados, e, portanto, parte da verossimilhança desta distribuição.

O estimador de máxima verossimilhança é obtido a partir da seguinte função de discrepância:

$$F_{ML} = \log|\Sigma(\boldsymbol{\theta})| + tr[\mathbf{S}\Sigma^{-1}(\boldsymbol{\theta})] - \log|\mathbf{S}| - (p + q),$$

em que:

- $\Sigma(\boldsymbol{\theta})$ é a matriz de covariância populacional do modelo que está sendo proposto;
- $|\mathbf{X}|$ é a notação para o determinante de uma matriz $\mathbf{X}$; e $tr[\mathbf{X}]$ é a notação para o traço, ou seja, da soma dos elementos da diagonal principal da matriz.

Esta função deve ser minimizada com relação a $\mathbf{B}$, $\mathbf{\Gamma}$, $\mathbf{\Phi}$ e $\mathbf{\Psi}$, encontrando-se então as estimativas de máxima verossimilhança destes parâmetros. De acordo com Bollen (1989a), estes estimadores são consistentes, invariantes, assintoticamente não-viciados, assintoticamente eficientes e com distribuição assintoticamente normal. Além disso, sob a hipótese de que $\mathbf{\Sigma} = \mathbf{\Sigma}(\boldsymbol{\theta})$ (ou seja, que as estimativas obtidas realmente refletem os verdadeiros valores populacionais das correlações, e que portanto o modelo está correto), vale que a função F_{ML} descrita acima, multiplicada por $N - 1$, converge para uma distribuição qui-quadrado:

$$(N - 1)F_{ML} \sim \chi^2\left(\frac{1}{2}(p + q)(p + q + 1) - t\right),$$

em que t é o número de parâmetros livres no vetor $\boldsymbol{\theta}$, descrito no Item 2.3.4.

Para uma amostra grande e com a hipótese da normalidade multivariada das variáveis cumprida, este valor pode servir para testar o ajuste global do modelo.

3.1.2 Método de mínimos quadrados generalizados (GLS)

A função de mínimos quadrados generalizados tem como objetivo minimizar a diferença entre os valores observados em $\mathbf{S}$ e em $\mathbf{\Sigma}(\boldsymbol{\theta})$. A função de GLS é dada pela seguinte expressão:

$$F_{GLS} = \frac{1}{2}tr(\{[\mathbf{S} - \mathbf{\Sigma}(\boldsymbol{\theta})]\mathbf{W}^{-1}\}^2),$$

em que as notações de traço e determinante são conforme descrito no item anterior, e a matriz $\mathbf{W}_{(k \times k)}^{-1}$ é uma matriz de pesos para os resíduos, que converge em probabilidade para uma matriz positiva-definida. Minimizando-se a função acima, obtêm-se os estimadores de mínimos quadrados generalizados para os parâmetros do modelo.

A escolha mais comum para a matriz de pesos $\mathbf{W}$ é $\mathbf{W} = \mathbf{S}$, o que leva à obtenção de estimadores consistentes, eficientes e com distribuição assintoticamente normal multivariada. Além disso, com esta escolha da matriz de pesos obtém-se também uma distribuição para o estimador $(N - 1)F_{GLS}$ idêntica à obtida no caso da F_{ML} , isto é,

$(N - 1)F_{GLS} \sim \chi^2(\frac{1}{2}(p + q)(p + q + 1) - t)$ (novamente, dada a suposição de que o modelo está correto).

Sob a suposição de normalidade multivariada, tanto o estimador de máxima verossimilhança quanto o de mínimos quadrados generalizados são ótimos, por serem mais precisos em grandes amostras.

3.1.3 Método de mínimos quadrados não-ponderados (ULS)

A função de discrepância de mínimos quadrados não-ponderados é um caso particular da F_{GLS} , no caso em que $\mathbf{W} = \mathbf{I}$. Logo, ela pode ser escrita a partir da seguinte expressão:

$$F_{ULS} = \frac{1}{2}tr[\{\mathbf{S} - \mathbf{\Sigma}(\boldsymbol{\theta})\}^2].$$

Minimizando-se a função acima, obtêm-se os estimadores de mínimos quadrados não-ponderados para os parâmetros do modelo.

Esta função basicamente consiste em minimizar a soma dos quadrados dos resíduos do modelo, e produz estimadores consistentes sem a suposição de distribuição normal multivariada. Entretanto, seus estimadores não são os assintoticamente mais eficientes e não é possível avaliar para ela o teste qui-quadrado (Bistaffa, 2010).

A ponderação imposta sobre a matriz de resíduos é o único fator que diferencia F_{GLS} de F_{ULS} .

3.1.4 Outros métodos

Existem diversas outras formas de se estimar os parâmetros do modelo. Apenas para mencionar as principais delas, duas possibilidades são utilizar as funções de mínimos quadrados ponderados (WLS), ou então mínimos quadrados ponderados diagonalmente (DWLS). Elas não permitem a realização do teste qui-quadrado, mas também não supõem a normalidade multivariada e ainda assim são assintoticamente eficientes. Ou ainda pode-se utilizar a função de mínimos quadrados generalizados assintoticamente sem distribuição (ADF - Browne, 1982), ou a função de mínimos quadrados generalizados de Muthén (1978,

1984), também chamada de metodologia de variáveis categóricas (CVM), mas indicados para casos com indicadores categóricos, conforme descrito na seção a seguir.

3.1.5 Suposições sobre a distribuição dos dados

Geralmente, as técnicas consideram que as variáveis do modelo são quantitativas. Em alguns trabalhos encontram-se indicadores categóricos ordinais (por exemplo, variáveis medidas na escala Likert), muitas vezes sendo tratados como variáveis contínuas. Muthén e Kaplan (1985) registram que, se a curtose e a assimetria destas variáveis forem baixas, ainda assim é possível obter bons resultados com as técnicas ML e GLS. Se pelo menos uma das duas medidas for mais alta, mas as correlações entre as variáveis forem baixas, o viés ainda não será tão grande; caso sejam altas, as estimativas obtidas por ML e GLS não ficam tão distorcidas (e o problema diminui com o aumento da amostra), mas são impactadas as estimativas dos erros e da estatística qui-quadrado. Neste caso, as técnicas ADF e CVM (mencionadas na seção anterior) tendem a apresentar melhores resultados.

Johnson e Creech (1983) acrescentam que, nestes casos, podem também surgir correlações entre os erros das variáveis e dos fatores, principalmente para casos de indicadores com poucas categorias (até 3). Uma sugestão do autor é utilizar como medida de correlação a correlação policórica, estudo realizado por Bistaffa (2010).

Entretanto, Babakus et al. (1987) coloca que a correlação policórica, apesar de produzir melhores resultados com relação à acurácia dos parâmetros e da estimativa dos erros padrão, produz estatísticas de qualidade de ajuste ruins, podendo levar à rejeição de um modelo corretamente especificado. Isto pode representar um paradoxo para o pesquisador, que para os modelos melhores ajustados obtém piores estatísticas de qualidade de ajuste (existem outros casos em que um modelo corretamente especificado pode levar a índices de qualidade de ajuste ruins, como será visto nos resultados deste trabalho, no Capítulo 4). Baseando-se neste comentário, no Capítulo 4 as simulações realizadas para avaliar a sensibilidade das medidas de qualidade de ajuste a perturbações na amostra levaram em conta também as estimativas obtidas em cada caso.

A estimação de modelos de SEM envolvendo variáveis categóricas não fazem parte do

escopo deste trabalho. Entretanto, mais detalhes podem ser encontrados em Skrondal e Rabe-Hesketh (2005), Bistaffa (2010), e, para um exemplo prático, Bartolo (2000).

Já com relação à suposição da distribuição das variáveis quantitativas, a maioria das técnicas supõe distribuição normal, mas uma parte delas é robusta à não-normalidade. Melhado (2004) sugere que, neste caso, pode-se utilizar os métodos de ML, GLS ou WLS; e que, se a amostra for pequena, o uso de WLS pode não ser adequado (e portanto seria melhor utilizar algum dos outros dois métodos), pois a matriz de covariância assintótica das variâncias e covariâncias amostrais não seria estimada de forma acurada. Neste caso, as funções de ML e GLS ainda poderiam ser avaliadas. Já Bistaffa (2010) coloca que estas duas funções só serviriam neste caso se os dados não possuírem curtose excessiva.

Se a amostra for grande, Bollen (1989a) afirma que a suposição de normalidade dos dados pode ser relaxada.

Outra opção seria utilizar uma técnica que não supõe a normalidade dos dados, como a ADF. Entretanto, segundo Pilati e Laros (2007), a ML apresenta algumas vantagens relevantes, como a facilidade do processamento estatístico e tamanho reduzido da amostra, além da possibilidade de estabelecimento de diversos índices de qualidade do ajuste.

Bistaffa (2010) resume que a não-normalidade dos dados não afeta a consistência dos estimadores de ML, GLS e ULS, mas que a curtose excessiva acaba por eliminar a eficiência assintótica e inviabilizar os testes estatísticos para os parâmetros e para o ajuste do modelo. Desta forma, o autor sugere 1- que sejam testadas a normalidade e o nível de curtose dos dados para averiguar a validade das estimativas obtidas por estes três estimadores; 2- que sejam utilizados os estimadores WLS ou DWLS para casos de não-normalidade, dado que estes não perdem sua eficiência sob esta condição; ou ainda que 3- as variáveis não-normais sejam transformadas ou que seja aplicado *bootstrap* ou *jackknife* e seja aplicado algum teste não-paramétrico sobre a nova amostra.

3.1.6 Suposições sobre as relações entre os fatores e seus indicadores

Usualmente, nos modelos de SEM os indicadores são reflexivos, isto é, são causados pelos constructos com que se relacionam. Entretanto, dependendo do estudo pode fazer mais sentido que o indicador seja formativo, isto é, seja uma das causas da variável latente.

Algumas pessoas, ao utilizar a técnica, acreditam que a mudança não apresenta impacto sobre o modelo. Entretanto, na verdade esta alteração afeta profundamente tanto a estimativa do parâmetro da variável indicadora em questão quanto também pode afetar a das demais.

Bollen (1984) explica que esta simples mudança pode ter sérias implicações. Uma delas é que, na análise fatorial usual (em que os indicadores são reflexivos), uma das análises realizadas para escolher quais indicadoras serão utilizadas para estimar cada fator é baseada nas correlações entre variáveis que medem a mesma variável latente. Mas, com a presença de indicadores formativos, o autor explica que esta análise perde o sentido, e que fatores com significado importante podem ser desconsiderados da análise por terem correlação baixa ou negativa com outros indicadores designados para medir o mesmo constructo, mas que na verdade são formativos.

Bollen e Lennox (1991) mostram também que até mesmo conceitos considerados verdadeiros do ponto de vista de medidas podem ser válidos para indicadores formativos, mas não para reflexivos (como por exemplo a de que a correlação de indicadores de um mesmo constructo deve ser maior do que a de indicadores de diferentes constructos).

Sanches (2005) faz uma análise aprofundada dos impactos de se realizar esta inversão de especificação. Nas simulações realizadas no Capítulo 4 ela também será analisada.

3.2 Qualidade de ajuste

Para verificar a qualidade do ajuste do modelo, é necessário realizar duas verificações:

1. se os valores estimados para os parâmetros fazem sentido (com relação ao sinal, se é necessário fixar limites para o valor, etc);

2. o ajuste geral do modelo: o quão boa está a aderência dos valores estimados aos dados realizados. Para isso, é avaliada a seguinte hipótese de interesse: $H_0 : \Sigma - \Sigma(\theta) = \mathbf{0}$, observando-se $\mathbf{S}$ (matriz de covariâncias amostrais, que é conhecida) ao invés de Σ , e $\Sigma(\hat{\theta})$, ou seja, a matriz de covariância $\Sigma(\theta)$ estimada no ponto que minimiza a função de discrepância utilizada. (Para simplificar a notação, a partir daqui esta matriz será denominada $\hat{\Sigma}$).

Baseando-se nesta hipótese, serão apresentadas na Seção 3.2.2 algumas medidas que ajudam a avaliar a qualidade do ajuste geral do modelo de SEM. Antes disso, na Seção 3.2.1 serão listados alguns procedimentos para avaliar a qualidade dos valores estimados.

3.2.1 Avaliação dos parâmetros estimados

Para garantir que o modelo seja válido, é importante analisar fatores como o sinal e a amplitude dos valores estimados para os parâmetros, ou ainda se ele é possível de ocorrer na população em estudo. Além disso, em casos de estudos confirmatórios é sempre interessante comparar os valores estimados com aqueles que seriam esperados baseando-se na teoria; uma discrepância muito grande pode indicar, por exemplo, que faltam parâmetros no modelo ou que alguma especificação pode estar inadequada.

Outros sinais de que o modelo pode ter sido especificado incorretamente podem ser verificados nas estimativas dos parâmetros: erros-padrão altos para algumas variáveis, correlações fora do intervalo $[-1, 1]$, variâncias negativas ou não significantes.

Outros fatores que podem causar estranhezas como as indicadas acima podem ser mencionados: amostra não-representativa da população de interesse, presença de *outliers* na amostra, dentre outros.

Uma medida que ajuda a avaliar o ajuste dos indicadores do modelo é o coeficiente de correlação múltipla, dado pela expressão abaixo:

$$R_{X_i}^2 = 1 - \frac{Var(\delta_i)}{\hat{\sigma}_{ii}},$$

em que δ_i é o erro associado ao indicador X_i e $\hat{\sigma}_{ii}$ é sua variância estimada. Não existem

valores de referência para $R_{X_i}^2$, mas espera-se que ele seja alto, ou seja, que o erro padrão da variável X_i seja explicado pelo erro aleatório associado à sua medida.

3.2.2 Avaliação do ajuste geral do modelo

Baseando-se na hipótese descrita no início desta seção, algumas medidas de ajuste podem ajudar a avaliar o ajuste do modelo de forma geral.

O objetivo deste trabalho reside em verificar como estas medidas respondem a diferentes perturbações que podem ocorrer na amostra ou na especificação do modelo; logo, será reservado um espaço para descrever as medidas que serão estudadas. Os resultados obtidos encontram-se no Capítulo 4.

Resíduos

Sob a hipótese de interesse mencionada anteriormente, espera-se que a diferença entre a matriz de covariância observada e a estimada pelo modelo seja o mais baixa possível. A diferença entre estas duas matrizes é dada pela matriz de resíduos do modelo, cujos elementos são $v_{ij} = s_{ij} - \hat{\sigma}_{ij}$ (em que os s_{ij} são os elementos de $\mathbf{S}$ e os $\hat{\sigma}_{ij}$, os de $\hat{\Sigma}$). O modelo ideal é aquele em que os resíduos valem 0.

Uma medida utilizada para avaliar a grandeza dos resíduos é a raiz do quadrado médio residual (RMR), que é dada pela raiz do quadrado médio dos elementos da diagonal principal e abaixo dela da matriz residual:

$$RMR = \left[2 \sum_{i=1}^k \sum_{j=1}^i \frac{v_{ij}^2}{k(k+1)} \right]^{\frac{1}{2}} = \left[2 \sum_{i=1}^k \sum_{j=1}^i \frac{(s_{ij} - \hat{\sigma}_{ij})^2}{k(k+1)} \right]^{\frac{1}{2}}.$$

Quanto menor o RMR, melhor será considerado o ajuste.

Outra possibilidade é utilizar o resíduo normalizado, que atenua o efeito que o tamanho da amostra e as escalas das variáveis podem ter sobre a avaliação da qualidade de ajuste. Ele é dado pela expressão abaixo:

$$E_{ij} = \frac{v_{ij}}{\left[\frac{(\hat{\sigma}_{ii}\hat{\sigma}_{jj} + \hat{\sigma}_{ij}^2)}{N} \right]^{\frac{1}{2}}}.$$

Esta medida é sugerida por Jöreskog e Sörbom (1988). Os autores indicam que, se existirem muitos resíduos padronizados com módulo maior do que 2 ou 3, há indicativos de mal especificação do modelo. Assim, ao contrário do que ocorre quando são utilizados os resíduos calculados diretamente, os resíduos normalizados não apenas ponderam sua medida pelo tamanho amostral quanto também padronizam a influência de variáveis com diferentes escalas.

Teste qui-quadrado

Conforme apresentado na Seção 3.1, as estatísticas F_{ML} e F_{GLS} possuem distribuição assintoticamente qui-quadrado com $(\frac{1}{2}(p + q)(p + q + 1) - t)$ graus de liberdade (esta afirmação também vale para a F_{WLS} , mencionada naquela seção).

Este fato pode ser usado para testar a hipótese de interesse, isto é, $H_0 : \Sigma - \Sigma(\theta) = 0$. Bistaffa (2010) menciona que, como o objetivo aqui é não rejeitar a hipótese nula, utilizam-se para este teste valores de significância mais altos, como 5% ou 10%. O objetivo é não rejeitar a hipótese.

Este teste possui, sobre a utilização dos resíduos para se avaliar a qualidade do ajuste do modelo, a vantagem de avaliar simultaneamente se todos os resíduos são próximos de zero, e não se cada um deles individualmente é alto.

As suposições do teste (Jöreskog e Sörbom, 1988) são que: 1- o tamanho amostral é suficientemente grande para que ocorra a convergência da distribuição da estatística F (mas, por outro lado, uma amostra grande demais pode aumentar a sensibilidade do teste a ponto de rejeitar H_0 devido a diferenças inexpressivas); 2- a curtose e a assimetria das variáveis são próximas às da distribuição normal; e 3- utiliza-se para o ajuste do modelo a matriz de covariância (outra possibilidade seria a matriz de correlações, o que diminui a acurácia da estatística do teste).

Medidas alternativas

Hoje, não existe nenhuma medida considerada ideal para se medir, ao mesmo tempo, se um modelo de SEM está bem ajustado, é parcimonioso e significativamente melhor

do que um modelo inferior (para esta última afirmação, compara-se o modelo com um modelo "baseline", que é um modelo que considera-se que possui ajuste ruim. Geralmente, utilizam-se como "baseline" modelos em que supõe-se a existência de uma variável latente por indicador, que tanto os erros quanto os constructos são não correlacionados entre si e que os parâmetros que ligam as variáveis latentes aos seus indicadores valem todos 1. Tais modelos possuem estrutura amarrada e supõem independência dos constructos e dos indicadores; caso as relações supostas pelo modelo do estudo sejam válidas, seu ajuste deve ficar muito melhor do que o do modelo "baseline").

Existem na literatura alguns indicadores que servem para avaliar simultaneamente tais fatores. Seu comportamento frente a diferentes perturbações na amostra será, conforme estudado anteriormente, alvo deste trabalho.

Segue abaixo um resumo das diferentes medidas que serão estudadas. A lista de indicadores foi principalmente baseada no trabalho de Melhado (2004). A notação utilizada será F_m para a função de ajustamento do modelo em questão (dado o método de estimação), e F_b a mesma função calculada para o modelo "baseline"; além disso, g_{lm} e g_{lb} são os respectivos números de graus de liberdade das distribuições qui-quadrado de $(N - 1)F_m$ e $(N - 1)F_b$.

1- Discrepância mínima da amostra ($\hat{C}$) - Bentler e Bonett (1980)

$$\hat{C} = N\hat{F},$$

em que N é o tamanho amostral. Esta medida não possui valor de referência, ou seja, é uma medida relativa; assim, ela é calculada para o modelo em questão, o modelo "baseline" e o modelo saturado, e os resultados são comparados (lembrando que quanto melhor o ajuste, menor seu valor). Esta medida é interessante porque compõe outros indicadores de qualidade de ajuste, como o RMSEA, AIC e CAIC (que serão descritos adiante).

2- Índice de ajuste normalizado (NFI) - Bentler e Bonett (1980)

$$NFI = \frac{F_b - F_m}{F_b} = \frac{\chi_b^2 - \chi_m^2}{\chi_b^2}.$$

O NFI avalia a redução na função de ajustamento quando se passa do modelo "baseline" para o modelo em questão. Caso o modelo do estudo esteja bem ajustado, $F_m = 0$ e $NFI = 1$. Caso seu ajuste seja tão ruim quanto o do modelo "baseline", $F_m = F_b$ e $NFI = 0$.

Ou seja, $0 \leq NFI \leq 1$, e quanto mais próximo de 1 ele for, melhor.

Limitações: ele é sensível ao acréscimo de parâmetros no modelo, e tende a sinalizar melhores ajustes conforme a amostra aumenta.

3- Índice de ajuste corrigido (IFI) - Bollen (1989b)

$$IFI = \frac{F_b - F_m}{F_b - [\frac{gl_m}{(N-1)}]} = \frac{\chi_b^2 - \chi_m^2}{\chi_b^2 - gl_m}.$$

Este índice visa corrigir as discrepâncias relativas ao tamanho da amostra ou à quantidade de parâmetros que podem ocorrer com o NFI. Ele não necessariamente varia entre 0 e 1, e valores muito maiores que 1 podem indicar superajuste. A tendência é que ele se aproxime de 1 quando o modelo for válido, e que se aproxime de NFI quando a amostra for grande.

4- Qui-quadrado relativo

O qui-quadrado relativo ou ponderado (*chisq_rel*) consiste na estatística qui-quadrado χ_m^2 (utilizada para realizar o teste descrito anteriormente nesta seção), dividida pelos seus graus de liberdade. Campana et al. (2009) propõe para os seus valores a seguinte classificação: valores inferiores a 1 indicam um ajuste pobre; valores acima de 5 indicam necessidade de ajuste. O valor aceitável deve ser igual ou menor a 5.

$$chisq\_rel = (\chi_m^2 / gl_m).$$

5- Índice de ajuste relativo (RFI) - Bollen (1986)

$$RFI = \frac{(F_b/gl_b) - (F_m/gl_m)}{F_b/gl_b} = \frac{(\chi_b^2/gl_b) - (\chi_m^2/gl_m)}{(\chi_b^2/gl_b)}$$

Aqui, a redução na função de ajustamento ao se passar do modelo "baseline" ao modelo proposto é relativizada pelos respectivos graus de liberdade. Logo, ele não é afetado pela adição de parâmetros, e detecta quando, dentre dois modelos com funções de ajustamento semelhantes, um é mais parcimonioso. Na prática, $0 \leq RFI \leq 1$, e quanto mais próximo de 1 ele for, melhor.

Entretanto, esta medida é afetada pelo tamanho da amostra.

6- Índice de ajuste comparativo (CFI) - Bentler (1990)

$$CFI = 1 - \frac{\max(NF_m - gl_m, 0)}{\max(NF_b - gl_b, 0)}.$$

Esta é uma modificação do NFI em que o tamanho da amostra permanece na expressão. Este também é um índice que varia entre 0 e 1, e valores mais próximos de 1 indicam melhor ajuste.

7- Índice de Tucker-Lewis (TLI) - Tucker e Lewis (1973)

$$TLI = \frac{(F_b/gl_b) - (F_m/gl_m)}{(F_b/gl_b) - [1/(N-1)]} = \frac{(\chi_b^2/gl_b) - (\chi_m^2/gl_m)}{(\chi_b^2/gl_b) - 1}.$$

Assim como o IFI com relação ao NFI, este índice visa corrigir as discrepâncias relativas ao tamanho da amostra que podem ocorrer com o RFI. Ele não necessariamente varia entre 0 e 1, e valores muito maiores que 1 podem indicar superajuste, enquanto que valores muito menores que 1 indicam que o modelo necessita ser reespecificado. Novamente, a tendência é que ele se aproxime de 1 quando o modelo for válido, e que se aproxime de RFI quando a amostra aumentar.

8- Índice de qualidade do ajuste (GFI) e Índice da qualidade do ajuste corrigido (AGFI) - Jöreskog e Sörbom (1986)

Estes índices possuem expressões diferentes, dependendo se são calculados a partir de F_{ML} ou de F_{ULS} :

$$GFI_{ML} = 1 - \frac{tr[(\hat{\Sigma}^{-1}\mathbf{S} - \mathbf{I})^2]}{tr[(\hat{\Sigma}^{-1}\mathbf{S})^2]},$$

$$AGFI_{ML} = 1 - [\frac{k(k+1)}{2gl_m}][1 - GFI_{ML}],$$

$$GFI_{ULS} = 1 - \frac{tr[(\mathbf{S} - \hat{\Sigma})^2]}{tr(\mathbf{S}^2)},$$

$$AGFI_{ULS} = 1 - [\frac{k(k+1)}{2gl_m}][1 - GFI_{ULS}],$$

em que $k = p+q$.

O GFI mede quanto da variabilidade em $\mathbf{S}$ é predita por $\hat{\Sigma}$, e AGFI corrige o GFI pelos graus de liberdade relativos ao número de variáveis. Geralmente os dois são maiores que 0, e valem no máximo 1 (no caso de ajuste perfeito, isto é, $\mathbf{S} = \hat{\Sigma}$).

Outras expressões para o GFI calculado a partir de métodos de estimação como o WLS e o DWLS podem ser vistas na referência original, e para o GLS em Tanaka e Huba (1985).

9- Índice de qualidade do ajuste de parsimônia (PGFI) - Mulaik et al. (1989)

$$PGFI = GFI \frac{2gl_m}{k(k+1)},$$

com k definido anteriormente.

É uma medida que também avalia a parcimônia do modelo, isto é, o impacto da adição de parâmetros. Geralmente, ele é utilizado de forma relativa para comparar dois modelos (sendo que este índice varia entre 0 e 1, e será mais ajustado o modelo com a medida mais próxima de 1).

10- Índice de ajuste normalizado de parsimônia (PNFI) - James et al. (1982)

$$PNFI = NFI \frac{gl_m}{gl_b}.$$

Esta também é uma medida que considera a parcimônia do modelo, mas dessa vez efetuando uma correção sobre o NFI. Mais uma vez, quanto maior o valor deste índice melhor o ajuste do modelo; ele também é mais utilizado de forma relativa (principalmente para comparar modelos com diferentes números de parâmetros).

11- Raiz do erro quadrático médio de aproximação (RMSEA) - Steiger e Lind (1980)

$$RMSEA = \sqrt{\frac{\hat{F}_0}{gl_m}},$$

com $\hat{F}_0 = \max(\frac{\hat{C} - gl_m}{N}, 0)$.

Steiger e Lind (1980) consideram para esta medida uma regra de decisão, na qual valores abaixo de 0,05 indicam um bom ajuste, entre 0,08 e 0,10 um ajuste razoável e acima de 0,10, um ajuste ruim para o modelo.

Ultimamente, o RMSEA tem sido considerado como um dos critérios mais informativos para ajuste de modelos estruturais (Sanches, 2005).

12- Critério da informação de Akaike (AIC) - Akaike (1974)

$$AIC = \hat{C} + 2t,$$

em que t é o número de parâmetros livres do modelo, descrita no Item 3.1.1, e $\hat{C}$ é a discrepância mínima do modelo, conforme descrito no Item 1 desta subseção. Valores baixos de AIC indicam um melhor ajuste do modelo.

13- Critério da informação de Akaike consistente (CAIC) - Bozdogan (1987)

$$CAIC = \hat{C} + t(\ln(N) + 1),$$

em que t e $\hat{C}$ são os mesmos descritos no AIC. Este também é um indicador que valoriza a parcimônia do modelo, e indicará um melhor ajuste do mesmo quanto menor for.

Finalmente, uma medida que não será empregada neste trabalho mas que vale a pena ser mencionada é o Critério Bayesiano de Schwarz, ou SBC (Schwarz, 1978; Sclove, 1987). Este índice é similar ao AIC, e indica um menor ajuste quando assume menores valores.

3.3 Outras suposições e cuidados

Jöreskog (1969) escreve que sempre pode haver diversos outros constructos, além daqueles especificados no modelo pelo pesquisador, que exercem impacto sobre as variáveis do modelo mas que muitas vezes nem mesmo são conhecidos. Por outro lado, se forem adicionados parâmetros ao modelo ele pode ficar superajustado, o que piora a estabilidade do modelo quando utilizado no futuro e pode deteriorar a interpretação dos coeficientes das variáveis. O autor explica que esta questão de até onde incluir parâmetros pode ser estudada comparando-se o valor da estatística qui-quadrado ajustada com o número de graus de liberdade do modelo. Caso a estatística seja relativamente maior, isso pode ser uma indicação de que é possível extrair mais informação dos dados, ou seja, que mais parâmetros poderiam ser adicionados, seja na forma de indicadores ou de constructos. Por outro lado, se a estatística tiver um valor próximo ao do número de graus de liberdade, isso pode indicar sobreajuste. Mas o autor recomenda que as variáveis adicionadas do modelo provenham de uma análise teórica e da interpretação que o pesquisador faz dos dados.

Por fim, Kline (2010) levanta outros cuidados que costumam ser menos comentados em trabalhos relativos a SEM, mas que não podem deixar de ser mencionados: é importante verificar e tratar se há dados omissos (a partir de alguma técnica de imputação de dados), checar questões de homocedasticidade e de *outliers*. Apesar de terem uma menor influência sobre o processo de SEM, esses pressupostos também devem ser observados para que não impactem as estimativas dos parâmetros do modelo.

Capítulo 4

Simulações

Neste capítulo, serão demonstrados os resultados de simulações realizadas para avaliar o impacto de diferentes perturbações nas amostras de dois modelos diferentes de SEM nas medidas de ajuste dos mesmos.

O recurso computacional utilizado para realizar as simulações foi o *proc calis* do SAS (cuja documentação pode ser vista em SAS Institute Inc., 2010).

Nos dois exemplos, foram especificados diferentes modelos (3 no primeiro e 2 no segundo, considerando ou não que poderia haver correlação entre as variáveis). Estes modelos foram ajustados a diversas amostras, de diferentes tamanhos, que em cada caso sofriam perturbações em algumas variáveis (aumento da curtose, distribuição assimétrica ou com *outliers*) ou na especificação (inversão de relações causais, correlação entre indicadoras). Além disso, cada ajuste foi realizado a partir de dois métodos: Máxima Verossimilhança e Mínimos Quadrados Generalizados (com o propósito de verificar o desempenho dos indicadores de qualidade de ajuste obtidos para suas estimativas).

Os diferentes ajustes foram então comparados com aqueles realizados na amostra simulada na situação "normal" (simulada exatamente com as mesmas especificações supostas no modelo) para comparar as diferenças nas medidas de ajuste e também nos valores dos parâmetros estimados em cada caso.

Com estes resultados, foi analisada a resposta das diferentes medidas de ajuste às perturbações, de forma a tentar compreender que tipo de alterações em quais medidas

podem trazer indicações a respeito dos problemas, tanto na amostra (com relação ao modelo suposto), quanto na especificação do modelo.

As medidas de qualidade do ajuste utilizadas nas simulações foram as seguintes: GFI, AGFI, NFI, RFI, TLI, CFI, IFI, PGFI, RMSEA, PNFI, AIC, CAIC e `chisq_rel`. A análise para verificar em cada caso se houve impacto nas medidas de ajuste foi basicamente visual, mas, em linhas gerais, o critério utilizado baseia-se na seguinte escala: se houve mudança de até 10% no valor observado para a medida na situação "normal", considera-se que a situação analisada não causou impacto; entre 80 e 90%, baixo impacto; e mais de 80%, alto impacto. Para medidas que variavam numa escala maior o critério não foi seguido tão à risca. Na verdade, o raciocínio seguido em todos os casos foi o de se questionar se o valor observado era diferente o bastante do que seria esperado segundo a literatura para aquela medida, a ponto de, numa situação prática em que não houvessem valores de comparação, causar no pesquisador um incômodo a ponto de fazê-lo perceber que há algo que poderia ser melhorado na especificação do modelo.

Os códigos SAS das duas simulações encontram-se no Apêndice B.

4.1 Exemplo 1

Na primeira simulação foi utilizado um exemplo mais simples, similar a uma análise fatorial com blocos em que um fator explica um conjunto de indicadores, e os indicadores de um bloco não estão relacionados com os do outro.

A Figura 4.1 traz os diagramas de caminho das 3 especificações que foram ajustadas, a partir do procedimento `proc calis` do SAS, neste exemplo.

Estes modelos possuem apenas a parte de equações de mensuração, mas não a de equações estruturais. Matricialmente, o Exemplo 1 fica da seguinte forma:

Equação de mensuração:

$$\mathbf{x} = \mathbf{\Lambda}_x \boldsymbol{\xi} + \boldsymbol{\delta}$$

Figura 4.1: Diagramas de caminho para os modelos ajustados no Exemplo 1

Variáveis:

$$\mathbf{x} = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \end{bmatrix}, \quad \boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \end{bmatrix}, \quad \boldsymbol{\xi} = \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix}$$

Parâmetros:

$$\boldsymbol{\Lambda}_{\mathbf{x}} = \begin{bmatrix} \lambda_{11} & 0 \\ \lambda_{21} & 0 \\ \lambda_{31} & 0 \\ 0 & \lambda_{42} \\ 0 & \lambda_{52} \\ 0 & \lambda_{62} \end{bmatrix}, \quad \boldsymbol{\Theta}_{\boldsymbol{\delta}} = \begin{bmatrix} \theta_{11} & 0 & 0 & \dots & 0 \\ 0 & \theta_{22} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & \theta_{66} \end{bmatrix}, \quad \boldsymbol{\Phi} = \begin{bmatrix} \phi_{11} & 0 \\ 0 & \phi_{22} \end{bmatrix}$$

O Modelo 2 possui uma forma matricial similar. O que muda é a matriz de covariância dos indicadores, que pode ser escrita como abaixo:

$$\Theta_{\delta} = \begin{bmatrix} \theta_{11} & \theta_{12} & \theta_{13} & 0 & 0 & 0 \\ & \theta_{22} & \theta_{23} & 0 & 0 & 0 \\ & & \theta_{33} & 0 & 0 & 0 \\ & \vdots & & \theta_{44} & \theta_{45} & \theta_{46} \\ & & & & \theta_{55} & \theta_{56} \\ & & & \dots & & \theta_{66} \end{bmatrix}$$

Já no Modelo 3, a mudança com relação ao Modelo 1 ocorre na matriz de covariância dos fatores:

$$\Phi = \begin{bmatrix} \phi_{11} & \phi_{12} \\ \phi_{12} & \phi_{22} \end{bmatrix}$$

Para verificar se os 3 modelos acima são identificáveis (ou se era necessário fixar algum dos parâmetros), foram aplicados os passos descritos na Seção 2.5. Inicialmente foi aplicada a Regra t. Tem-se que, nos 3 casos, $p = 0$ e $q = 6$; portanto, $\frac{1}{2}(p+q)(p+q+1) = 21$. Contando os parâmetros de cada especificação (que não foram fixados nas definições acima), obtêm-se os valores de t de cada modelo: 14, 20 e 15, respectivamente. Logo, nos três casos verifica-se que $t \leq \frac{1}{2}(p+q)(p+q+1)$, o que é uma condição necessária para a identificabilidade.

Em seguida, foi aplicada a Regra 2 Passos. Como no modelo não há variáveis latentes, é necessário cumprir apenas a primeira etapa, em que se verifica a identificabilidade das equações de mensuração.

Os modelos não possuem variáveis observadas endógenas, e portanto não é necessário reaplicar a Regra t supondo que elas fossem exógenas; passa-se diretamente para a próxima etapa. De maneira direta, verifica-se que a Regra 3 Indicadores é válida para os Modelos 1 e 3, o que é uma condição suficiente para que as equações de mensuração de ambos (e portanto estes modelos na totalidade) sejam identificáveis. Já para o Modelo 2 não é possível cumprir nenhuma das condições suficientes para verificar este fato. Portanto,

Tabela 4.1: Descrição das situações aplicadas sobre as amostras nas quais foram ajustados os Modelos 1 a 3 do Exemplo 1.

Situações	Cenários	Criação do cenário
"normal"	Relações causais análogas ao Exemplo 1, sem correlações entre nenhuma das variáveis; variáveis com distribuição normal.	
"coutliers1"	Semelhante à situação "normal", mas com <i>outliers</i> na variável X_3 .	Multiplicar X_3 por 100 com probabilidade 0,5%.
"coutliers2"	Com <i>outliers</i> na variável X_6 .	Multiplicar X_6 por 100 com probabilidade 5%.
"cassim1"	Com assimetria na variável X_3 .	Simular X_3 a partir de erro com distribuição exponencial(1).
"cassim2"	Com assimetria nas variáveis X_3 e X_6 .	Simular X_3 e X_6 a partir de erros com distribuição exponencial(1).
"ccorrel1"	Com correlação entre as variáveis X_5 e X_6 .	Ao simular X_6 , somar ao seu erro aleatório o erro simulado para X_5 .
"relac"	Invertendo a relação causal entre X_3 e ξ_1 .	Efetuar as simulações com X_3 causando ξ_1 , e não o contrário.

não é possível verificar, por este método, se o Modelo 2 é identificável. Apenas para fins da simulação, foi possível ajustar o modelo na amostra simulada com as especificações corretas, e os parâmetros foram estimados conforme esperado.

Após definidos os modelos que foram ajustados aos dados, falta definir os tipos de alterações realizadas sobre as características das amostras a que eles foram aplicados. A Tabela 4.1 traz um resumo das características para cada situação.

É importante mencionar a escolha das situações utilizadas no estudo mantendo em mente que os modelos são compostos de 2 "blocos". Algumas das perturbações causavam impacto apenas nas medidas de qualidade de ajuste, mas não nas estimativas dos parâmetros; outras impactavam apenas as estimativas do "bloco" ao qual a variável perturbada pertencia, enquanto que outros impactavam as estimativas de todo o modelo. Logo, de forma a realizar investigações referentes a tal variação, algumas perturbações foram aplicadas primeiro a uma variável, e depois a outra de outro bloco ou então a duas (uma de cada bloco).

Também vale comentar a situação "relac", que inverte a relação causal entre uma das variáveis e sua indicadora. Esta relação poderia ter sido invertida no ajuste do modelo, o que mudaria a maneira de ajustá-lo e interpretá-lo (Sanches, 2005); entretanto, como o erro mais comum cometido na utilização de SEM é supor o modelo de análise fatorial tradicional em situações em que na verdade é a variável observada que influencia o constructo, e não o contrário, decidiu-se que impactar a amostra traria um resultado de maior utilidade prática.

As amostras na situação "normal" foram simuladas com os seguintes valores de parâmetros: $\lambda_{11} = 1,0$; $\lambda_{21} = 0,5$; $\lambda_{31} = 1,3$; $\lambda_{42} = 1,0$; $\lambda_{52} = 0,8$; $\lambda_{62} = 1,9$.

• Tamanho da amostra

Além de impactar a amostra de diferentes formas e ajustar três modelos a partir de dois métodos de estimação distintos, nesta simulação também foi variado o tamanho da amostra, para avaliar sua participação nos resultados obtidos. Para obter resultados robustos, foram geradas 5.000 amostras de cada tipo, dentre as diferentes situações apresentadas na Tabela 4.1, e por tamanho - 15, 30, 100 e 1000. Os tamanhos 15, 30 e 100 foram escolhidos por se aproximarem dos tamanhos de amostras de estudos em que tipicamente se aplica a técnica de SEM. Já as amostras de tamanho 1000 servem para investigar o efeito dos impactos estudados sem que houvesse dúvidas, caso o ajuste não ficasse bom, de que isso foi causado pelos mesmos e não porque a amostra não era grande o suficiente.

O tamanho amostral 1000, apesar de atípico em situações em que se aplica SEM, foi escolhido baseado na afirmação de Hair et al. (2010) de que, para avaliar o impacto da má especificação de um modelo, é necessário tomar uma amostra maior do que a que seria suficiente se o modelo estivesse bem especificado.

Sumarizaram-se os resultados observados (tanto das medidas de qualidade de ajuste quanto das estimativas dos parâmetros) tomando-se os valores mínimo, médio e máximo das estimativas obtidas, e os desvios padrões. Tal análise foi realizada para poder observar tanto o comportamento médio quanto a dispersão dos dados em cada situação. É com estas medidas sumarizadas que todas as análises a seguir serão realizadas.

Desta forma, a Tabela 4.2 traz os valores obtidos para os parâmetros $\lambda_{11}, \dots, \lambda_{62}$ para todas as amostras simuladas para a situação "normal", com o ajuste do Modelo 1 pelo método ML (os resultados obtidos a partir do método de estimação GLS não serão apresentados aqui, dado que em geral eles foram muito parecidos com os obtidos para ML; mas eles se encontram no Apêndice A. Quando houver alguma diferença notável, eles serão descritos no texto). A partir da tabela, é possível observar que o tamanho da amostra impacta fortemente as estimativas obtidas (principalmente a das variâncias dos parâmetros), no caso das amostras menores. Na amostra de tamanho 100 as estimativas não estão tão distorcidas na média, mas apresentam desvios consideráveis a este valor nas amostras simuladas. Os resultados da literatura descritos na Seção 3.1.5 pareciam indicar que estes métodos de estimação seriam mais robustos a tamanhos amostrais reduzidos do que o observado aqui.

Tabela 4.2: Estimativas dos parâmetros do ajuste do Modelo 1 para a situação "normal", por Máxima Verossimilhança, no Exemplo 1.

Tamanho da amostra		15				30				100				1000				Valores simulados
Medida		média	desvp	min	max	média	desvp	min	max	média	desvp	min	max	média	desvp	min	max	
Estimativas	lambda11	1,02	0,81	-9,22	6,00	0,95	0,60	-16,07	6,26	0,92	0,19	-1,90	5,73	0,99	0,02	0,78	1,06	1,00
	lambda21	0,41	0,67	-11,91	9,27	0,44	0,38	-9,31	6,35	0,47	0,15	-0,39	1,32	0,49	0,05	0,33	0,66	0,50
	lambda31	1,00	1,69	-34,04	17,48	1,08	1,28	-12,32	19,59	1,24	0,56	-4,88	12,42	1,29	0,12	0,92	1,89	1,30
	lambda42	0,87	0,45	-2,75	7,17	0,87	0,22	-1,78	3,25	0,95	0,08	0,42	1,33	0,99	0,01	0,88	1,01	1,00
	lambda52	0,69	0,61	-11,83	8,80	0,72	0,31	-3,63	3,51	0,77	0,16	0,25	1,66	0,80	0,05	0,64	0,98	0,80
	lambda62	1,57	1,57	-34,96	36,03	1,74	1,09	-17,08	27,37	1,84	0,33	0,85	4,27	1,89	0,11	1,56	2,35	1,90
	phi1	1,39	1,20	-2,87	8,93	1,29	1,01	-2,80	5,05	1,22	0,50	-2,55	3,23	1,03	0,12	0,64	1,61	1,00
	phi2	1,49	1,01	-3,84	5,48	1,34	0,69	-3,47	4,44	1,13	0,30	0,23	2,59	1,02	0,09	0,72	1,37	1,00
	theta1	-0,27	6,55	-62,72	40,50	0,67	3,88	-44,08	35,50	0,97	0,65	-22,17	20,79	1,00	0,09	0,63	1,34	1,00
	theta2	0,84	2,21	-59,49	35,75	0,98	0,97	-22,74	30,22	0,99	0,16	0,53	1,59	1,00	0,05	0,81	1,23	1,00
	theta3	0,32	9,12	-109,27	121,70	1,00	6,76	-48,61	56,53	1,00	2,25	-21,13	48,40	0,99	0,15	0,41	1,49	1,00
	theta4	0,59	3,10	-64,70	32,76	0,93	0,79	-33,85	22,16	0,98	0,21	-0,06	1,87	1,00	0,07	0,78	1,24	1,00
	theta5	0,87	1,67	-33,32	28,46	0,96	0,59	-16,44	30,79	0,99	0,17	0,38	1,65	1,00	0,05	0,81	1,21	1,00
	theta6	0,32	10,38	-174,41	140,82	0,84	5,97	-67,36	100,69	0,92	0,61	-2,75	2,69	1,00	0,18	0,31	1,62	1,00

Já na Tabela 4.3, é avaliado o comportamento das medidas de qualidade de ajuste frente a tais perturbações. Verifica-se que as medidas GFI, PGFI e PNFI parecem ser as medidas que mais mantiveram consistência nas amostras menores. Já as medidas AGFI e RFI perdem precisão, mas em média assumem valores menores nestas amostras; enquanto que NFI, CFI e IFI também perdem, mas em média têm um desempenho mais parecido ao obtido em amostras maiores. Deve-se assim tomar cuidado com estas medidas, já

que, conforme observado na Tabela 4.2, as estimativas não estão bem ajustadas nestas amostras pequenas, de forma que elas passam a ser pouco informativas ao indicar um ajuste tão bom quanto o observado nas amostras grandes.

É interessante notar para as medidas TLI, chisq_rel, AIC, CAIC e RMSEA que a diminuição do tamanho da amostra possibilita que elas assumam valores consideravelmente mais altos do que aqueles que chegam a ocorrer para amostras maiores; isto é, valores atipicamente altos para estas medidas não necessariamente são um forte indicativo de mal ajuste, quando se trabalha com amostras pequenas.

A Tabela A.2 no Apêndice A traz os resultados obtidos nas mesmas situações da Tabela 4.3, para quando se estima o modelo por mínimos quadrados generalizados. Notam-se inversões de comportamento médio para as medidas TLI, chisq_rel, IFI (que por este método parece ser bem menos informativa) e AIC (que passa a apresentar uma maior consistência).

Tabela 4.3: Medidas de qualidade de ajuste para a aplicação do Modelo 1 para a situação "normal", por Máxima Verossimilhança, no Exemplo 1.

Tamanho da amostra	GFI				AGFI				NFI				RFI				CFI			
	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	0,83	0,0007	0,65	0,98	0,48	0,0022	-0,04	0,94	0,68	0,0019	0,13	0,97	0,36	0,0037	-0,74	0,94	0,69	0,0019	0,12	0,98
30	0,91	0,0005	0,77	0,99	0,72	0,0015	0,31	0,97	0,82	0,0012	0,36	0,98	0,64	0,0023	-0,29	0,97	0,82	0,0012	0,35	0,99
100	0,97	0,0002	0,91	1,00	0,91	0,0005	0,74	0,99	0,94	0,0004	0,80	0,99	0,88	0,0008	0,61	0,99	0,94	0,0004	0,80	0,99
1000	1,00	0,0000	0,99	1,00	0,99	0,0001	0,97	1,00	0,99	0,0000	0,98	1,00	0,99	0,0001	0,95	1,00	0,99	0,0000	0,98	1,00

Tamanho da amostra	PGFI				PNFI				IFI				TLI				chisq_rel			
	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	0,39	0,0003	0,31	0,46	0,34	0,0009	0,06	0,48	0,85	0,0025	0,16	2,08	0,62	0,0183	-41,86	58,87	1,73	0,0116	0,13	6,69
30	0,42	0,0002	0,36	0,46	0,41	0,0006	0,18	0,49	0,94	0,0013	0,50	1,37	0,86	0,0034	-4,80	2,62	1,46	0,0098	0,12	5,16
100	0,45	0,0001	0,43	0,47	0,47	0,0002	0,40	0,50	0,99	0,0004	0,84	1,06	0,97	0,0008	0,67	1,14	1,33	0,0085	0,13	4,55
1000	0,47	0,0000	0,46	0,47	0,50	0,0000	0,49	0,50	1,00	0,0000	0,98	1,00	1,00	0,0001	0,96	1,01	1,30	0,0088	0,14	4,34

Tamanho da amostra	AIC				CAIC				RMSEA			
	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	-1,91	0,0810	-13,10	32,80	-13,86	0,0810	-25,05	20,84	0,20	0,0018	0,00	0,64
30	-3,76	0,0688	-13,19	22,11	-20,57	0,0688	-30,00	5,30	0,11	0,0012	0,00	0,38
100	-4,69	0,0596	-13,11	17,83	-29,93	0,0596	-38,35	-7,40	0,05	0,0006	0,00	0,19
1000	-4,91	0,0619	-13,02	16,40	-46,26	0,0619	-54,38	-24,95	0,01	0,0002	0,00	0,06

Uma forma de analisar a Tabela 4.3 é comparar os valores observados para as amostras menores com aqueles obtidos para as amostras de tamanho 1000, já que nem todas as medidas de ajuste têm um valor de referência.

Por isso, ao se estudar os efeitos de outras perturbações sobre o modelo nota-se que será necessário tomar um cuidado especial para controlar o que é efeito do tamanho da amostra, principalmente para as medidas RFI, AGFI, TLI, RMSEA e AIC (para estimação por ML). Assim, para não misturar o que vem a ser efeito das perturbações que serão realizadas com a perda de qualidade acusada pelas medidas conforme mostram as Tabelas 4.2 e 4.3, os estudos comparando as amostras com e sem alterações serão realizados, neste exemplo, sempre sobre a amostra de tamanho 1000.

- **Existência de *outliers***

As Figuras 4.2 e 4.3 trazem a comparação entre os resultados obtidos para as estimativas (por Máxima Verossimilhança) dos parâmetros das amostras simuladas em situações que envolviam a existência de *outliers*, "coutliers1" (*outliers* na variável X_3) e "coutliers2" (*outliers* na variável X_6). Nota-se, voltando a enxergar o modelo como possuindo dois "blocos", que o bloco que não possui variáveis com *outliers* é pouco afetado, enquanto que no bloco onde ela está, tanto a sua estimativa quanto a de sua variância são bastante aumentadas (e as outras variáveis do bloco acabam sendo um pouco afetadas também).

Foram realizadas simulações que colocavam duas variáveis com *outliers* ao mesmo tempo (tanto no mesmo bloco quanto uma em cada bloco). O resultado apresentou diferenças com relação ao que seria esperado - mesmo no caso em que as duas variáveis eram do mesmo bloco, o outro bloco era bastante afetado (ao contrário do que acontece no caso de apenas uma variável). Entretanto, na maioria das vezes as estimativas nesse exemplo não convergiam, e portanto os parâmetros não podiam ser estimados. Assim, um ponto a ser estudado futuramente é entender melhor o que acontece quando diversas variáveis do modelo possuem *outliers*.

Outro ponto é que a única diferença entre os resultados obtidos para cada um dos 3 modelos especificados foi que, no Modelo 2 (em que havia correlação entre os indicadores), o modelo ajustou parte da variância excessiva observada para a variável X_3 como se fosse correlação entre estas e outras variáveis do seu bloco. Mas este resultado foi menos marcante do que o verificado acima.

Figura 4.2: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "coutliers1" com tamanho $N=1000$, e os valores simulados, no Exemplo 1.

Figura 4.3: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "coutliers2" com tamanho $N=1000$, e os valores simulados, no Exemplo 1.

Os resultados obtidos estimando-se os modelos por GLS foram análogos.

Observa-se na Figura 4.4 o desempenho das diferentes medidas de qualidade do ajuste para as duas amostras simuladas com *outliers*, e para as três diferentes especificações

Figura 4.4: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "coutliers1", "coutliers2" e "normal", com tamanho $N=1000$, no Exemplo 1.

aplicadas (o agrupamento das medidas em diferentes quadros não tem nenhum objetivo além daquele de facilitar a visualização separando medidas de escalas distintas, tanto neste quanto nos demais gráficos análogos apresentados ao longo deste trabalho). Nota-se que a grande maioria das medidas de ajuste não aponta diferença entre os ajustes nas amostras das situações "normal" e com *outliers*; as exceções são as medidas RFI e TLI, embora o impacto seja pequeno. Na Figura A.1 do Apêndice A estão os resultados obtidos para as simulações por GLS; a única diferença é que as medidas RFI e TLI só são impactadas quando se aplica a especificação do Modelo 2.

• Assimetria

Nas Figuras 4.5 e 4.6 está a comparação entre os resultados obtidos para as estimativas dos parâmetros das amostras simuladas nas situações com assimetria nas variáveis, "cassim1" (com assimetria em X_3) e "cassim2" (com assimetria em X_3 e X_6 , ou seja, uma

variável de cada "bloco"). Elas foram muito pouco impactadas, permanecendo próximas aos valores simulados. Para GLS, foi obtido um resultado semelhante.

Figura 4.5: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "cassim1" com tamanho $N=1000$, e os valores simulados, no Exemplo 1.

Figura 4.6: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "cassim2" com tamanho $N=1000$, e os valores simulados, no Exemplo 1.

A Figura 4.7 mostra os valores das medidas de qualidade de ajuste quando se acrescenta

Figura 4.7: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "cassim1", "cassim2" e "normal", com tamanho N=1000, no Exemplo 1.

assimetria na amostra. Os resultados mostram que praticamente não houve impacto. Na Figura A.2 do Apêndice A estão os resultados obtidos para as simulações por GLS, e observa-se que ocorre o mesmo.

Na Figura 4.8 estão os valores mínimo, médio e máximo das medidas de ajuste para as três amostras, quando aplicado o Modelo 2 (que será utilizado para esta ilustração por ser o que mais causa impacto nas medidas) e Máxima Verossimilhança, para N=1000. Nela observa-se um resultado interessante: as medidas de ajuste da situação "cassim2" estão na média mais próximas às da situação "normal" do que as da "cassim1", o que não é intuitivo dado que a situação "cassim1" consiste num cenário sob menos perturbações com relação à situação "normal". Na situação "cassim1", as medidas de ajuste são menos precisas e acuradas.

Figura 4.8: Comparação entre os valores mínimo, médio e máximo das medidas de qualidade do ajuste para o Modelo 2, estimados por Máxima Verossimilhança para as situações "cassim1", "cassim2" e "normal", com tamanho $N=1000$, no Exemplo 1.

• Correlação entre indicadores

Nesta simulação, a distribuição simulada para o erro aleatório da variável X_6 foi alterada, de forma que ele ficasse correlacionado com o erro de X_5 . A Tabela 4.4 traz os valores das correlações entre os indicadores para uma das simulações da situação "ccorrel1" realizadas (com $N=1000$). Verifica-se que as variáveis X_5 e X_6 possuem uma correlação maior do que a que seria natural pelo fato de serem indicadores do mesmo fator (quando não foi forçada a maior correlação entre seus erros, em média o valor da correlação entre estas duas variáveis girou em torno de 0,5).

Na Figura 4.9 estão os valores das estimativas dos parâmetros da situação "ccorrel1". Eles ficam distantes dos valores que seriam esperados caso não houvesse correlação, e portanto este parece ser um problema mais facilmente identificável na amostra do que os estudados anteriormente. Além disso, mesmo quando não foi especificada a existência de correlação entre os dois fatores do modelo, o procedimento proc calis do SAS estimou um valor para este parâmetro (enquanto que as correlações entre os indicadores só apareceram quando especificadas). O maior impacto foi sobre a matriz de covariância Φ dos fatores,

Tabela 4.4: Correlação entre os indicadores do modelo para uma das simulações da situação "ccorrel1", com N=1000, no Exemplo 1.

	x1	x2	x3	x4	x5	x6
x1	1,00	0,33	0,56	0,01	-0,02	-0,02
x2		1,00	0,38	-0,01	-0,03	-0,04
x3			1,00	0,01	0,01	0,01
x4				1,00	0,47	0,59
x5					1,00	0,84
x6						1,00

Figura 4.9: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "ccorrel1" com tamanho N=1000, e os valores simulados, no Exemplo 1.

enquanto que as variâncias e covariâncias dos indicadores (principalmente de X_5 e X_6 , as variáveis que tiveram sua correlação alterada) tiveram em média estimativas próximas de zero.

A partir da Figura 4.9, conclui-se que este modelo está completamente mal ajustado a tal amostra (ou seja, mesmo que se obtenham medidas de qualidade de ajuste que afirmem o contrário, as estimativas não correspondem aos valores que foram simulados para os parâmetros nestes casos). A Figura 4.10 mostra como se comportaram as medidas de qualidade de ajuste para esta situação. Nela observa-se que a única medida que não

foi eficaz em identificar o mau ajuste do modelo (apresentando um melhor desempenho apenas para o segundo ajuste), foi a PGFI. Para a maior parte das medidas, o Modelo 2 sempre foi identificado como tendo o melhor ajuste sobre a situação "ccorrel1" (mais próximo do desempenho da situação "normal") do que os outros dois. Ou seja, por mais que as estimativas não fiquem corretas, e por mais que o fato de o Modelo 2 estimar as correlações entre os indicadores não afete as demais estimativas (comparativamente aos Modelos 1 e 3), quando as correlações não são especificadas o modelo é considerado ainda pior ajustado.

Figura 4.10: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "ccorrel1" e "normal", com tamanho $N=1000$, no Exemplo 1.

As conclusões obtidas quando se utiliza GLS para as estimativas são análogas.

• Inversão da relação causal

Na situação "relac", a variável X_3 foi simulada como sendo um indicador formativo de ξ_1 , ao invés de reflexivo.

Figura 4.11: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 a 3, ajustados por Máxima Verossimilhança para a situação "relac", com tamanho N=1000, e os valores simulados, no Exemplo 1.

Figura 4.12: Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 a 3, estimados por Máxima Verossimilhança para as situações "relac" e "normal", com tamanho N=1000, no Exemplo 1.

A Figura 4.11 mostra como ficaram as estimativas dos Modelos 1 a 3, comparativamente aos valores de referência. O único impacto foi sobre as estimativas dos parâmetros e variâncias do "bloco" onde X_3 se encontra, e não ocorreu a estimação de covariâncias e correlações sem que elas tivessem sido simuladas, como ocorreu nos casos anteriores.

A Figura 4.12 compara as medidas de qualidade dos ajustes nas situações "relac" e "normal". De forma geral, o ajuste da situação "relac" é indicado como sendo bom. As medidas que mais são impactadas pela alteração são: RFI e TLI (para o Modelo 2). Por outro lado, as outras medidas mal são impactadas. Na Figura A.4 do Apêndice A estão os resultados equivalentes para GLS, e eles levam às mesmas conclusões.

• Resumo

A Tabela 4.5 traz um resumo de todos os resultados apresentados nesta seção. É possível verificar que as principais medidas com sensibilidade aos impactos estudados na amostra são: RFI e TLI. Entretanto, vale lembrar que elas não funcionam tão bem em amostras pequenas, conforme visto nos resultados obtidos no início deste capítulo.

Tabela 4.5: Resumo dos resultados obtidos para o Exemplo 1.

Modelos 1 e 3			Modelo 2		
Problema	Impacto nas estimativas	Medidas impactadas	Problema	Impacto nas estimativas	Medidas impactadas
<i>Outliers1</i>	Apenas no bloco correspondente, baixo	RFI e TLI (máxima verossimilhança)	<i>Outliers1</i>	Apenas no bloco correspondente, baixo	RFI e TLI
<i>Outliers2</i>	Nos blocos correspondentes, baixo	RFI e TLI (máxima verossimilhança)	<i>Outliers2</i>	Nos blocos correspondentes, baixo	RFI e TLI
<i>Cassim1</i>	Muito baixo	-	<i>Cassim1</i>	Muito baixo	-
<i>Cassim2</i>	Muito baixo	-	<i>Cassim2</i>	Muito baixo	-
<i>Ccorrel1</i>	Muito alto	Todas menos PGFI	<i>Ccorrel1</i>	Muito alto	Todas
<i>Relac</i>	Apenas no bloco correspondente, baixo	RFI	<i>Relac</i>	Apenas no bloco correspondente, baixo	RFI e TLI
Impacto da diminuição do tamanho da amostra					
Medidas mais impactadas:			RFI, AGFI, TLI, chisq_rel e RMSEA; AIC (mínimos quadrados)		
Medidas menos impactadas:			GFI, PGFI, PNFI, AIC (Mínimos Quadrados Generalizados)		

As Figuras 4.13 e 4.14 comparam como as diferentes perturbações sobre a amostra impactaram os Modelos 1 e 2. Para o Modelo 1, os impactos foram muito baixos. Já para o Modelo 2, fica mais claro o resultado mostrado na Tabela 4.5, de que as medidas TLI

e RFI são as mais impactadas pelos outros problemas além da correlação. Isso pode ser um indicativo de que, em casos em que foi verificado que a especificação de correlações adicionais no Modelo 2 não impactou as estimativas dos parâmetros, essa pode ser uma prática que, associada ao uso das medidas RFI e TLI, pode torná-las mais sensíveis a capturar problemas nas variáveis. Deve-se tomar um cuidado, entretanto, de notar que para este ajuste o resultado considerado "adequado" para as medidas de ajuste também se altera, conforme pode ser observado para o resultado da situação "normal" nos gráficos apresentados nesta seção. Além disso, conforme já mencionado, deve-se tomar cuidado ao utilizar estas duas medidas em amostras pequenas.

Figura 4.13: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1, com ajuste por Máxima Verossimilhança e N=1000, no Exemplo 1.

Figura 4.14: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2, com ajuste por Máxima Verossimilhança e N=1000, no Exemplo 1.

4.2 Exemplo 2

O segundo exemplo simulado consiste num caso mais elaborado, com variáveis latentes endógenas e exógenas (e seus indicadores), uma parte de mensuração e outra estrutural. Agora o modelo é composto de três "blocos" (sendo que cada um deles consiste em uma variável latente e seus indicadores), e a suposição inicial é de que os indicadores de um bloco não estão correlacionados com os de outro.

Como no Exemplo 1, o Modelo 3 (que acrescenta ao modelo mais simples correlações entre as variáveis latentes) apresentou resultados muito parecidos aos do Modelo 1. Aqui foram construídas apenas duas configurações de modelos: o Modelo 1, que não supõe correlações entre nenhuma das variáveis, e o Modelo 2, que supõe correlações entre os indicadores de um mesmo bloco.

A Figura 4.15 traz os diagramas de caminho das 2 especificações que foram ajustadas, a partir do procedimento proc calis do SAS, neste exemplo.

Figura 4.15: Diagramas de caminho para os modelos ajustados no Exemplo 2

Matricialmente, o Exemplo 2 pode ser escrito da seguinte forma:

Equações de mensuração:

$$x = \Lambda_x \xi + \delta$$

$$y = \Lambda_y \eta + \epsilon$$

Equações estruturais:

$$\eta = \Gamma \xi + \zeta$$

Variáveis:

$$\mathbf{x} = \begin{bmatrix} X_1 \\ X_2 \\ X_3 \\ X_4 \\ X_5 \\ X_6 \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix}, \quad \boldsymbol{\delta} = \begin{bmatrix} \delta_1 \\ \delta_2 \\ \delta_3 \\ \delta_4 \\ \delta_5 \\ \delta_6 \end{bmatrix}, \quad \boldsymbol{\epsilon} = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \epsilon_3 \end{bmatrix}, \quad \boldsymbol{\xi} = \begin{bmatrix} \xi_1 \\ \xi_2 \end{bmatrix}, \quad \boldsymbol{\zeta} = \begin{bmatrix} \zeta_1 \end{bmatrix}$$

,

Parâmetros:

$$\boldsymbol{\Lambda}_{\mathbf{x}} = \begin{bmatrix} \lambda x_{11} & 0 \\ \lambda x_{21} & 0 \\ \lambda x_{31} & 0 \\ 0 & \lambda x_{42} \\ 0 & \lambda x_{52} \\ 0 & \lambda x_{62} \end{bmatrix}, \quad \boldsymbol{\Lambda}_{\mathbf{y}} = \begin{bmatrix} \lambda y_{11} \\ \lambda y_{21} \\ \lambda y_{31} \end{bmatrix}, \quad \boldsymbol{\Gamma} = \begin{bmatrix} \gamma_1 \\ \gamma_2 \end{bmatrix}, \quad \boldsymbol{\Theta}_{\boldsymbol{\delta}} = \begin{bmatrix} \theta x_{11} & 0 & 0 & \dots & 0 \\ 0 & \theta x_{22} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & & \vdots \\ 0 & 0 & 0 & \dots & \theta x_{66} \end{bmatrix},$$

$$\boldsymbol{\Theta}_{\boldsymbol{\epsilon}} = \begin{bmatrix} \theta y_{11} & 0 & 0 \\ 0 & \theta y_{22} & 0 \\ 0 & 0 & \theta y_{33} \end{bmatrix}, \quad \boldsymbol{\Phi} = \begin{bmatrix} \phi_{11} & 0 \\ 0 & \phi_{22} \end{bmatrix}, \quad \boldsymbol{\Psi} = \begin{bmatrix} \psi_{11} \end{bmatrix}$$

O Modelo 2 possui uma forma matricial similar, só apresentando mudança nas matrizes de correlação dos indicadores $\mathbf{x}$ e $\mathbf{y}$:

$$\boldsymbol{\Theta}_{\boldsymbol{\delta}} = \begin{bmatrix} \theta x_{11} & \theta x_{12} & \theta x_{13} & 0 & 0 & 0 \\ & \theta x_{22} & \theta x_{23} & 0 & 0 & 0 \\ & & \theta x_{33} & 0 & 0 & 0 \\ & \vdots & & \theta x_{44} & \theta x_{45} & \theta x_{46} \\ & & & & \theta x_{55} & \theta x_{56} \\ & & & \dots & & \theta_{66} \end{bmatrix},$$

$$\Theta_{\epsilon} = \begin{bmatrix} \theta_{y_{11}} & \theta_{y_{12}} & \theta_{y_{13}} \\ & \theta_{y_{22}} & \theta_{y_{23}} \\ & & \theta_{y_{33}} \end{bmatrix}$$

Inicialmente, é necessário verificar se os dois modelos são identificáveis (ou se era necessário fixar algum dos parâmetros). O primeiro passo para isso é aplicar a Regra t. Tem-se que, para os dois modelos, $p = 3, q = 6$ e $\frac{1}{2}(p + q)(p + q + 1) = 45$. No Modelo 1, $t = 23$, e no Modelo 2, $t = 32$. Logo, a regra está cumprida para ambos.

Em seguida, é aplicada a Regra 2 Passos. Na primeira etapa considera-se que os elementos do vetor $\mathbf{y}$ pertencem ao $\mathbf{x}$, e os elementos de η e ξ são variáveis de ξ . Ademais, no Modelo 1 a matriz Θ_{δ} continuará diagonal após a realização da suposição, dado que nenhum dos indicadores é correlacionado com outro neste exemplo. Logo, pela Regra 3 Indicadores, conclui-se que as equações de mensuração do Modelo 1 são identificáveis. Como no Modelo 2 a diagonalidade da matriz de covariância dos indicadores não ocorre, não é possível concluir se suas equações de mensuração (e portanto, que o Modelo 2, é identificável).

Por último, falta conferir se a parte estrutural do Modelo 1 também é identificável. Isso se dá pela Regra B Nula. Portanto, demonstra-se que o Modelo 1 é identificável. Quanto ao Modelo 2, será seguida novamente a linha de que, como o software SAS consegue estimar o modelo "normal" corretamente, o Modelo é identificável - analogamente ao que foi suposto no Exemplo 1). As amostras utilizadas neste exemplo sofreram perturbações diferentes daquelas realizadas no Exemplo 1, e portanto simularam-se apenas as amostras de tamanho 1000 (dado que no Exemplo 1 já foi concluído que amostras menores podem camuflar o impacto real das demais perturbações). Foram simuladas 5.000 amostras para cada uma das perturbações descritas na Tabela 4.6, e os Modelos 1 e 2 foram ajustados a cada uma delas por dois métodos: GLS e ML.

Apesar de que algumas das transformações são semelhantes às realizadas no Exem-

Tabela 4.6: Descrição das situações nas quais foram simuladas as amostras sobre as quais foram ajustados os Modelos 1 e 2 do Exemplo 2.

Situações	Cenários	Criação do cenário
"normal"	Amostra simulada "corretamente", com variáveis com distribuição normal e não-correlacionadas.	
"ccurt"	Semelhante à situação "normal", mas com maior curtose na variável X_3	Simular X_3 a partir de erro com distribuição t com 2 graus de liberdade.
"ccorrelx"	Especifica correlação entre os indicadores X_2 e X_3 .	Ao simular X_2 , somar ao seu erro aleatório também o erro simulado para X_3 .
"ccorrelx"	Especifica correlação entre os indicadores Y_1 e Y_2 .	Ao simular Y_2 , somar ao seu erro aleatório também o erro simulado para Y_1 .
"icausal1"	Inverte a relação causal entre os fatores ξ_2 e η_1 .	Efetuar as simulações com η_1 causando ξ_2 , e não o contrário.
"icausa2"	Transforma os fatores endógenos em exógenos e vice-versa.	Efetuar as simulações com η_1 causando ξ_1 e ξ_2 , e não o contrário.

plo 1 (como a inversão de relação causal), elas são essencialmente diferentes pois, desta vez, é possível analisar seu impacto sobre as variáveis latentes. Ou seja, o Exemplo 2 foi construído de forma a complementar o Exemplo 1, criando também análises mais completas para as situações já estudadas ali.

Na situação "normal" as amostras foram simuladas com os seguintes valores de parâmetros: $\lambda_{x_{11}} = 1, 0$; $\lambda_{x_{21}} = 0, 3$; $\lambda_{x_{31}} = 1, 2$; $\lambda_{x_{42}} = 1, 0$; $\lambda_{x_{52}} = 0, 8$; $\lambda_{x_{62}} = 1, 9$; $\lambda_{y_{11}} = 1, 0$; $\lambda_{y_{21}} = 0, 6$; $\lambda_{y_{31}} = 1, 5$; $\gamma_1 = 0, 6$; $\gamma_2 = 1, 4$.

• Curtose

Para simular alta curtose em um dos indicadores, seu erro foi simulado com distribuição t com dois graus de liberdade. Ainda assim, durante as simulações percebeu-se que o fato de que o erro era somado a uma variável latente, nem sempre a mudança na distribuição do erro era suficiente para aumentar a curtose a ponto de gerar resultados interessantes para a análise. Caso o erro fosse distorcido muito drasticamente, isso impactaria a relação entre o indicador e a variável latente, o que faria com que não fosse possível concluir que os resultados observados eram devidos à maior curtose. Para contornar esse problema, a distribuição t foi simulada sobre o peso da variável X_2 , que é a indicadora com menor

coeficiente para a influência que sofre da variável latente que a influencia.

A Figura 4.16 faz a comparação entre os resultados obtidos para as estimativas (por ML) dos parâmetros da situação "ccurt" (com curtose), em comparação aos valores simulados. Nota-se que a principal estimativa impactada foi a variância da variável X_2 . Este resultado corresponde ao que seria esperado, dado que foi esta a variável que sofreu mudanças em sua distribuição (tornando-se as caudas mais pesadas).

Os resultados obtidos estimando-se os modelos por GLS foram análogos.

Figura 4.16: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccurt" com tamanho $N=1000$, e os valores simulados, no Exemplo 2.

Observa-se na Figura 4.17 o desempenho das medidas de qualidade do ajuste para a situação "ccurt" e para a "normal", para os Modelos 1 e 2. O único impacto visível ocorre na mudança do Modelo 1 para o 2, mas em ambas as situações (ou seja: a diferença é fruto da má-especificação que surge ao se passar de um modelo para o outro, e não da curtose, que ocorre nos dois igualmente). Na Figura A.5 do Apêndice A estão os resultados obtidos para as simulações por GLS; novamente, o impacto causado pela curtose sobre as medidas de ajuste é quase nulo.

• Correlações

Figura 4.17: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "ccurt" e "normal", com tamanho $N=1000$, no Exemplo 2.

No estudo a seguir, foram forçadas correlações entre os indicadores (tanto aqueles causados por variáveis latentes exógenas quanto endógenas, para comparar se há diferença).

Na situação "ccorrelx", foi simulada correlação entre as variáveis X_2 e X_3 , que são função de uma variável latente exógena. A Figura 4.18 mostra como ficaram as estimativas dos Modelos 1 a 2 (realizadas por ML) para esta situação, comparativamente aos valores simulados. Foram impactados tanto os coeficientes quanto as variâncias de todas as variáveis que são função deste mesmo constructo (ou seja, além destas duas, também X_1), mas as dos outros blocos não sofreram efeitos.

A Figura 4.19 compara as medidas de qualidade dos ajustes nas situações "ccorrelx" e "normal". Apenas as medidas AIC e CAIC foram impactadas pelas perturbações simuladas nas variáveis, e só no primeiro ajuste. Na Figura A.6 do Apêndice A estão os resultados equivalentes para GLS. Novamente as medidas AIC e CAIC foram as mais impactadas.

Figura 4.18: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccorrelx" com tamanho $N=1000$, e os valores simulados, no Exemplo 2.

Figura 4.19: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "ccorrelx" e "normal", com tamanho $N=1000$, no Exemplo 2.

O outro teste realizado impactando as correlações entre as variáveis foi relacionado com as variáveis Y_1 e Y_2 (que são funções de uma variável latente endógena). Neste caso, a Figura 4.20 mostra que o resultado afetou mais parâmetros: os coeficientes do bloco em que estão estas variáveis, suas variâncias, as correlações entre elas e também o coeficiente que relaciona o fator endógeno com os fatores exógenos que o causam. Isto está de acordo com a suspeita que originou esta simulação: o efeito das variáveis exógenas é absorvido dentro do próprio "bloco", enquanto que o efeito que origina a correlação entre as variáveis endógenas se espalha por toda a estrutura do modelo. Pensando em situações práticas nas quais correlações destas naturezas pudessem ocorrer, tal resultado parece bastante razoável.

Figura 4.20: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "ccorrely" com tamanho $N=1000$, e os valores simulados, no Exemplo 2.

Resta verificar se alguma das medidas de ajuste responde de forma diferenciada a este impacto. A Figura 4.21 traz o resultado das medidas de qualidade de ajuste obtidas para esta simulação, que foram muito parecidos com os obtidos para o caso de correlação entre as variáveis exógenas (impacto principalmente nas medidas AIC e CAIC no ajuste 1). Isto mostra que, apesar de os parâmetros terem sido estimados com distorções para os dois modelos, quando as correlações entre as variáveis estavam especificadas as medidas

indicaram uma qualidade de ajuste muito melhor do que quando não estavam. Para GLS, novamente foram impactadas também as medidas TLI, NFI, RFI, IFI e CFI; entretanto, aqui este efeito foi ainda maior.

Figura 4.21: Comparação entre as medidas de qualidade do ajuste médias para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situação "ccorrelly" e "normal", com tamanho N=1000, no Exemplo 2.

• Relação causal entre os constructos

Finalmente, foram realizadas duas simulações em que eram invertidas relações causais entre variáveis. Como no Exemplo 1 um estudo semelhante já havia sido realizado envolvendo variáveis observadas, aqui o foco foi alterar as relações entre os constructos. Assim, na primeira ("icausa1"), a inversão ocorreu entre as variáveis ξ_2 e η_1 ; na segunda ("icausa2"), todos os fatores formativos passaram a ser reflexivos e vice-versa (ou seja, η_1 , que antes era causada por ξ_1 e ξ_2 , agora causa estas variáveis).

Figura 4.22: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "icausa1" com tamanho $N=1000$, e os valores simulados, do Exemplo 2.

Figura 4.23: Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "icausa1" e "normal", com tamanho $N=1000$, no Exemplo 2.

A Figura 4.22 traz as estimativas dos parâmetros simulados e obtidos para o ajuste

na situação "icausa1". Os maiores impactos ocorreram nos blocos de indicadores das duas variáveis latentes envolvidas na mudança, e também na correlação entre elas e na estimativa de γ_1 (que é justamente o parâmetro que as relaciona). Este resultado é bem coerente com o que seria ilustrado, e vai de acordo com a hipótese de que o resto do modelo não é afetado. Com relação às medidas de ajuste, conforme mostra a Figura 4.23 finalmente boa parte delas expressa a diferença entre a qualidade deste modelo e o do aplicado na situação "normal": AIC, CAIC, RFI, TLI e AGFI. Já quando se estima por Mínimos Quadrados Generalizados (Figura A.8 do Apêndice A), verifica-se que AGFI é uma das medidas com menos impacto; enquanto que RFI e TLI passam a ser bastante impactadas, além das medidas NFI, CFI e IFI.

Figura 4.24: Comparação entre as estimativas médias para os parâmetros dos Modelos 1 e 2, ajustados por Máxima Verossimilhança para a situação "icausa2" com tamanho $N=1000$, e os valores simulados, no Exemplo 2.

Já para a situação "icausa2", que inverte todas as relações entre constructos, o impacto é generalizado pelos indicadores, pelos coeficientes das relações entre os fatores, e também afeta a correlação entre as variáveis latentes, conforme mostra a Figura 4.24. A Figura 4.25 indica que novamente as medidas de qualidade de ajuste mais impactadas foram AIC, CAIC, e, para o Modelo 2, AGFI, RFI e TLI (quando se estima o modelo por Máxima Verossimilhança). Na Figura A.8 do Apêndice A ocorre o mesmo que na Figura A.7:

quando se estima por GLS, a medida AGFI perde seu poder discriminatório, enquanto que CFI, NFI e IFI passam a indicar também que o modelo está mal-ajustado. Para muitas medidas, os resultados foram muito semelhantes aos obtidos para a situação "icausa1".

Figura 4.25: Comparação entre as medidas médias de qualidade do ajuste para os Modelos 1 e 2, estimados por Máxima Verossimilhança para as situações "icausa2" e "normal", com tamanho $N=1000$, no Exemplo 2.

• Resumo

A Tabela 4.7 lista um resumo de todos os resultados apresentados nesta seção. Nota-se que as principais medidas de ajuste a responder aos estímulos realizados nestas simulações foram: AIC e CAIC, seguidas (em menor escala) por outras, como RFI, TLI, NFI e AGFI. Além disso, novamente em alguns casos houve diferença significativa entre o resultado apresentado quando se estima o modelo por GLS ou por ML, apesar de que na maioria das vezes as duas técnicas resultam em estimativas semelhantes.

As Figuras 4.26 e 4.27 comparam como as diferentes perturbações sobre a amostra impactaram os Modelos 1 e 2. Para o Modelo 1, as medidas relevantes levantadas na

Tabela 4.7: Resumo dos resultados obtidos para o Exemplo 2.

Modelo 1			Modelo 2		
Problema	Impacto nas estimativas	Medidas impactadas	Problema	Impacto nas estimativas	Medidas impactadas
<i>ccurt</i>	Alto, na variável impactada	Nenhuma	<i>ccurt</i>	Alto, na variável impactada	Nenhuma
<i>Ccorrelx</i>	Alto, apenas no bloco correspondente	AIC, CAIC	<i>Ccorrelx</i>	Médio, apenas no bloco correspondente	Nenhuma
<i>Correly</i>	Alto, podendo afetar outros blocos e as relações entre os fatores	AIC e CAIC; TLI, NFI, RFI, IFI e CFI (por GLS)	<i>Correly</i>	Médio, apenas nos blocos correspondentes	Nenhuma
<i>Icausa1</i>	Intermediário; apenas nos blocos envolvidos	AIC, CAIC, RFI e TLI; AGFI (por ML); NFI, CFI e IFI (por GLS)	<i>Icausa1</i>	Intermediário; apenas nos blocos envolvidos e nas correlações	AIC, CAIC, RFI e TLI; AGFI (por ML); NFI, CFI e IFI (por GLS)
<i>Icausa2</i>	Intermediário; afeta todos os blocos	AIC e CAIC; NFI, CFI e IFI (por GLS)	<i>Icausa2</i>	Intermediário; afeta todos os blocos e as correlações	AIC, CAIC, RFI e TLI; AGFI (por ML); NFI, CFI e IFI (por GLS)

Figura 4.26: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1 do Exemplo 2, estimado por Máxima Verossimilhança, com N=1000.

Figura 4.27: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2 do Exemplo 2, estimado por Máxima Verossimilhança, com N=1000.

Tabela 4.5 foram principalmente CAIC e AIC, e para todas elas, a ordem das perturbações (das que menos impactaram para as que mais) é: curtose, correlação nos indicadores, mudança na relação causal e correlação nos indicadores de variáveis latentes endógenas.

Para o Modelo 2 a ordem é um pouco diferente. Seguindo da perturbação que menos causou impactos para a que mais causou, tem-se: correlação, curtose e inversões nas relações de causa. Tal mudança na ordem se deve ao fato de que para este modelo estão especificadas as covariâncias entre as variáveis; assim, quando elas ocorrem efetivamente o modelo não fica mal-ajustado.

Capítulo 5

Conclusão e sugestões de trabalhos futuros

O objetivo deste trabalho foi estudar as medidas de qualidade de ajuste de Modelos de Equações Estruturais (SEM), e tentar entender padrões de comportamento entre estas medidas conforme o estudo sofresse diferentes mudanças e impactos.

Isso auxilia a avaliar na prática o que determinado resultado observado no conjunto de medidas pode dizer a respeito da amostra.

Para tanto, inicialmente foi realizada uma revisão dos conceitos de SEM. Em seguida, foram também revisadas as principais técnicas de estimação e medidas de qualidade de ajuste utilizadas para esta metodologia.

Por fim, foram realizadas duas simulações em que foi possível observar a resposta das estimativas dos parâmetros e também das medidas de ajuste.

De forma geral, não foi possível definir exatamente perfis de comportamento das medidas de ajuste para cada possível problema no estudo ou na amostra, dado que as medidas que mais sofriam alterações perceptíveis com os impactos acabavam sendo na maioria das vezes uma dentre poucas opções (AIC, CAIC, RFI, TLI). Entretanto, foi possível identificar medidas pouco robustas a amostras pequenas e também medidas que quase sempre indicam um bom ajuste, mesmo quando a amostra apresenta problemas que as outras medidas são capazes de detectar. Logo, pode-se utilizar este trabalho como um guia para saber quais medidas evitar, dependendo por exemplo de alguma característica da amostra

a ser utilizada.

A consulta deste material também ajuda a identificar o quão impactado seria o modelo caso se conheça de antemão algum problema que a amostra possa ter. Como um exemplo, suponha-se que o pesquisador saiba que determinada variável deste estudo possui uma distribuição assimétrica. Com isso, é possível saber quais medidas de ajuste ficarão inconclusivas neste caso.

Uma sugestão de trabalho futuro é a realização de outras possíveis investigações, com perturbações que não foram estudadas aqui.

Além disso, parece ser necessário aprofundar-se nos estudos acerca da melhor forma de simular a curtose para obter as análises desejadas (sem que as relações existentes segundo o modelo se percam).

Apêndice A

Medidas de qualidade de ajuste do Capítulo 4, obtidas para estimação por Mínimos Quadrados Generalizados

Tabela A.1: Estimativas dos parâmetros do ajuste do Modelo 1 sobre a situação "normal", por Mínimos Quadrados Generalizados, no Exemplo 1.

Tamanho da amostra		15				30				100				1000				Valores simulados
Medida		média	desvpad	min	max	média	desvpad	min	max	média	desvpad	min	max	média	desvpad	min	max	
Estimativas	lambda11	0,88	0,97	-9,11	17,93	0,89	0,65	-6,58	11,34	0,91	0,22	-2,08	7,69	0,98	0,03	0,79	1,07	1,00
	lambda21	0,39	0,94	-13,51	32,96	0,41	0,41	-8,99	5,16	0,46	0,16	-0,37	3,13	0,49	0,05	0,33	0,66	0,50
	lambda31	0,92	1,60	-30,32	17,54	1,05	1,30	-17,84	19,25	1,22	0,57	-6,44	12,46	1,29	0,12	0,92	1,90	1,30
	lambda42	0,80	0,74	-7,28	29,46	0,84	0,31	-1,46	5,35	0,93	0,09	0,36	1,40	0,99	0,01	0,90	1,02	1,00
	lambda52	0,62	0,83	-25,63	11,17	0,68	0,35	-4,54	3,56	0,76	0,16	0,28	1,76	0,79	0,05	0,63	0,97	0,80
	lambda62	1,42	1,57	-33,47	23,70	1,67	1,12	-17,08	27,67	1,82	0,34	0,78	4,22	1,89	0,11	1,56	2,35	1,90
	phi1	1,30	1,21	-2,88	8,93	1,27	0,99	-2,72	5,04	1,20	0,51	-2,45	3,23	1,03	0,12	0,64	1,61	1,00
	phi2	1,40	1,02	-2,99	5,48	1,28	0,70	-3,18	4,44	1,10	0,30	0,22	2,58	1,01	0,09	0,72	1,37	1,00
	theta1	-0,05	5,31	-44,68	90,87	0,51	3,80	-33,96	42,10	0,92	0,63	-12,11	23,69	0,99	0,09	0,64	1,34	1,00
	theta2	0,51	2,32	-47,08	43,46	0,80	0,94	-22,94	23,66	0,93	0,22	0,42	12,15	0,99	0,05	0,81	1,23	1,00
	theta3	-0,40	7,97	-91,26	66,73	0,33	6,74	-70,80	58,37	0,92	2,37	-26,44	64,23	0,98	0,15	0,38	1,46	1,00
	theta4	0,28	2,91	-31,05	35,21	0,75	1,11	-23,22	30,08	0,93	0,21	-0,19	1,80	0,99	0,07	0,78	1,22	1,00
	theta5	0,48	1,77	-26,46	32,77	0,78	0,67	-16,55	34,58	0,93	0,17	0,34	1,64	0,99	0,05	0,81	1,21	1,00
	theta6	-0,66	9,53	-104,97	91,72	0,37	6,39	-105,20	123,35	0,86	0,62	-3,35	2,67	0,99	0,18	0,29	1,61	1,00

Tabela A.2: Medidas de qualidade de ajuste para a aplicação do Modelo 1 sobre a situação "normal", por Mínimos Quadrados Generalizados, no Exemplo 1.

Tamanho da amostra	GFI				AGFI				NFI				RFI				CFI			
	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	0,84	0,0007	0,63	0,98	0,53	0,0020	-0,10	0,94	0,57	0,0016	0,06	0,90	0,14	0,0033	-0,89	0,81	0,57	0,0018	0,03	0,95
30	0,91	0,0004	0,75	0,99	0,74	0,0013	0,26	0,97	0,69	0,0014	0,13	0,96	0,39	0,0028	-0,74	0,92	0,70	0,0014	0,13	0,97
100	0,97	0,0002	0,87	1,00	0,91	0,0005	0,62	0,99	0,87	0,0007	0,50	0,98	0,74	0,0014	0,00	0,97	0,87	0,0007	0,50	0,99
1000	1,00	0,0000	0,99	1,00	0,99	0,0001	0,97	1,00	0,98	0,0001	0,95	1,00	0,97	0,0002	0,90	1,00	0,98	0,0001	0,95	1,00

Tamanho da amostra	PGFI				PNFI				IFI				TLI				chisq_rel			
	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	0,39	0,0003	0,30	0,46	0,28	0,0008	0,03	0,45	1,15	0,0078	-4,94	17,77	1,52	1,9918	-5889,21	6905,30	0,94	0,0041	0,12	2,20
30	0,43	0,0002	0,35	0,46	0,35	0,0007	0,07	0,48	0,99	0,0023	0,18	1,74	1,03	0,0741	-218,62	227,75	1,07	0,0055	0,11	3,08
100	0,45	0,0001	0,41	0,47	0,44	0,0003	0,25	0,49	0,98	0,0008	0,55	1,13	0,95	0,0019	-0,01	1,33	1,20	0,0071	0,13	5,31
1000	0,47	0,0000	0,46	0,47	0,49	0,0001	0,47	0,50	1,00	0,0001	0,96	1,01	0,99	0,0002	0,92	1,02	1,29	0,0087	0,14	4,20

Tamanho da amostra	AIC				CAIC				RMSEA			
	média	dp	min	max	média	dp	min	max	média	dp	min	max
15	-7,43	0,0284	-13,14	1,40	-19,38	0,0284	-25,10	-10,55	0,05	0,0009	0,00	0,29
30	-6,51	0,0387	-13,21	7,58	-23,32	0,0387	-30,01	-9,23	0,05	0,0008	0,00	0,27
100	-5,57	0,0494	-13,12	23,19	-30,81	0,0494	-38,36	-2,05	0,04	0,0005	0,00	0,21
1000	-5,00	0,0606	-13,02	15,37	-46,36	0,0606	-54,38	-25,99	0,01	0,0002	0,00	0,06

Figura A.1: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "coutliers1", "coutliers2" e "normal", com tamanho N=1000, no Exemplo 1.

Figura A.2: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "cassim1", "cassim2" e "normal", com tamanho $N=1000$, no Exemplo 1.

Figura A.3: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorrel1" e "normal", com tamanho $N=1000$, no Exemplo 1.

Figura A.4: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 a 3, estimados por Mínimos Quadrados Generalizados, para as amostras "relac" e "normal", com tamanho N=1000, no Exemplo 1.

Figura A.5: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccurt" e "normal", com tamanho N=1000, no Exemplo 2.

Figura A.6: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorrelx" e "normal", com tamanho N=1000, no Exemplo 2.

Figura A.7: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "ccorrelx" e "normal", com tamanho N=1000, no Exemplo 2.

Figura A.8: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "icausa1" e "normal", com tamanho N=1000, no Exemplo 2

Figura A.9: Comparação entre as medidas de qualidade do ajuste médias para os ajustes dos Modelos 1 e 2, estimados por Mínimos Quadrados Generalizados, para as amostras "icausa2" e "normal", com tamanho N=1000, no Exemplo 2.

Figura A.10: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 1 do Exemplo 2, ajustado por Mínimos Quadrados Generalizados, com N=1000.

Figura A.11: Comparativo do desempenho das principais medidas de qualidade de ajuste para o Modelo 2 do Exemplo 2, ajustado por Mínimos Quadrados Generalizados, com N=1000.

Apêndice B

Códigos SAS utilizados nas simulações

```
/*Macro que calcula as medidas de qualidade do ajuste*/
%macro quali_ajuste(namostra, base, indmods, qtmodes);

%let metodos = ML GLS;
%do k=1 %to 2;
%let metodo=%scan(&metodos.,&k.);

%do m=1 %to &qtmodes.;
%let indmod=%scan(&indmods.,&m.);

/*Da base estimada para o modelo, filtra as medidas de interesse*/
data estaux_&base._&metodo._&indmod.;
set ram_&base._&metodo._par&indmod. (keep=_name_ _estim_);
if _name_ in ("DF", "CHISQUAR", "CHISQNUL", "NPARM", "GFI", "AGFI", "PGFI", "AIC",
"CAIC", "RMSEAEST", "RMSEALOB", "RMSEAUPB");
run;

proc transpose data=estaux_&base._&metodo._&indmod.
    out=medidas_&base._&metodo._&indmod.
    (keep=DF CHISQUAR CHISQNUL NPARM GFI AGFI PGFI AIC CAIC
    RMSEAEST RMSEALOB RMSEAUPB rename=(nparm=DF_indep chisqnul=chisq_indep chisquar=chisq));
run;

/* Trata a base e constroi novas medidas*/
data medidas_&base._&metodo._&indmod.;
set medidas_&base._&metodo._&indmod.;
C=&namostra.*chisq;
C_indep=&namostra.*chisq_indep;
NFI = (chisq_indep - chisq)/chisq_indep;
IFI = (chisq_indep - chisq)/(chisq_indep - df);
RFI = ((chisq_indep/df_indep) - (chisq/df))/(chisq_indep/df_indep);
TLI = ((chisq_indep/df_indep) - (chisq/df))/((chisq_indep/df_indep)-1);
PNFI = NFI*(df/df_indep);
CFI = 1-(max(C-df, 0))/(max(C_indep-df_indep, 0));
chisq_rel=chisq/df;
chisq_p = (chisq-df)/sqrt(2*df);
base = "&base._&metodo._&indmod.";
run;
```

```

/* Seleciona os valores das estimativas dos parâmetros*/
data parametros_&base._&metodo._&indmod. (drop=_type_);
retain n_var;
set ram_&base._&metodo._par&indmod. (keep=_name_ _type_ _estim_ _stderr_);
where _type_ = "ESTIM";
n_var = compress("var_"!!put(_n_, z2.));
base = "&base._&metodo._&indmod.";
run;

proc transpose data=parametros_&base._&metodo._&indmod.
    out=estim_&base._&metodo._&indmod. (drop=_name_ _label_);
id n_var;
idlabel _name_;
var _estim_;
by base;
run;

proc transpose data=parametros_&base._&metodo._&indmod.
    out=desvpad_&base._&metodo._&indmod.;
id n_var;
idlabel _name_;
var _stderr_;
by base;
run;
%end;
%end;
%mend; /*Fim da macro que avalia a qualidade de ajuste*/

```

```

/*****
/* Especificações dos Modelos 1 a 3 do Exemplo 1*/
*****/

```

```
%macro modelo(base);
```

```
\*Laço para estimar o modelo pelos dois métodos: ML e GLS*/
```

```
%let metodos = ML GLS;
```

```
%do k=1 %to 2;
```

```
%let metodo=%scan(&metodos.,&k.);
```

```
/*****
```

```
/*1- Modelo sem correlações*/
```

```
*****/
```

```
proc calis cov data=amostra_&base. met=&metodo.
```

```
tech=nr outest=par_&base._&metodo._1
```

```
outram=ram_&base._&metodo._par1 /*noprint*/;
```

```
Ram
```

```

    1    1    7          gama11,
    1    2    7          gama21,
    1    3    7          gama32,
    2    1    1          phi1,
    2    2    2          phi2,

```

```

2      3      3      phi3,
2      7      7      zeta1,

1      4      8      gama42,
1      5      8      gama52,
1      6      8      gama62,
2      4      4      phi4,
2      5      5      phi5,
2      6      6      phi6,
2      8      8      zeta2;

run;

```

```

/*****/
/*2- Modelo com correlações entre os indicadores*/
/*****/

```

```

proc calis cov data=amostra_&base. met=&metodo.
tech=nr outest=par_&base._&metodo._2
outtram=ram_&base._&metodo._par2 /*noprint*/;
Ram

```

```

1      1      7      gama11,
1      2      7      gama21,
1      3      7      gama31,
2      1      1      phi1,
2      2      2      phi2,
2      3      3      phi3,
2      1      2      phi12,
2      1      3      phi13,
2      2      3      phi23,
2      7      7      zeta1,

```

```

1      4      8      gama42,
1      5      8      gama52,
1      6      8      gama62,
2      4      4      phi4,
2      5      5      phi5,
2      6      6      phi6,
2      4      5      phi45,
2      4      6      phi46,
2      5      6      phi56,
2      8      8      zeta2;

```

```

run;

```

```

/*****/
/*3- Modelo com correlação entre os fatores e indicadores*/
/*****/

```

```

proc calis cov data=amostra_&base. met=&metodo.
tech=nr outest=par_&base._&metodo._3
outtram=ram_&base._&metodo._par3 /*noprint*/;
Ram

```

```

1      1      7      gama11,
1      2      7      gama21,
1      3      7      gama31,
2      1      1      phi1,

```

```

2      2      2      phi2,
2      3      3      phi3,
2      7      7      zeta1,

1      4      8      gama42,
1      5      8      gama52,
1      6      8      gama62,
2      4      4      phi4,
2      5      5      phi5,
2      6      6      phi6,
2      8      8      zeta2,

2      7      8      zeta12;
run;

```

```

%end;
%mend;

```

```

/*****
/* Códigos que geram todas as amostras e consolidam os resultados*/
*****/

```

```

%macro simula_amostra(N);
/*****/
/*1- Amostra normal*/
/*****/
data amostra_normal;
do _i_ = 1 to &N.;
    phi1 = 1 * rannor(0);
    phi2 = 1 * rannor(0);
    phi3 = 1 * rannor(0);
    zeta1 = 1 * rannor(0);
    eta1 = zeta1;
    x1 = 1*eta1 + phi1;
    x2 = 0.5*eta1 + phi2;
    x3 = 1.3*eta1 + phi3;

    phi4 = 1 * rannor(0);
    phi5 = 1 * rannor(0);
    phi6 = 1 * rannor(0);
    zeta2 = 1 * rannor(0);
    eta2 = zeta2;
    x4 = 1*eta2 + phi4;
    x5 = 0.8*eta2 + phi5;
    x6 = 1.9*eta2 + phi6;
output;

```



```

        end;
        drop zeta1 zeta2 phi1 phi2 phi3 phi4 phi5 phi6 eta1 eta2 _i_;
run;

%modelo(normal);
%quali_ajuste(&N., normal, 1 2 3, 3);

/*****
/*2- Coloca outliers*/
*****/
data amostra_coutliers1;
    do _i_ = 1 to &N.;
    phi1 = 1 * rannor(0);
    phi2 = 1 * rannor(0);
    phi3 = 1 * rannor(0);
    zeta1 = 1 * rannor(0);
    eta1 = zeta1;
    x1 = 1*eta1 + phi1;
    x2 = 0.5*eta1 + phi2;
    x3 = 1.3*eta1 + phi3;
/*Produz 0.5% de outliers em x3*/
    aux1 = 1000 * ranuni(1);
    if aux1 <= 5 then x3 = 100*x3;

    phi4 = 1 * rannor(0);
    phi5 = 1 * rannor(0);
    phi6 = 1 * rannor(0);
    zeta2 = 1 * rannor(0);
    eta2 = zeta2;
    x4 = 1*eta2 + phi4;
    x5 = 0.8*eta2 + phi5;
    x6 = 1.9*eta2 + phi6;
    output;
    end;
    drop zeta1 zeta2 phi1 phi2 phi3 phi4 phi5 phi6 eta1 eta2 _i_ aux1;
run;

%modelo(coutliers1);
%quali_ajuste(&N., coutliers1, 1 2 3, 3);

data amostra_coutliers2;
    do _i_ = 1 to &N.;
    phi1 = 1 * rannor(0);
    phi2 = 1 * rannor(0);
    phi3 = 1 * rannor(0);
    zeta1 = 1 * rannor(0);
    eta1 = zeta1;
    x1 = 1*eta1 + phi1;
    x2 = 0.5*eta1 + phi2;
    x3 = 1.3*eta1 + phi3;

    phi4 = 1 * rannor(0);
    phi5 = 1 * rannor(0);

```

```

        phi6 = 1 * rannor(0);
        zeta2 = 1 * rannor(0);
        eta2 = zeta2;
        x4 = 1*eta2 + phi4;
        x5 = 0.8*eta2 + phi5;
        x6 = 1.9*eta2 + phi6;
        /*Produce 5% de outliers em x6*/
        aux2 = 1000 * ranuni(1); if aux2 <= 50 then x6 = 100*x6;
        output;
    end;
    drop zeta1 zeta2 phi1 phi2 phi3 phi4
    phi5 phi6 eta1 eta2 _i_ aux2;
run;

```

```

%modelo(coutliers2);
%quali_ajuste(&N., coutliers2, 1 2 3, 3);

```

```

/*****
/*3- Coloca variáveis com distribuições assimétricas*/
*****/
data amostra_cassim1;
    do _i_ = 1 to &N.;
        phi1 = 1 * rannor(0);
        phi2 = 1 * rannor(0);
        phi3 = 1 * ranexp(0);
        zeta1 = 1 * rannor(0);
        eta1 = zeta1;
        x1 = 1*eta1 + phi1;
        x2 = 0.5*eta1 + phi2;
        /*Coloca distribuição assimétrica em x3*/
        x3 = 1.3*eta1 + phi3;

        phi4 = 1 * rannor(0);
        phi5 = 1 * rannor(0);
        phi6 = 1 * rannor(0);
        zeta2 = 1 * rannor(0);
        eta2 = zeta2;
        x4 = 1*eta2 + phi4;
        x5 = 0.8*eta2 + phi5;
        x6 = 1.9*eta2 + phi6;
        output;
    end;
    drop zeta1 zeta2 phi1 phi2 phi3 phi4
    phi5 phi6 eta1 eta2 _i_ ;
run;

```

```

%modelo(cassim1);
%quali_ajuste(&N., cassim1, 1 2 3, 3);

```

```

data amostra_cassim2;
    do _i_ = 1 to &N.;
        phi1 = 1 * rannor(0);

```

```

    phi2 = 1 * rannor(0);
    phi3 = 1 * ranexp(0);
    zeta1 = 1 * rannor(0);
    eta1 = zeta1;
    x1 = 1*eta1 + phi1;
    x2 = 0.5*eta1 + phi2;
/*Coloca distribuição assimétrica em x3*/
    x3 = 1.3*eta1 + phi3;

    phi4 = 1 * rannor(0);
    phi5 = 1 * rannor(0);
    phi6 = 1 * ranexp(0);
    zeta2 = 1 * rannor(0);
    eta2 = zeta2;
    x4 = 1*eta2 + phi4;
    x5 = 0.8*eta2 + phi5;
/*Coloca distribuição assimétrica em x6*/
    x6 = 1.9*eta2 + phi6;
    output;
    end;
    drop zeta1 zeta2 phi1 phi2 phi3
    phi4 phi5 phi6 eta1 eta2 _i_ ;
run;

%modelo(cassim2);
%quali_ajuste(&N., cassim2, 1 2 3, 3);

/*****/
/*4- Coloca variáveis correlacionadas (eta1 e eta2)*/
/*****/
data amostra_ccorre1;
    do _i_ = 1 to &N.;
        phi1 = 1 * rannor(0);
        phi2 = 1 * rannor(0);
        phi3 = 1 * rannor(0);
        zeta1 = 1 * rannor(0);
        eta1 = zeta1;
        x1 = 1*eta1 + phi1;
        x2 = 0.5*eta1 + phi2;
        x3 = 1.3*eta1 + phi3;

        phi4 = 1 * rannor(0);
        phi5 = 1 * rannor(0);
        phi6 = 1 * rannor(0);
        zeta2 = 1 * rannor(0);
        eta2 = zeta2;
        x4 = 1*eta2 + phi4;
        x5 = 0.8*eta2 + phi5;
        x6 = 1.9*eta2 + phi5 + phi6;
        output;
        end;
    drop zeta1 zeta2 phi1 phi2 phi3 phi4 phi5 phi6 /*eta1 eta2*/ _i_ ;
run;

```

```

%modelo(ccorre1);
%quali_ajuste(&N., ccorre1, 1 2 3, 3);

/*****/
/*6- Inverte relação causal*/
/*****/
data amostra_relac;
  do _i_ = 1 to &N.;
    phi1 = 1 * rannor(0);
    phi2 = 1 * rannor(0);
    phi3 = 1 * rannor(0);
    zeta1 = 1 * rannor(0);
    x3 = phi1;
    eta1 = 1.3*x3 + zeta1;
    x1 = 1*eta1 + phi3;
    x2 = 0.5*eta1 + phi2;

    phi4 = 1 * rannor(0);
    phi5 = 1 * rannor(0);
    phi6 = 1 * rannor(0);
    zeta2 = 1 * rannor(0);
    eta2 = zeta2;
    x4 = 1*eta2 + phi4;
    x5 = 0.8*eta2 + phi5;
    x6 = 1.9*eta2 + phi6;
    output;
  end;
  drop zeta1 zeta2 phi1 phi2 phi3 phi4 phi5 phi6 eta1 eta2 _i_;
run;

%modelo(relac);
%quali_ajuste(&N., relac, 1 2 3, 3);

%mend;

%macro simula_n_amstras(namostras, tamamostra, listamods, nmods, nespec);

data medidas_ml; format base $20.; run;
data estimativas_ml; format base $20.; run;

data medidas_gls; format base $20.; run;
data estimativas_gls; format base $20.; run;

%do j = 1 %to &namostras.;
%simula_amostra(&tamamostra.);

%let metodos = ML GLS;
%do l=1 %to 2;
%let metodo=%scan(&metodos.,&l.);

```

```

%do m=1 %to &nmods.;
%let nomebase=%scan(&listamods.,&m.);
data medidas_&metodo.;
set medidas_&metodo.;
%do n=1 %to &nespec.;
medidas_&nomebase._&metodo._&n. %end;;
run;

data estimativas_&metodo.;
set estimativas_&metodo. %do n=1 %to &nespec.;
estim_&nomebase._&metodo._&n. %end;;
run;
%end;
%end;
%end;

%let metodos = ML GLS;
%do p=1 %to 2;
%let metodo=%scan(&metodos.,&p.);

%let metricas = mean min max;
%do q=1 %to 3;
%let met=%scan(&metricas.,&q.);

proc sql;
create table medidas_&metodo._&met. as select
base, "&met." as medida,
&met.(GFI) as GFI, &met.(AGFI) as AGFI,
&met.(PGFI) as PGFI, &met.(AIC) as AIC,
&met.(CAIC) as CAIC, &met.(RMSEAEST) as RMSEAEST,
&met.(RMSEALOB) as RMSEALOB,
&met.(RMSEAUPB) as RMSEAUPB,
&met.(NFI) as NFI, &met.(IFI) as IFI,
&met.(RFI) as RFI, &met.(TLI) as TLI,
&met.(PNFI) as PNFI, &met.(CFI) as CFI,
&met.(chisq) as chisq,
&met.(chisq_rel) as chisq_rel,
&met.(chisq_p) as chisq_p
from medidas_&metodo.
group by base;
quit;

proc means data=estimativas_&metodo. mean min max;
output out=estimativas_&metodo._&met.
(where=(lowercase(_stat_) = "&met.") drop = _freq_ _type_);
class base; run;
%end;
%end;

data estimativas (drop = _stat_);
set estimativas_ml_min (in=a)
estimativas_ml_mean (in=b) estimativas_ml_max (in=c)
estimativas_gls_min (in=d) estimativas_gls_mean (in=e)
estimativas_gls_max (in=f) ;

```

```

if max(a, b, c) = 1 then metodo = "ml "; else metodo = "gls";
if max(a, d) = 1 then metrica = "min";
else if max(b, e) = 1 then metrica = "med";
else metrica = "max";
where base ne "";
run;

data medidas (drop = _stat_);
set medidas_ml_min (in=a) medidas_ml_mean (in=b)
medidas_ml_max (in=c) medidas_gls_min (in=d)
medidas_gls_mean (in=e) medidas_gls_max (in=f) ;
if max(a, b, c) = 1 then metodo = "ml "; else metodo = "gls";
if max(a, d) = 1 then metrica = "min";
else if max(b, e) = 1 then metrica = "med";
else metrica = "max";
where base ne "";
run;

%mend;

%simula_n_amostras(10000, 15, normal coutliers1
coutliers2 cassim1 cassim2 ccorrel1 relac, 9, 3);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação\
Simulações\Medidas_Exemplo_1_15.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação\
Simulações\Estimativas_Exemplo_1_15.xls"
dbms=excel2000 replace ;
run ;

%simula_n_amostras(10000, 30, normal
coutliers1 coutliers2 cassim1 cassim2 ccurt1 ccurt2 ccorrel1 relac, 9, 3);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos\
Dissertação\Simulações\Medidas_Exemplo_1_100.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos\
Dissertação\Simulações\Estimativas_Exemplo_1_100.xls"
dbms=excel2000 replace ;
run ;

%simula_n_amostras(10000, 1000, normal coutliers1
coutliers2 cassim1 cassim2 ccurt1 ccurt2 ccorrel1 relac, 9, 3);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos\
Dissertação\Simulações\Medidas_Exemplo_1_1000.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas

```

```

outfile="C:\Users\Renata\Desktop\Arquivos\
Dissertação\Simulações\Estimativas_Exemplo_1_1000.xls"
dbms=excel2000 replace ;
run ;

proc sql; select * from estimativas; quit;

/*****
/*Especificações do Exemplo 2
*****/

%macro modelo(base);

%let metodos = ML GLS;
%do k=1 %to 2;
%let metodo=%scan(&metodos.,&k.);

/*****
/*1- Modelo sem correlações*/
*****/
proc calis cov data=amostra_&base. met=&metodo.
tech=nr outest=par_&base._&metodo._1 outram=ram_&base._&metodo._par1 /*noprnt*/;
Ram
1 1 10 lambda11,
1 2 10 lambda21,
1 3 10 lambda31,
2 1 1 theta_x_11,
2 2 2 theta_x_22,
2 3 3 theta_x_33,
2 10 10 phi1,

1 4 11 lambda42,
1 5 11 lambda52,
1 6 11 lambda62,
2 4 4 theta_x_44,
2 5 5 theta_x_55,
2 6 6 theta_x_66,
2 11 11 phi2,

1 7 12 lambday11,
1 8 12 lambday21,
1 9 12 lambday31,
2 7 7 theta_y_11,
2 8 8 theta_y_22,
2 9 9 theta_y_33,
2 12 12 psi1,

1 12 10 gamma1,
1 12 11 gamma2;
run;
/*****
/*2- Modelo com correlações entre os indicadores*/

```

```

/*****/
proc calis cov data=amostra_&base. met=&metodo. tech=nr
outest=par_&base._&metodo._2 outram=ram_&base._&metodo._par2 /*noprint*/;
Ram
  1      1      10      lambdax11,
  1      2      10      lambdax21,
  1      3      10      lambdax31,
  2      1      1      theta_x_11,
  2      2      2      theta_x_22,
  2      3      3      theta_x_33,
  2      10     10      phi1,
  2      1      2      theta_x_12,
  2      1      3      theta_x_13,
  2      2      3      theta_x_23,

  1      4      11      lambdax42,
  1      5      11      lambdax52,
  1      6      11      lambdax62,
  2      4      4      theta_x_44,
  2      5      5      theta_x_55,
  2      6      6      theta_x_66,
  2      11     11      phi2,
  2      4      5      theta_x_45,
  2      4      6      theta_x_46,
  2      5      6      theta_x_56,

  1      7      12      lambday11,
  1      8      12      lambday21,
  1      9      12      lambday31,
  2      7      7      theta_y_11,
  2      8      8      theta_y_22,
  2      9      9      theta_y_33,
  2      12     12      psi1,
  2      7      8      theta_y_12,
  2      7      9      theta_y_13,
  2      8      9      theta_y_23,

  1      12     10      gamma1,
  1      12     11      gamma2;
run;

%end;
%mend;

/*****/
/* Simula as amostras e consolida as informações do Exemplo 2 */
/*****/

%macro simula_amostra(N);
/*****/
/*1- Amostra normal*/

```



```

/*****/
data amostra_normal;
do _i_ = 1 to &N.;
    delta1 = 1 * rannor(0);
    delta2 = 1 * rannor(0);
    delta3 = 1 * rannor(0);
    zetax1 = 1 * rannor(0);
    ksi1 = zetax1;
    x1 = 1*ksi1 + delta1;
    x2 = 0.3*ksi1 + delta2;
    x3 = 1.2*ksi1 + delta3;

    delta4 = 1 * rannor(0);
    delta5 = 1 * rannor(0);
    delta6 = 1 * rannor(0);
    zetax2 = 1 * rannor(0);
    ksi2 = zetax2;
    x4 = 1*ksi2 + delta4;
    x5 = 0.8*ksi2 + delta5;
    x6 = 1.9*ksi2 + delta6;

    epsilon1 = 1 * rannor(0);
    epsilon2 = 1 * rannor(0);
    epsilon3 = 1 * rannor(0);
    zetay1 = 1 * rannor(0);
    eta1 = 0.6*ksi1 + 1.4*ksi2 + zetay1;
    y1 = 1*eta1 + epsilon1;
    y2 = 0.6*eta1 + epsilon2;
    y3 = 1.5*eta1 + epsilon3;
    output;
end;
drop delta1 delta2 delta3 delta4 delta5 delta6
epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(normal);
%quali_ajuste(&N., normal, 1 2, 2);

/*****/
/*2- Coloca curtose*/
/*****/
data amostra_ccurt;
do _i_ = 1 to &N.;
    delta1 = 1 * rannor(0);
    delta2 = 1 * rand('T', 2);
    delta3 = 1 * rannor(0);
    zetax1 = 1 * rannor(0);
    ksi1 = zetax1;
    x1 = 1*ksi1 + delta1;
    x2 = 0.3*ksi1 + delta2;
    x3 = 1.2*ksi1 + delta3;

    delta4 = 1 * rannor(0);
    delta5 = 1 * rannor(0);

```

```

delta6 = 1 * rannor(0);
zetax2 = 1 * rannor(0);
ksi2 = zetax2;
x4 = 1*ksi2 + delta4;
x5 = 0.8*ksi2 + delta5;
x6 = 1.9*ksi2 + delta6;

epsilon1 = 1 * rannor(0);
epsilon2 = 1 * rannor(0);
epsilon3 = 1 * rannor(0);
zetay1 = 1 * rannor(0);
eta1 = 0.6*ksi1 + 1.4*ksi2 + zetay1;
y1 = 1*eta1 + epsilon1;
y2 = 0.6*eta1 + epsilon2;
y3 = 1.5*eta1 + epsilon3;
output;
end;

drop delta1 delta2 delta3 delta4 delta5 delta6
epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(ccurt);
%quali_ajuste(&N., ccurt, 1 2, 2);

/*****/
/*3- Coloca correlação nos indicadores X*/
/*****/
data amostra_ccorrelx;
do _i_ = 1 to &N.;
delta1 = 1 * rannor(0);
delta2 = 1 * rannor(0);
delta3 = 1 * rannor(0);
zetax1 = 1 * rannor(0);
ksi1 = zetax1;
x1 = 1*ksi1 + delta1;
x2 = 0.3*ksi1 + delta2 + delta3;
x3 = 1.2*ksi1 + delta3;

delta4 = 1 * rannor(0);
delta5 = 1 * rannor(0);
delta6 = 1 * rannor(0);
zetax2 = 1 * rannor(0);
ksi2 = zetax2;
x4 = 1*ksi2 + delta4;
x5 = 0.8*ksi2 + delta5;
x6 = 1.9*ksi2 + delta6;

epsilon1 = 1 * rannor(0);
epsilon2 = 1 * rannor(0);
epsilon3 = 1 * rannor(0);
zetay1 = 1 * rannor(0);
eta1 = 0.6*ksi1 + 1.4*ksi2 + zetay1;

```

```

        y1 = 1*eta1 + epsilon1;
        y2 = 0.6*eta1 + epsilon2;
        y3 = 1.5*eta1 + epsilon3;
        output;
    end;
    drop delta1 delta2 delta3 delta4 delta5 delta6
    epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(ccorrelx);
%quali_ajuste(&N., ccorrelx, 1 2, 2);

/*****
/*4- Coloca correlação nos indicadores Y*/
*****/
data amostra_ccorrely;
    do _i_ = 1 to &N.;
        delta1 = 1 * rannor(0);
        delta2 = 1 * rannor(0);
        delta3 = 1 * rannor(0);
        zetax1 = 1 * rannor(0);
        ksi1 = zetax1;
        x1 = 1*ksi1 + delta1;
        x2 = 0.3*ksi1 + delta2;
        x3 = 1.2*ksi1 + delta3;

        delta4 = 1 * rannor(0);
        delta5 = 1 * rannor(0);
        delta6 = 1 * rannor(0);
        zetax2 = 1 * rannor(0);
        ksi2 = zetax2;
        x4 = 1*ksi2 + delta4;
        x5 = 0.8*ksi2 + delta5;
        x6 = 1.9*ksi2 + delta6;

        epsilon1 = 1 * rannor(0);
        epsilon2 = 1 * rannor(0);
        epsilon3 = 1 * rannor(0);
        zetay1 = 1 * rannor(0);
        eta1 = 0.6*ksi1 + 1.4*ksi2 + zetay1;
        y1 = 1*eta1 + epsilon1;
        y2 = 0.6*eta1 + epsilon2 + epsilon1;
        y3 = 1.5*eta1 + epsilon3;
        output;
    end;
    drop delta1 delta2 delta3 delta4 delta5 delta6
    epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(ccorrely);
%quali_ajuste(&N., ccorrely, 1 2, 2);

```

```

/*****
/*5- Inverte relação causal*/
*****/
/*Entre ksi2 e eta1*/
data amostra_icausal;
do _i_ = 1 to &N.;
    delta1 = 1 * rannor(0);
    delta2 = 1 * rannor(0);
    delta3 = 1 * rannor(0);
    zetax1 = 1 * rannor(0);
    ksi1 = zetax1;
    x1 = 1*ksi1 + delta1;
    x2 = 0.3*ksi1 + delta2;
    x3 = 1.2*ksi1 + delta3;

    epsilon1 = 1 * rannor(0);
    epsilon2 = 1 * rannor(0);
    epsilon3 = 1 * rannor(0);
    zetay1 = 1 * rannor(0);
    eta1 = 0.6*ksi1 + zetay1;
    y1 = 1*eta1 + epsilon1;
    y2 = 0.6*eta1 + epsilon2;
    y3 = 1.5*eta1 + epsilon3;

    delta4 = 1 * rannor(0);
    delta5 = 1 * rannor(0);
    delta6 = 1 * rannor(0);
    zetax2 = 1 * rannor(0);
    ksi2 = 1.4*eta1 + zetax2;
    x4 = 1*ksi2 + delta4;
    x5 = 0.8*ksi2 + delta5;
    x6 = 1.9*ksi2 + delta6;
    output;
end;
drop delta1 delta2 delta3 delta4 delta5 delta6
epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(icausal);
%quali_ajuste(&N., icausal, 1 2, 2);

/*Troca indicadores formativos por reflexivos*/
data amostra_icausa2;
do _i_ = 1 to &N.;
    epsilon1 = 1 * rannor(0);
    epsilon2 = 1 * rannor(0);
    epsilon3 = 1 * rannor(0);
    zetay1 = 1 * rannor(0);
    eta1 = zetay1;
    y1 = 1*eta1 + epsilon1;
    y2 = 0.6*eta1 + epsilon2;
    y3 = 1.5*eta1 + epsilon3;

```

```

    delta1 = 1 * rannor(0);
    delta2 = 1 * rannor(0);
    delta3 = 1 * rannor(0);
    zetax1 = 1 * rannor(0);
    ksi1 = 0.6*eta1 + zetax1;
    x1 = 1*ksi1 + delta1;
    x2 = 0.3*ksi1 + delta2;
    x3 = 1.2*ksi1 + delta3;

    delta4 = 1 * rannor(0);
    delta5 = 1 * rannor(0);
    delta6 = 1 * rannor(0);
    zetax2 = 1 * rannor(0);
    ksi2 = 1.4*eta1 + zetax2;
    x4 = 1*ksi2 + delta4;
    x5 = 0.8*ksi2 + delta5;
    x6 = 1.9*ksi2 + delta6;

    output;
    end;
    drop delta1 delta2 delta3 delta4 delta5 d
    elta6 epsilon1 epsilon2 epsilon3 ksi1 ksi2 zetax1 zetax2 eta1 zetay1 _i_;
run;

%modelo(icausa2);
%quali_ajuste(&N., icausa2, 1 2, 2);
%mend;

%macro simula_n_amostras(namostras, tamamostra, listamods, nmods, nespec);

data medidas_ml; format base $20.; run;
data estimativas_ml; format base $20.; run;

data medidas_gls; format base $20.; run;
data estimativas_gls; format base $20.; run;

%do j = 1 %to &namostras.;
%simula_amostra(&tamamostra.);

%let metodos = ML GLS;
%do l=1 %to 2;
%let metodo=%scan(&metodos.,&l.);

%do m=1 %to &nmods.;
%let nomebase=%scan(&listamods.,&m.);
data medidas_&metodo.;
set medidas_&metodo. %do n=1 %to &nespec.;

```

```

medidas_&nomebase._&metodo._&n. %end;; run;
data estimativas_&metodo.;
set estimativas_&metodo. %do n=1 %to &nespec.;
    estim_&nomebase._&metodo._&n. %end;; run;
%end;
%end;
%end;

%let metodos = ML GLS;
%do p=1 %to 2;
%let metodo=%scan(&metodos.,&p.);

%let metricas = mean min max stderr;
%do q=1 %to 4;
%let met=%scan(&metricas.,&q.);

proc sql;
create table medidas_&metodo._&met. as select
base, "&met." as medida,
&met.(GFI) as GFI, &met.(AGFI) as AGFI, &met.(PGFI) as PGFI, &met.(AIC) as AIC,
&met.(CAIC) as CAIC, &met.(RMSEAEST) as RMSEAEST, &met.(RMSEALOB) as RMSEALOB,
&met.(RMSEAUPB) as RMSEAUPB,
&met.(NFI) as NFI, &met.(IFI) as IFI, &met.(RFI) as RFI, &met.(TLI) as TLI,
&met.(PNFI) as PNFI, &met.(CFI) as CFI, &met.(chisq) as chisq,
&met.(chisq_rel) as chisq_rel, &met.(chisq_p) as chisq_p
from medidas_&metodo.
group by base;
quit;

proc means data=estimativas_&metodo. mean min max;
output out=estimativas_&metodo._&met.
(where=(lowercase(_stat_) = "&met.") drop = _freq_ _type_);
class base; run;
%end;
%end;

data estimativas (drop = _stat_);
set estimativas_ml_min (in=a) estimativas_ml_mean (in=b)
estimativas_ml_max (in=c) estimativas_ml_stderr (in=g)
estimativas_gls_min (in=d) estimativas_gls_mean (in=e)
estimativas_gls_max (in=f) estimativas_gls_stderr (in=h);
if max(a, b, c, g) = 1 then metodo = "ml "; else metodo = "gl";
if max(a, d) = 1 then metrica = "min ";
else if max(b, e) = 1 then metrica = "med ";
else if max(c, f) = 1 then metrica = "max ";
else metrica = "stderr";
where base ne "";
run;

data medidas (drop = _stat_);
set medidas_ml_min (in=a) medidas_ml_mean (in=b)
medidas_ml_max (in=c) medidas_ml_stderr (in=g)
medidas_gls_min (in=d) medidas_gls_mean (in=e)
medidas_gls_max (in=f) medidas_gls_stderr (in=h);

```

```

if max(a, b, c) = 1 then metodo = "ml "; else metodo = "gls";
if max(a, d) = 1 then metrica = "min";
else if max(b, e) = 1 then metrica = "med";
else if max(c, f) = 1 then metrica = "max  ";
else metrica = "stderr";
where base ne "";
run;

%mend;

```

```

%simula_n_amstras(5000, 1000, normal ccurt
ccorrelx ccorrely icausa1 icausa2, 6, 2);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação
\Simulações\Medidas_Exemplo_2_1000.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação
\Simulações\Estimativas_Exemplo_2_1000.xls"
dbms=excel2000 replace ;
run ;

```

```

proc sql; select * from estimativas; quit;

```

```

%simula_n_amstras(10000, 15, normal ccurt ccorrelx
ccorrely icausa1 icausa2, 6, 2);
proc export data=medidas
outfile="C:\Users\Renata\Desktop
\Arquivos\Dissertação\Simulações\Medidas_Exemplo_2_15.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop
\Arquivos\Dissertação\Simulações\Estimativas_Exemplo_2_15.xls"
dbms=excel2000 replace ;
run ;

```

```

%simula_n_amstras(10000, 30, normal ccurt
ccorrelx ccorrely icausa1 icausa2, 6, 2);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação
\Simulações\Medidas_Exemplo_2_30.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos\Dissertação
\Simulações\Estimativas_Exemplo_2_30.xls"
dbms=excel2000 replace ;
run ;

```

```

%simula_n_amostras(10000, 100, normal ccurt
ccorrelx ccorrely icausa1 icausa2, 6, 2);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos
\Dissertação\Simulações\Medidas_Exemplo_2_100.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos
\Dissertação\Simulações\Estimativas_Exemplo_2_100.xls"
dbms=excel2000 replace ;
run ;

%simula_n_amostras(10000, 1000, normal ccurt
ccorrelx ccorrely icausa1 icausa2, 6, 2);
proc export data=medidas
outfile="C:\Users\Renata\Desktop\Arquivos
\Dissertação\Simulações\Medidas_Exemplo_2_1000.xls"
dbms=excel2000 replace ;
run ;
proc export data=estimativas
outfile="C:\Users\Renata\Desktop\Arquivos
\Dissertação\Simulações\Estimativas_Exemplo_2_1000.xls"
dbms=excel2000 replace ;
run ;

proc sql; select * from estimativas; quit;

```


Apêndice C

Resultados das simulações para todos os tamanhos de amostra

Tabela C.2: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Máxima Verossimilhança, no Exemplo 1.

casim1_ML_1		casim1_ML_2		casim1_ML_3		casim2_ML_1		casim2_ML_2		casim2_ML_3		ccore1_ML_1		ccore1_ML_2		ccore1_ML_3		ccurt1_ML_1		ccurt1_ML_2		ccurt1_ML_3		ccurt2_ML_1		ccurt2_ML_2		ccurt2_ML_3																																																																			
med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std																																																																		
gamma11	0.99	0.0254	1.00	0.0000	0.99	0.0238	0.99	0.0236	1.00	0.0000	0.99	0.0220	0.00	0.0245	0.00	0.0245	0.94	0.3188	1.00	0.0127	0.93	0.2319	0.99	0.0311	1.00	0.0000	0.99	0.1215																																																																			
gamma21	0.49	0.0463	0.50	0.0462	0.49	0.0463	0.49	0.0456	0.50	0.0446	0.49	0.0456	0.00	0.0351	0.00	0.0351	0.48	0.3832	0.48	0.2355	0.47	0.3009	0.50	0.1595	0.50	0.0945	0.50	0.0975																																																																			
gamma31	1.28	0.1148	1.27	0.1232	1.28	0.1155	1.29	0.1158	1.27	0.1225	1.29	0.1164	0.00	0.0280	0.00	0.0280	1.23	1.6443	1.12	1.6485	1.23	1.6596	1.29	0.2885	1.27	0.3047	1.28	0.3047																																																																			
gamma42	0.99	0.0090	1.00	0.0001	0.99	0.0085	0.99	0.0090	1.00	0.0001	0.99	0.0085	0.00	0.0219	0.00	0.0219	0.95	0.0738	1.00	0.0030	0.95	0.0722	0.99	0.0357	1.00	0.0087	0.99	0.0368																																																																			
gamma52	0.80	0.0458	0.80	0.0456	0.80	0.0458	0.80	0.0466	0.80	0.0464	0.80	0.0466	0.34	0.0081	0.34	0.0081	0.77	0.1529	0.78	0.1501	0.77	0.1531	0.79	0.2462	0.79	0.2176	0.79	0.2481																																																																			
gamma62	1.89	0.1082	1.89	0.1083	1.89	0.1083	1.89	0.1071	1.89	0.1078	1.89	0.1072	0.34	0.0155	0.34	0.0155	1.85	0.3367	1.79	0.3606	1.85	0.3413	1.89	0.3756	1.88	0.3902	1.89	0.3741																																																																			
phi1	1.00	0.0959	0.97	0.1044	1.00	0.0962	1.00	0.0967	0.97	0.1030	1.00	0.0968	1.00	0.0455	1.00	0.0455	0.99	1.6507	0.97	0.4218	0.98	1.3105	1.00	0.1043	0.97	0.1136	1.00	0.1271																																																																			
phi2	1.00	0.0501	0.99	0.0504	1.00	0.0501	1.00	0.0498	1.00	0.0499	1.00	0.0498	2.00	0.0897	2.00	0.0897	0.96	0.8311	0.97	0.1840	0.98	0.4727	0.99	0.1574	0.99	0.0539	1.00	0.1163																																																																			
phi3	0.99	0.1661	1.05	0.1786	0.99	0.1668	0.99	0.1682	1.04	0.1765	0.99	0.1683	1.25	0.0559	1.25	0.0559	78.13	4775.2814	78.23	4775.1552	78.16	4775.2739	23.01	848.2836	23.07	848.2816	23.01	848.2852																																																																			
phi4	1.00	0.0652	0.99	0.0661	1.00	0.0653	1.00	0.0659	0.99	0.0663	1.00	0.0659	2.69	0.1219	2.69	0.1219	0.99	0.2080	0.89	0.2317	0.99	0.2107	1.00	0.1122	0.99	0.0716	1.00	0.1027																																																																			
phi5	1.00	0.0545	1.00	0.0544	1.00	0.0545	1.00	0.0542	1.00	0.0542	1.00	0.0543	0.36	0.0159	0.36	0.0159	0.99	0.1728	0.98	0.1716	0.99	0.1740	0.99	0.1895	1.00	0.0628	0.99	0.1751																																																																			
phi6	0.99	0.1768	1.03	0.1782	0.99	0.1772	0.99	0.1951	1.03	0.1952	0.99	0.1953	1.35	0.0595	1.35	0.0595	0.92	0.6107	1.21	0.5865	0.91	0.6500	50.04	3124.6025	50.07	3124.6021	50.04	3124.6022																																																																			
phi12	-0.01	0.0218			-0.01	0.0203			-0.01	0.0203			1.00	0.0548			1.12	0.2957	1.11	0.2972	1.13	0.2953	1.01	0.0960	1.01	0.0933	1.01	0.0963																																																																			
phi13	0.00	0.0074			0.00	0.0071			0.00	0.0071			0.50	0.0390			0.07	1.0960		0.0773	0.07	1.0960		0.00	0.2207																																																																						
phi23	0.00	0.0084			0.00	0.0084			0.00	0.0077			0.50	0.0523			0.06	0.5548		0.0773	0.06	0.5548		0.00	0.0519																																																																						
phi45	-0.01	0.0087			-0.01	0.0085			-0.01	0.0085			0.00	0.0309			-0.04	0.0773		0.0773	-0.04	0.0773		0.00	0.0286																																																																						
phi46	0.00	0.0038			0.00	0.0038			0.00	0.0039			0.00	0.0602			-0.01	0.0591		0.0591	-0.01	0.0591		0.00	0.3442																																																																						
phi56	0.00	0.0068			0.00	0.0068			0.00	0.0070			0.36	0.0248			0.05	0.0691		0.0691	0.05	0.0691		0.00	0.2388																																																																						
zeta1	1.04	0.1205	1.03	0.1202	1.04	0.1204	1.03	0.1195	1.03	0.1193	1.03	0.1194	1.64	0.0731	1.64	0.0731	1.21	0.5825	1.22	0.4929	1.22	0.5767	1.03	0.1302	1.03	0.1303	1.03	0.1295																																																																			
zeta12					0.00	0.0408					0.00	0.0406	5.61	0.2499	5.61	0.2499	2.52	0.1241			1.12	0.2957	1.11	0.2972		0.00	0.0415	0.00	0.0415																																																																		
zeta2	1.01	0.0909	1.01	0.0909	1.01	0.0909	1.01	0.0892	1.01	0.0891	1.01	0.0891	2.52	0.1241	2.52	0.1241	1.01	0.0960	1.01	0.0960	1.12	0.2953	1.01	0.0960	1.01	0.0933	1.01	0.0963																																																																			
releac_ML_1																																releac_ML_2																																releac_ML_3																															
normal_ML_2																																normal_ML_1																																normal_ML_2																															
gamma11	1.04	0.2791	1.00	0.0229	1.00	0.0229	1.04	0.2864	0.99	0.0170	1.00	0.0000	0.99	0.0167	0.99	0.0245	1.00	0.0000	0.99	0.0228	0.99	0.0101	1.00	0.0001	1.00	0.0001	0.99	0.0094																																																																			
gamma21	0.46	0.5318	0.40	0.4727	0.46	0.5434	0.50	0.5434	0.50	0.0447	0.50	0.0440	0.49	0.0447	0.49	0.0453	0.50	0.0445	0.49	0.0452	2.06	0.1043	2.06	0.1060	2.06	0.1044																																																																					
gamma31	1.93	0.9530	1.90	0.9787	1.92	0.9624	1.29	0.9624	1.29	0.1175	1.28	0.1201	1.29	0.1182	1.29	0.1151	1.27	0.1231	1.29	0.1157	1.03	0.0569	1.03	0.0564	1.03	0.0568																																																																					
gamma42	1.00	0.0060	1.00	0.0001	0.99	0.0067	0.99	0.0067	0.99	0.0450	1.00	0.0011	0.99	0.0529	0.99	0.0089	1.00	0.0001	0.99	0.0084	0.99	0.0071	1.00	0.0001	0.99	0.0067	1.00	0.0001																																																																			
gamma52	0.80	0.0458	0.80	0.0457	0.80	0.0458	0.81	0.2624	0.81	0.2624	0.70	0.2828	0.81	0.2620	0.80	0.0471	0.80	0.0469	0.80	0.0470	0.80	0.0460	0.80	0.0458	0.80	0.0460																																																																					
gamma62	1.90	0.1086	1.89	0.1089	1.89	0.1089	11.18	2.9835	11.18	2.9835	11.19	2.9943	11.18	3.0006	1.89	0.1079	1.88	0.1088	1.89	0.1080	1.90	0.1079	1.89	0.1079	1.89	0.1081	1.90	0.1080																																																																			
phi1	0.88	1.5901	0.95	0.4571	0.87	1.6092	1.00	0.0963	0.98	0.0995	1.00	0.0995	1.00	0.0966	1.00	0.0940	0.97	0.1025	1.00	0.0942	0.37	0.0311	0.37	0.0321	0.37	0.0311																																																																					
phi2	1.18	1.6272	0.99	0.2564	1.17	1.5820	1.00	0.0494	1.00	0.0494	1.00	0.0492	1.00	0.0494	1.00	0.0493	1.00	0.0498	1.00	0.0493	1.00	0.1211	1.01	0.1244	1.00	0.1212																																																																					
phi3	134.20	103.5409	134.43	103.6763	134.15	103.4922	0.99	0.1505	0.99	0.1509	1.02	0.1527	0.99	0.1509	0.99	0.1484	1.04	0.1603	0.99	0.1487	1.00	0.0527	1.00	0.0527	1.00	0.0527																																																																					
phi4	1.00	0.0660	0.99	0.0662	1.00	0.0661	0.97	0.0661	0.97	0.2446	0.93	0.2522	0.97	0.2489	1.00	0.0653	0.99	0.0658	1.00	0.0653	1.00	0.0646	0.99	0.0647	1.00	0.0646																																																																					
phi5	1.00	0.0549	1.00	0.0547	1.00	0.0548	0.99	0.0548	0.99	0.3400	1.10	0.3852	0.99	0.3013	1.00	0.0536	1.00	0.0534	1.00	0.0536	1.00	0.0551	1.00	0.0551	1.00	0.0552																																																																					
phi6	0.99	0.1780	1.01	0.1774	0.99	0.1782	1.01	0.1774	0.99	0.1782	1.01	0.1782	1.01	0.1774	0.99	0.1782	1.01	0.1796	1.03	0.1799	1.00	0.1797	0.99	0.1793	1.02	0.1770	0.99	0.1787																																																																			
phi12	0.12	0.3047			0.12	0.3047			-0.01	0.0137			-0.01	0.0137			-0.01	0.0111							0.00	0.0047																																																																					
phi13	0.18	0.4493			0.18	0.4493			0.00	0.0046			0.00	0.0046			0.00	0.0072			0.00	0.0078		0.00	0.0078																																																																						
phi23	0.26	0.5776			0.26	0.5776			0.00	0.0060			0.00	0.0060			0.00	0.0085			0.00	0.0058		0.00	0.0058																																																																						
phi45	0.00	0.0053			0.00	0.0053			0.09	0.2019			0.09	0.2019			-0.01	0.0084			0.00	0.0065		0.00	0.0065																																																																						
phi46	0.00	0.0027			0.00	0.0027			-0.33	0.9526			-0.33	0.9526			0.00	0.0040			0.00	0.0032		0.00	0.0032																																																																						
phi56	0.00	0.0049			0.00	0.0049			1.10	2.0571			1.10	2.0571			0.00	0.0070			0.00	0.0056		0.00	0.0056																																																																						
zeta1	1.07	0.6185	1.07	0.5290	1.07	0.6207	1.03	0.1180	1.03	0.1181	1.03	0.1181	1.03	0.1196	1.03	0.1194	1.03	0.1191	1.03	0.1191	1.03	0.1193	0.64	0.0505	0.63	0.0501	0.64	0.0504																																																																			
zeta12					0.00	0.0460					0.00	0.0460									0.00	0.0412		0.00	0.0412		0.00	0.0304																																																																			
zeta2	1.01	0.0914	1.01	0.0915	1.01	0.0922	1.06	0.2751	1.07	0.2632	1.05	0.2743	1.02	0.0913	1.01	0.0912	1.01	0.0912	1.01	0.0912	1.01	0.0904	1.01	0.0906	1.01	0.0904	1.01	0.0904																																																																			

Tabela C.3: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Mínimos Quadrados Generalizados, no Exemplo 1.

Simulação		casim1_GLS_1		casim2_GLS_1		casim2_GLS_2		casim2_GLS_3		ccorrel1_GLS_1		ccorrel1_GLS_2		ccorrel1_GLS_3		ccorrel2_GLS_1		ccorrel2_GLS_2		ccorrel2_GLS_3																	
Modelo	Medida	casim1_GLS_1		casim2_GLS_1		casim2_GLS_2		casim2_GLS_3		ccorrel1_GLS_1		ccorrel1_GLS_2		ccorrel1_GLS_3		ccorrel2_GLS_1		ccorrel2_GLS_2		ccorrel2_GLS_3																	
		med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std																
gama11	0.90	0.2074	0.98	0.0310	0.91	0.1946	0.91	0.2147	0.98	0.0312	0.91	0.1898	0.91	0.0940	0.00	0.0798	0.00	0.1021	0.93	0.3800	0.98	0.1286	0.92	0.2352	0.93	0.4112	0.98	0.1223	0.92	0.2856							
gama21	0.45	0.1603	0.47	0.1448	0.45	0.1572	0.46	0.1624	0.47	0.1522	0.46	0.1657	0.46	0.1285	0.00	0.1145	0.00	0.1362	0.46	0.4088	0.47	0.3327	0.45	0.3873	0.46	0.2922	0.46	0.2292	0.45	0.2432							
gama31	1.19	0.6133	1.07	0.5392	1.20	0.6092	1.19	0.6097	1.07	0.5384	1.20	0.6149	1.20	0.0933	0.00	0.0887	0.00	0.0962	1.21	5.6364	1.19	5.6420	1.09	5.6200	1.21	5.6364	1.19	1.6016	1.05	1.5948							
gama42	0.93	0.0892	0.98	0.0308	0.94	0.0813	0.93	0.0913	0.98	0.0295	0.94	0.0839	0.94	0.0736	0.00	0.0701	0.00	0.0782	0.93	0.0949	0.98	0.0303	0.94	0.0830	0.94	0.1419	0.99	0.1498	0.94	0.2184							
gama52	0.76	0.1562	0.77	0.1517	0.76	0.1553	0.76	0.1570	0.77	0.1520	0.76	0.1562	0.76	0.0267	0.34	0.0262	0.34	0.0270	0.76	0.1581	0.77	0.1518	0.76	0.1578	0.76	0.4721	0.77	0.2652	0.76	0.3741							
gama62	1.81	0.3465	1.75	0.3713	1.82	0.3493	1.82	0.3490	1.75	0.3767	1.83	0.3508	1.83	0.0524	0.34	0.0516	0.34	0.0529	1.82	0.3487	1.75	0.3692	1.83	0.3559	1.82	20.2383	1.44	20.2402	1.53	20.2393							
phi11	0.92	0.9053	0.75	0.3907	0.91	0.9328	0.93	1.1226	0.76	0.3854	0.90	0.9011	0.08	0.0364	0.22	0.0372	0.08	0.0364	0.93	1.7590	0.77	0.4253	0.89	1.2831	0.98	2.5066	0.77	0.4543	0.89	1.4802							
phi12	0.93	0.2151	0.92	0.1603	0.93	0.1549	0.93	0.1563	0.92	0.1619	0.93	0.1569	0.82	0.1367	0.82	0.1367	0.82	0.1367	0.95	1.0258	0.92	0.4441	0.95	0.9314	0.92	0.6684	0.92	0.1685	0.92	0.1685							
phi13	1.04	2.8197	1.24	0.5984	0.99	2.6488	1.02	2.8536	1.24	0.5987	0.99	2.7531	0.87	0.1370	0.98	0.1517	0.87	0.1369	302.56	13708.64	303.22	13708.64	302.41	13708.29	18.08	706.0626	18.37	706.1549	17.88	700.7372							
phi14	0.92	0.2063	0.85	0.2374	0.92	0.2090	0.93	0.2108	0.85	0.2425	0.93	0.2123	0.77	0.1318	0.59	0.0990	0.77	0.1318	0.94	0.3225	0.86	0.3232	0.93	0.2115	0.93	0.4020	0.85	0.2931	0.92	0.5496							
phi15	0.93	0.1712	0.93	0.1680	0.93	0.1721	0.93	0.1692	0.93	0.1646	0.93	0.1698	0.18	0.0342	0.32	0.0488	0.18	0.0342	0.93	0.1703	0.93	0.1667	0.93	0.1711	0.93	0.7680	0.93	0.1908	0.93	0.5849							
phi16	0.88	0.6106	1.22	0.5798	0.88	0.6338	0.87	0.6713	1.21	0.6223	0.86	0.7153	0.71	0.1305	1.24	0.1884	0.71	0.1305	0.87	0.6361	1.21	0.5717	0.87	0.7233	7600.93	534270.62	7601.28	534270.62	7600.19	534270.51							
phi12			-0.05	0.1282				-0.04	0.1246						0.22	0.0708			-0.03	0.1727								-0.03	0.1557								
phi13			0.09	0.2099				0.09	0.2056						0.11	0.0631			0.12	1.1513								0.12	0.6666								
phi23			0.07	0.0989				0.07	0.0975						0.09	0.9923			0.09	0.9923								0.08	0.6150								
phi45			-0.03	0.0824				-0.03	0.0853						0.00	0.0584			-0.03	0.0806								-0.03	0.1139								
phi46			0.02	0.0646				0.02	0.0691						0.00	0.1152			0.02	0.0612								0.07	2.4005								
phi56			0.07	0.0721				0.07	0.0763						0.32	0.0772			0.07	0.0679								0.03	3.3759								
zeta1	1.20	0.5330	1.20	0.4667	1.22	0.5209	1.20	0.5363	1.20	0.4678	1.22	0.5266	1.61	0.2358	1.61	0.2360	1.57	0.2344	1.17	0.5963	1.17	0.5101	1.19	0.5771	1.19	0.5969	1.18	0.5143	1.21	0.5840							
zeta12			0.00	0.1577				0.00	0.1574				5.56	0.8064	5.55	0.8058	2.46	0.3963										0.00	0.1662								
zeta2	1.10	0.3109	1.08	0.3124	1.12	0.3081	1.10	0.3097	1.08	0.3117	1.12	0.3072	2.53	0.4000	2.53	0.4000	5.44	0.7967	1.10	0.3028	1.07	0.3027	1.11	0.3011	1.10	0.3565	1.07	0.3518	1.12	0.3546							
Simulação		coulter1_GLS_1		coulter1_GLS_2		coulter1_GLS_3		coulter2_GLS_1		coulter2_GLS_2		coulter2_GLS_3		normal_GLS_1		normal_GLS_2		normal_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3	
Modelo	Medida	coulter1_GLS_1		coulter1_GLS_2		coulter1_GLS_3		coulter2_GLS_1		coulter2_GLS_2		coulter2_GLS_3		normal_GLS_1		normal_GLS_2		normal_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3		retrac_GLS_1		retrac_GLS_2		retrac_GLS_3	
		med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std		
gama11	1.16	1.4507	1.06	0.5440	1.07	0.8934	1.07	0.8934	0.91	0.1644	0.98	0.0304	0.90	0.1765	0.91	0.2177	0.98	0.0303	0.91	0.1864	0.95	0.0888	1.00	0.0215	0.96	0.0760	0.96	0.0760	0.96	0.0760	0.96	0.0760	0.96	0.0760	0.96		
gama21	0.49	1.9538	0.49	1.2330	0.48	1.7144	0.48	1.7144	0.46	0.1602	0.47	0.1440	0.45	0.1560	0.46	0.1614	0.47	0.1473	0.46	0.1603	0.201	0.3442	1.96	0.3874	2.01	0.3482	2.01	0.3482	2.01	0.3482	2.01	0.3482	2.01	0.3482	2.01		
gama31	1.71	3.7823	1.35	4.1369	1.66	3.9967	1.66	3.9967	1.23	0.4739	1.12	0.4327	1.21	0.5039	1.22	0.5734	1.09	0.5459	1.23	0.5812	0.99	0.1962	1.00	0.1913	0.99	0.1952	1.00	0.1913	0.99	0.1952	1.00	0.1913	0.99	0.1952	1.00		
gama42	0.94	0.0846	0.98	0.0307	0.94	0.0780	0.94	0.0780	1.20	1.6317	2.05	1.5994	1.23	1.6064	0.93	0.0911	0.98	0.0302	0.94	0.0831	0.94	0.0850	0.98	0.0301	0.94	0.0782	0.94	0.0850	0.98	0.0301	0.94	0.0782	0.94	0.0850	0.98		
gama52	0.76	0.1577	0.76	0.1532	0.76	0.1581	0.72	0.1581	0.72	0.1581	0.72	0.1581	0.65	2.8566	0.76	0.1627	0.77	0.1527	0.76	0.1610	0.76	0.1560	0.77	0.1494	0.76	0.1560	0.77	0.1494	0.76	0.1560	0.77	0.1494	0.76	0.1560	0.77		
gama62	1.82	0.3492	1.76	0.3680	1.83	0.3509	10.44	10.1833	9.61	10.8421	10.31	10.3504	10.31	10.3504	1.82	0.3402	1.75	0.3678	1.83	0.3424	1.83	0.3543	1.76	0.3729	1.84	0.3568	1.84	0.3568	1.84	0.3568	1.84	0.3568	1.84	0.3568	1.84		
phi1	0.90	0.5356	0.84	0.9490	0.67	4.0165	0.90	0.6993	0.78	0.3651	0.93	0.1557	0.87	0.9093	0.92	0.6347	0.76	0.3870	0.90	0.8495	0.34	0.0989	0.30	0.1264	0.34	0.1002	0.34	0.1002	0.34	0.1002	0.34	0.1002	0.34	0.1002	0.34		
phi2	0.81	4.4902	0.92	0.4189	0.82	3.4632	0.94	0.2783	0.93	0.1557	0.93	0.1557	0.93	0.1561	0.93	0.2239	0.92	0.1625	0.93	0.1581	0.90	0.3897	1.09	0.4456	0.90	0.3976	0.90	0.3976	0.90	0.3976	0.90	0.3976	0.90	0.3976	0.90		
phi3	123.40	295.4664	128.14	304.7146	123.20	300.3675	0.90	2.1416	1.18	0.5113	0.83	2.3428	0.92	2.3700	1.12	0.5466	0.90	2.2693	0.93	0.1634	0.94	0.1693	0.93	0.1634	0.94	0.1693	0.93	0.1636	0.94	0.1693	0.93	0.1636	0.94	0.1693	0.93		
phi4	0.93	0.2086	0.86	0.2331	0.93	0.2110	0.40	5.4961	-0.60	3.2220	-0.09	6.1902	0.93	0.2111	0.85	0.2392	0.93	0.2130	0.93	0.2076	0.86	0.2273	0.93	0.2076	0.86	0.2273	0.93	0.2089	0.93	0.2076	0.86	0.2273	0.93	0.2089	0.93		
phi5	0.93	0.1686	0.93	0.1686	0.93	0.1704	1.02	7.8827	0.48	1.9517	0.89	6.5242	0.93	0.1691	0.93	0.1643	0.93	0.1693	0.93	0.1702	0.94	0.1629	0.93	0.1702	0.94	0.1629	0.93	0.1707	0.93	0.1629	0.93	0.1707	0.93	0.1629	0.93		
phi6	0.86	0.6324	1.18	0.5617	0.86	0.6519	2035.83	1506.92	2128.79	1569.14	2025.43	1485.17	0.86	0.6228	1.20	0.5814	0.85	0.6418	0.86	0.6376	1.18	0.5596	0.85	0.5596	0.85	0.5596	0.85	0.5596	0.85	0.5596	0.85	0.5596	0.85	0.5596	0.85		
phi12			0.02	0.4800				-0.04	0.1057							-0.05	0.1295																				

Tabela C.4: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Máxima Verossimilhança, no Exemplo 1.

casim1_ML_1			casim1_ML_2			casim1_ML_3			casim2_ML_1			casim2_ML_2			casim2_ML_3			ccore1_ML_1			ccore1_ML_2			ccore1_ML_3			ccurt1_ML_1			ccurt1_ML_2			ccurt1_ML_3			ccurt2_ML_1			ccurt2_ML_2			ccurt2_ML_3					
Medida	med	std	med	std	med	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std								
gamma11	0.92	0.1924	1.00	0.0102	0.92	0.1836	0.92	0.1954	1.00	0.0102	0.92	0.1847	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793	0.00	0.0793					
gamma21	0.46	0.1519	0.48	0.1470	0.46	0.1529	0.47	0.1589	0.48	0.1542	0.46	0.1618	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126	0.00	0.1126					
gamma31	1.21	0.6213	1.10	0.5930	1.21	0.6114	1.21	0.6195	1.10	0.5367	1.21	0.6226	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875	0.00	0.0875					
gamma42	0.95	0.0759	1.00	0.0032	0.95	0.0744	0.95	0.0781	1.00	0.0037	0.95	0.0766	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709	0.00	0.0709					
gamma52	0.77	0.1521	0.78	0.1495	0.77	0.1520	0.77	0.1520	0.78	0.1495	0.77	0.1519	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257	0.34	0.0257					
gamma62	1.84	0.3394	1.78	0.3642	1.84	0.3435	1.84	0.3431	1.78	0.3693	1.84	0.3465	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505	0.34	0.0505					
phi11	0.98	0.8475	0.78	0.3923	0.96	0.9179	0.98	0.8890	0.78	0.3868	0.94	0.8848	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393	0.99	0.1393					
phi12	0.99	0.1566	0.97	0.0452	0.99	0.1586	0.97	0.0467	0.99	0.1567	0.99	0.1603	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774	0.99	0.2774					
phi13	1.14	2.9620	1.27	0.6154	1.07	0.6310	1.13	0.3063	1.27	0.6154	1.08	0.3185	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744	1.24	0.1744					
phi14	0.98	0.2080	0.88	0.2340	0.98	0.2112	0.98	0.2119	0.88	0.2330	0.99	0.2145	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813	2.66	0.3813					
phi15	0.98	0.1726	0.97	0.1722	0.98	0.1740	0.98	0.1691	0.97	0.1663	0.98	0.1704	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495	0.35	0.0495					
phi16	0.94	0.6058	1.24	0.5871	0.93	0.6378	0.93	0.6667	1.23	0.6309	0.92	0.6931	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885	1.34	0.1885					
phi17	-0.06	0.1270	phi18	0.07	0.2102	phi19	0.06	0.1024	phi20	-0.05	0.0801	phi21	-0.01	0.0569	phi22	0.05	0.0711	phi23	0.05	0.0773	phi24	0.05	0.0773	phi25	0.05	0.0773	phi26	0.05	0.0773	phi27	0.05	0.0773	phi28	0.05	0.0773	phi29	0.05	0.0773	phi30	0.05	0.0773	phi31	0.05	0.0773			
zeta11	1.22	0.5425	1.22	0.4574	1.22	0.5302	1.22	0.5451	1.23	0.4590	1.23	0.5350	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362	1.65	0.2362					
zeta12	0.00	0.1516	0.00	0.1516	0.00	0.1515	5.63	0.8060	5.63	0.8060	5.63	0.8060	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000	2.53	0.4000					
zeta21	1.12	0.3061	1.12	0.3074	1.13	0.3058	1.13	0.3046	1.12	0.3067	1.14	0.3044	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515					
zeta22	1.13	0.2979	1.11	0.3004	1.13	0.3058	1.13	0.3046	1.12	0.3067	1.14	0.3044	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515	0.00	0.1515					
Simulação			couter1_ML_1			couter1_ML_2			couter1_ML_3			couter2_ML_1			couter2_ML_2			couter2_ML_3			normal_ML_1			normal_ML_2			normal_ML_3			relic_ML_1			relic_ML_2			relic_ML_3			relic_ML_3			relic_ML_3			relic_ML_3		
Medida	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std			
gamma11	1.12	1.2801	1.00	0.0278	1.09	0.8938	0.93	0.1442	1.00	0.0088	0.90	0.1731	0.92	0.1881	1.00	0.0104	0.92	0.1661	0.96	0.0760	1.00	0.0058	0.96	0.0707	1.00	0.0058	0.96	0.0707	1.00	0.0058	0.96	0.0707	1.00	0.0058	0.96	0.0707	1.00	0.0058	0.96	0.0707	1.00	0.0058	0.96	0.0707			
gamma21	0.52	1.9378	0.44	1.1403	0.50	1.6339	0.47	0.1473	0.49	0.1451	0.45	0.1637	0.47	0.1541	0.48	0.1496	0.46	0.1557	2.02	0.3403	1.98	0.3805	2.02	0.3445	1.98	0.3805	2.02	0.3445	1.98	0.3805	2.02	0.3445	1.98	0.3805	2.02	0.3445	1.98	0.3805	2.02	0.3445	1.98	0.3805	2.02	0.3445			
gamma31	1.79	3.8340	1.57	4.1311	1.74	4.0410	1.25	0.4601	1.15	0.4298	1.22	0.4761	1.24	0.5604	1.12	0.5435	1.24	0.5761	1.00	0.1904	1.01	0.1894	1.00	0.1899	1.01	0.1894	1.00	0.1904	1.01	0.1894	1.00	0.1904	1.01	0.1894	1.00	0.1904	1.01	0.1894	1.00	0.1904	1.01	0.1894					
gamma41	0.95	0.0711	1.00	0.0038	0.95	0.0723	1.11	1.3245	0.99	0.0465	1.22	1.3514	0.95	0.0772	1.00	0.0032	0.95	0.0761	0.95	0.0711	0.95	0.0711	0.95	0.0699	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711	0.95	0.0711					
gamma52	0.77	0.1529	0.78	0.1509	0.76	0.1535	0.61	2.9020	0.52	0.9457	0.64	2.7228	0.77	0.1560	0.78	0.1506	0.77	0.1553	0.77	0.1500	0.78	0.1473	0.77	0.1503	0.78	0.1473	0.77	0.1503	0.78	0.1473	0.77	0.1503	0.78	0.1473	0.77	0.1503	0.78	0.1473	0.77	0.1503	0.78	0.1473					
gamma62	1.85	0.3427	1.79	0.3599	1.84	0.3470	1.06	10.1194	10.60	10.1194	10.36	10.3353	1.84	0.3337	1.78	0.3603	1.84	0.3375	1.85	0.3479	1.79	0.3650	1.85	0.3510	1.79	0.3650	1.85	0.3510	1.79	0.3650	1.85	0.3510	1.79	0.3650	1.85	0.3510	1.79	0.3650	1.85	0.3510	1.79	0.3650					
phi1	0.83	4.4127	0.95	0.5975	0.80	3.6265	0.96	0.5604	0.81	0.3665	0.93	0.7826	0.97	0.6499	0.79	0.3886	0.95	0.7040	0.36	0.0594	0.32	0.1228	0.36	0.1010	0.32	0.1228	0.36	0.1010	0.32	0.1228	0.36	0.1010	0.32	0.1228	0.36	0.1010	0.32	0.1228	0.36	0.1010	0.32	0.1228					
phi2	0.83	3.6344	0.97	0.2937	0.82	2.9958	0.99	0.1548	0.98	0.1583	1.00	0.1571	0.99	0.1590	0.97	0.1671	0.99	0.1601	0.96	0.3913	1.11	0.4515	0.96	0.4012	1.11	0.4515	0.96	0.4012	1.11	0.4515	0.96	0.4012	1.11	0.4515	0.96	0.4012	1.11	0.4515	0.96	0.4012	1.11	0.4515					
phi3	119.75	307.3568	119.68	307.0383	119.36	312.2644	0.97	1.8452	1.21	0.5246	0.85	1.1939	1.00	0.2549	1.26	0.5624	0.98	0.2705	0.99	0.1646	0.98	0.1729	0.99	0.1649	0.98	0.1729	0.99	0.1649	0.98	0.1729	0.99	0.1646	0.98	0.1729	0.99	0.1646	0.98	0.1729	0.99	0.1646							
phi4	0.99	0.2097	0.90	0.2298	0.99	0.1314	0.50	4.1729	0.84	0.9839	0.98	4.5033	0.98	0.21																																	

Tabela C.5: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Mínimos Quadrados Generalizados, no Exemplo 1.

casim1_GIS_1		casim1_GIS_2		casim1_GIS_3		casim2_GIS_1		casim2_GIS_2		casim2_GIS_3		ccorrel1_GIS_1		ccorrel1_GIS_2		ccorrel1_GIS_3		ccurt1_GIS_1		ccurt1_GIS_2		ccurt1_GIS_3		ccurt2_GIS_1		ccurt2_GIS_2		ccurt2_GIS_3					
Modelo		Medida		1		2		3		1		2		3		1		2		3		1		2		3		1		2		3	
med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std		
gama11	1.08	1.7734	0.93	0.0858	0.88	0.7061	0.93	0.0887	0.92	0.5574	0.00	0.1819	0.00	0.1501	0.00	0.3181	0.93	0.3936	0.98	0.0960	0.92	0.2563	0.95	0.9496	0.94	0.1631	0.94	0.6727	0.94	0.6727			
gama21	0.45	2.4276	0.45	0.3302	0.41	0.3752	0.41	0.3071	0.42	0.3981	0.01	0.3506	0.01	0.2201	0.00	0.3746	0.45	0.5822	0.47	0.2176	0.45	0.5408	0.43	0.8379	0.40	0.5113	0.42	0.7059	0.42	0.7059			
gama31	1.40	6.8454	1.16	7.0949	1.42	6.6925	1.08	1.3878	0.87	1.1841	1.07	1.3700	1.05	1.2960	0.83	1.0438	1.05	1.1981	0.93	0.4131	0.92	0.4087	0.93	0.4352	0.93	0.4352	0.93	0.4352	0.93	0.4352			
gama41	0.83	0.2851	0.95	0.0908	0.86	0.2959	1.72	0.0597	1.99	0.2597	1.33	3.7829	0.84	0.3079	0.95	0.0894	0.86	0.2867	0.93	0.0894	0.85	0.0894	0.85	0.0894	0.85	0.0894	0.85	0.0894	0.85	0.0894			
gama52	0.68	0.3541	0.69	0.3200	0.70	0.3748	0.99	5.5224	1.15	3.2909	0.81	4.2953	0.68	0.3503	0.69	0.3122	0.70	0.3940	0.69	0.3290	0.69	0.2553	0.70	0.3765	0.70	0.3765	0.70	0.3765	0.70	0.3765			
gama62	1.65	0.9247	1.46	0.7846	1.68	0.8871	9.05	23.5934	8.49	24.1781	9.05	23.9994	1.67	1.1199	1.47	1.0021	1.69	1.1039	1.69	0.9248	1.48	0.8494	1.71	0.9230	1.71	0.9230	1.71	0.9230	1.71	0.9230			
phi1	0.33	7.2265	0.58	1.0662	0.14	5.8006	0.26	0.0438	0.64	0.5382	0.08	4.7825	0.51	3.8008	0.65	0.5453	0.28	3.9720	0.26	0.7720	0.20	0.2159	0.24	0.7488	0.24	0.7488	0.24	0.7488	0.24	0.7488			
phi2	0.53	4.5256	0.77	0.6856	0.60	3.7219	0.80	1.3946	0.80	0.2772	0.77	1.2047	0.80	0.9385	0.81	0.2833	0.77	0.6054	0.70	0.3659	1.20	0.7493	0.64	3.3961	0.64	3.3961	0.64	3.3961	0.64	3.3961			
phi3	111.13	612.4121	123.52	556.1932	112.14	553.5105	0.32	6.9319	1.28	0.6951	0.24	7.0077	0.33	1.3731	0.31	0.7316	0.24	6.8717	0.79	0.3712	0.84	0.3187	0.79	0.7051	0.79	0.7051	0.79	0.7051	0.79	0.7051			
phi4	0.74	0.9471	0.61	0.9300	0.68	1.5390	-0.84	13.0050	-1.10	6.3500	-0.26	8.9593	0.75	1.1060	0.60	0.4361	0.67	1.4216	0.75	0.9495	0.61	0.4713	0.69	1.2914	0.69	1.2914	0.69	1.2914	0.69	1.2914			
phi5	0.78	0.6274	0.82	0.3009	0.76	0.9559	-0.79	12.3723	0.03	3.8186	-0.11	11.1785	0.78	0.6720	0.82	0.3036	0.75	0.7793	0.79	0.5360	0.83	0.3012	0.78	0.7248	0.78	0.7248	0.78	0.7248	0.78	0.7248			
phi6	0.36	6.5653	0.47	0.5487	0.32	5.8443	1757.15	2509.20	1967.32	2649.47	1764.89	2490.93	0.37	6.3994	1.48	9.9528	0.45	6.0959	0.12	5.5569	1.46	0.9310	0.12	5.6497	0.12	5.6497	0.12	5.6497	0.12	5.6497			
phi12	-0.01	-0.01	-0.01	0.7594	-0.01	-0.01	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940	0.00	0.1940			
phi13	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010	0.61	2.4010			
phi23	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782	0.39	2.7782			
phi45	-0.03	-0.03	-0.03	0.1882	-0.03	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882	-0.03	0.1882		
phi46	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567	0.11	0.2567			
phi56	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817	0.22	0.1817			
zeta1	1.18	1.4138	1.03	1.2051	1.23	1.3420	1.19	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782	1.29	0.9782			
zeta12	-0.01	-0.01	-0.01	0.3693	-0.01	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693	-0.01	0.3693		
zeta2	1.27	0.7018	1.20	0.6239	1.33	0.6880	1.15	2.4397	0.22	2.4688	1.13	2.6401	1.28	0.7006	1.21	0.6339	1.32	0.6890	1.28	0.6553	1.20	0.6194	1.32	0.6597	1.29	0.6194	1.32	0.6597	1.29	0.6194			

Tabela C.6: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Máxima Verossimilhança, no Exemplo 1.

[illegible]

Tabela C.7: Medidas-resumo das estimativas dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Mínimos Quadrados Generalizados, no Exemplo 1.

casim1_GLS_1		casim1_GLS_2		casim1_GLS_3		casim2_GLS_1		casim2_GLS_2		casim2_GLS_3		ccornell_GLS_1		ccornell_GLS_2		ccornell_GLS_3		ccurt1_GLS_1		ccurt1_GLS_2		ccurt1_GLS_3		ccurt2_GLS_1		ccurt2_GLS_2		ccurt2_GLS_3																																																					
med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std	med	std																																																				
gamma11	0,86	1,1822	0,87	0,1536	0,90	0,7608	0,87	0,9153	0,87	0,1478	0,89	0,7403	0,00	0,2735	0,00	0,2240	0,01	1,7037	0,93	0,5205	0,98	0,1284	0,94	0,5055	0,92	1,4338	0,90	0,3829	0,91	0,8723																																																			
gamma21	0,38	0,9508	0,33	0,6561	0,36	0,8799	0,37	0,8528	0,32	0,5741	0,37	0,8093	0,00	0,3914	0,00	0,3407	0,01	2,6677	0,46	0,5404	0,46	0,2043	0,45	0,2972	0,38	2,1784	0,30	1,3418	0,35	2,1068																																																			
gamma31	0,89	2,0595	0,62	1,9343	0,88	2,1162	0,92	1,5898	0,64	1,2791	0,91	1,5552	0,00	0,3019	0,00	0,2803	-0,01	1,6227	1,14	2,0436	1,06	1,0835	1,16	1,4199	0,82	9,5148	0,60	9,5767	0,85	9,5216																																																			
gamma42	0,80	0,7012	0,90	0,1552	0,84	0,5744	0,79	0,6506	0,90	0,1587	0,82	0,5377	0,00	0,2350	0,00	0,2035	0,00	0,8874	0,94	0,0889	0,98	0,0303	0,94	0,0811	0,83	1,0255	0,94	0,5405	0,85	0,6697																																																			
gamma52	0,64	0,7937	0,59	0,5538	0,66	0,7507	0,62	0,6995	0,57	0,7487	0,63	0,6915	0,33	0,0891	0,34	0,0816	0,34	0,8028	0,76	0,1565	0,77	0,1511	0,76	0,1557	0,64	1,2361	0,57	0,8709	0,60	1,2108																																																			
gamma62	1,42	1,7392	1,16	1,5835	1,47	1,7170	1,43	1,6834	1,15	1,4569	1,45	1,6852	0,33	0,1727	0,34	0,1596	0,32	1,3499	1,82	0,3606	1,75	0,3702	1,83	0,3610	1,25	12,1018	0,97	12,0830	1,36	12,2806																																																			
phi1	-0,13	5,5731	0,58	0,6148	-0,36	5,3332	-0,16	5,1657	0,58	0,6243	-0,31	4,8627	0,05	0,0639	0,16	0,0899	0,04	0,1112	0,98	1,9300	0,77	0,4324	0,89	1,7051	-0,22	7,0118	0,63	1,0010	-0,37	5,9531																																																			
phi12	0,59	2,4202	0,68	0,3724	0,52	2,7891	0,57	2,6025	0,68	0,3654	0,51	2,5337	0,36	0,2514	0,71	0,3875	0,37	0,3239	0,94	0,6552	0,93	0,1727	0,94	0,5958	0,33	3,6956	0,68	0,8082	0,36	3,4154																																																			
phi13	-0,34	7,9149	1,20	0,9154	-0,30	7,7170	-0,26	8,2199	1,21	0,9498	-0,46	8,4870	0,37	0,2516	0,59	0,3180	0,38	0,2834	14,94	398,20	15,34	399,83	14,81	396,90	83,25	3400,09	83,99	3468,32	79,50	3400,50																																																			
phi14	0,32	2,9927	0,44	0,5381	0,20	2,9770	0,36	2,7182	0,44	0,5319	0,27	2,6969	0,35	0,2583	0,43	0,2352	0,35	0,3202	0,93	0,2091	0,85	0,2335	0,93	0,2104	0,16	4,6370	0,41	1,0626	0,09	4,3215																																																			
phi15	0,53	2,1575	0,71	0,4104	0,49	2,1438	0,49	1,9357	0,70	0,4807	0,50	1,8093	0,08	0,0635	0,19	0,1031	0,08	0,1001	0,93	0,1697	0,93	0,1679	0,93	0,1704	0,41	3,8245	0,68	0,9336	0,46	3,4706																																																			
phi16	-0,31	8,9727	1,56	1,1249	-0,36	9,1563	-0,25	9,0407	1,56	1,2398	-0,35	9,8289	0,33	0,2416	0,75	0,3978	0,32	0,3573	0,88	1,1156	1,20	0,5783	0,88	1,1186	171,78	8882,58	173,46	8617,24	174,47	8606,10																																																			
zeta12	1,30	1,2310	1,18	1,0330	1,35	1,1986	1,30	1,2189	1,18	1,0308	1,35	1,1964	1,52	0,6229	1,51	0,6212	0,90	0,6176	1,18	0,6125	1,18	0,5254	1,20	0,5849	1,15	1,4515	1,00	1,1828	1,23	1,3712																																																			
zeta22	1,37	1,0302	1,24	0,9240	1,45	0,9078	1,39	1,0326	1,26	0,9419	1,47	1,0061	5,22	2,1262	5,20	2,1193	1,32	1,0867				0,00	0,1606					0,00	0,6253																																																				
Simulação																																relic_GLS_1		relic_GLS_2		relic_GLS_3		normal_GLS_1		normal_GLS_2		normal_GLS_3		relic_GLS_1		relic_GLS_2		relic_GLS_3		normal_GLS_1		normal_GLS_2		normal_GLS_3		relic_GLS_1		relic_GLS_2		relic_GLS_3																					
Modelo																																med		std		med		std		med		std		med		std		med		std		med		std		med		std		med		std																			
Medida																																gamma11		0,98		1,8939		0,92		0,7410		0,93		1,1631		0,87		1,0363		0,87		0,1570		0,87		0,8986		0,88		0,9730		0,87		0,1511		0,90		0,7701		0,88		0,7591		0,97		0,1240		0,88		0,5783	
																																gamma21		0,40		3,6793		0,34		1,0755		0,39		1,3560		0,40		0,8727		0,33		0,5533		0,38		0,8117		0,39		0,9422		0,34		0,6800		0,39		0,8187		1,65		2,1537		1,46		2,0618		1,65		2,1455	
																																gamma31		1,21		9,2858		0,99		9,7290		1,22		9,7396		0,95		2,5401		0,66		2,3967		0,93		2,5228		0,92		1,6027		0,64		1,3467		0,90		1,6215		0,86		0,9517		0,82		0,7442		0,85		0,9333	
																																gamma42		0,80		0,6649		0,90		0,1589		0,84		0,5961		1,59		5,8093		1,73		2,7396		1,22		2,9469		0,80		0,7395		0,90		0,1554		0,83		0,5792		0,76		0,6090		0,90		0,1578		0,83		0,6469	
																																gamma52		0,60		0,7767		0,57		0,6261		0,62		0,7468		0,90		4,9355		0,97		2,7971		0,77		3,6772		0,62		0,8253		0,59		0,5717		0,66		0,7361		0,62		0,6466		0,58		0,4836		0,64		0,5803	
																																gamma62		1,41		1,5890		1,11		1,3685		1,42		1,5946		7,35		32,1025		7,12		32,6715		7,44		32,9735		1,42		1,5704		1,14		1,3686		1,46		1,5488		1,45		1,4854		1,14		1,2474		1,46		1,3877	
																																phi1		-0,38		7,9906		0,43		2,1117		-0,54		7,0247		-0,24		6,5415		0,57		0,6074		-0,28		6,2898		-0,05		5,3061		0,58		0,6148		-0,29		4,9656		0,05		1,6156		0,15		0,2646		0,03		1,5174	
																																phi2		0,30		4,4110		0,61		0,9748		0,37		3,9786		0,52		2,9651		0,67		0,3745		0,48		2,3391		0,51		2,3160		0,68		0,4124		0,49		2,2550		0,16		7,4711		1,17		0,8700		0,09		7,3229	
																																phi3		118,34		730,5965		116,02		671,4878		106,99		696,7474		-0,60		9,2785		1,19		0,7967		-0,42		8,9599		-0,40		7,9662		1,22		0,8340		-0,46		8,3533		0,58		2,2713		0,71		0,4120		0,51		2,3852	
																																phi4		0,24		3,4014		0,44		0,5232		0,11		3,5264		-1,74		14,9264		-1,34		7,0937		-0,75		10,3577		0,28		2,9080		0,44		0,5224		0,16		3,2221		0,28		2,9059		0,42		0,5117		0,16		3,4923	
																																phi5		0,54		1,6643		0,71		0,4201		0,50		2,1327		-1,09		11,0630		-0,28		4,1873		-0,25		9,4575		0,48		1,7656		0,71		0,4173		0,41		2,2313		0,50		1,9305		0,71		0,3967		0,50		2,1077	
																																phi6		-0,59		9,4801		1,55		1,0959		-0,33		11,1207		1653,70		3388,94		1745,64		3385,63		1599,87		3352,44		-0,66		9,5278		1,56		1,1158		-0,54		9,2044		-0,76		9,8333		1,54		1,0929		-0,48		8,7849	
																																phi12		0,00		1,0910								0,04		0,2615										0,05		0,2649								0,14		0,2789						0,14		0,2789					
																																phi13		0,54		2,9395		0,30		0,3879		0,30		0,3879		0,30		0,4054								0,03		0,1982								0,03		0,1982						0,03		0,1982					
																																phi23		0,40		2,6714		0,40		2,6714		0,19		0,2893		0,19		0,2893								0,28		0,3081								0,28		0,3081						0,28		0,3081					
																																phi45		0,01		0,2574		0,01		0,2574		-0,78		4,6361		-0,78		4,6361		0,00		0,2638		0,00		0,2638		0,00		0,2638		0,00		0,2638		0,00		0,2638		0,00		0,2638									
																																phi46		0,23		0,3843		0,23		0,3843		2,24		10,5570		2,24		10,5570								0,22		0,3732								0,22		0,3732						0,22		0,3732					
																																phi56		0,33		0,3939		0,33		0,3939		3,46		12,2792		3,46		12,2792								0,33		0,3288								0,33		0,3288						0,33		0,3288					
																																zeta12		1,21		1,6869		1,05		1,4714		1,29		1,6124		1,31		1,2282		1,17		1,0205		1,41		1,4084		1,30		1,2086		1,16		1,0297		1,35		1,1820		0,74		0,6117		0,62		0,4814		0,81		0,5961	
																																zeta22		1,41		1,0209		1,26		0,9316		1,48		1,0316		0,91		2,8756		0,36		2,6670		0,95		3,0775		1,40		1,0217		1,25		0,9322		1,47		0,9972		1,43		0,9972		1,47		0,9972					

Tabela C.8: Medidas de qualidade de ajuste dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Máxima Verossimilhança, no Exemplo 1.

Simulação		casim1_ML_1			casim2_ML_1			casim2_ML_2			casim2_ML_3			ccorrel1_ML_1			ccorrel1_ML_2			ccorrel1_ML_3			ccurt1_ML_1			ccurt1_ML_2			ccurt1_ML_3			ccurt2_ML_1			ccurt2_ML_2			ccurt2_ML_3		
Modelo	Medida	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3			
gamma11	med	1.03	0.8585	0.99	0.0607	1.01	0.7528	1.00	0.7948	0.99	0.0346	1.01	0.7561	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219	0.00	0.2219			
gamma21	std	0.40	0.7400	0.39	0.6496	0.38	0.8051	0.40	0.7630	0.39	0.5841	0.38	0.7826	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128	0.01	0.3128			
gamma31	med	0.98	2.1610	0.79	1.9460	0.94	2.1695	1.02	1.5818	0.81	1.2871	0.99	1.5964	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520	0.00	0.2520			
gamma42	std	0.87	0.4599	0.99	0.0366	0.88	0.5383	0.87	0.4594	0.99	0.0545	0.88	0.5433	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963	0.00	0.1963			
gamma52	med	0.70	0.6203	0.68	0.5333	0.67	0.7152	0.66	0.9570	0.66	0.7090	0.66	0.7015	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726	0.34	0.0726			
gamma62	std	1.58	1.7386	1.39	1.5605	1.58	1.7540	1.58	1.5302	1.37	1.4194	1.56	1.7065	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411	0.34	0.1411			
phi1	med	-0.32	7.0813	0.72	0.6550	-0.93	7.5422	-0.18	6.3025	0.71	0.6579	-1.04	7.6368	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664	0.93	0.3664			
phi2	std	0.91	2.1775	0.93	0.4331	0.80	3.8590	0.85	2.8647	0.93	0.4274	0.79	2.8248	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287	1.86	0.7287			
phi3	med	0.17	9.3083	1.48	1.0727	-0.36	9.3634	0.14	9.2619	1.50	1.1305	-0.70	13.2431	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425	1.15	0.4425			
phi4	std	0.65	3.0992	0.59	0.5398	0.17	4.8455	0.61	3.1178	0.60	0.3350	0.09	4.9573	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813	2.50	0.9813			
phi5	med	0.89	2.1825	0.96	0.4844	0.82	2.3938	0.88	2.0611	0.95	0.5689	0.81	2.5855	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306	0.33	0.1306			
phi6	std	0.47	10.0341	1.82	1.2876	-0.73	12.4232	0.37	10.2314	1.82	1.4144	-0.81	14.3303	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924	1.26	0.4924			
phi12	med	0.00	0.2721	0.00	0.2721	0.00	0.2721	0.00	0.2721	0.00	0.2721	0.00	0.2721	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458	0.92	0.4458			
phi13	std	0.24	0.4272	0.23	0.4292	0.23	0.4292	0.23	0.4292	0.23	0.4292	0.23	0.4292	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148	0.46	0.3148			
phi23	med	0.19	0.3011	0.18	0.3039	0.18	0.3039	0.18	0.3039	0.18	0.3039	0.18	0.3039	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237	0.46	0.4237			
phi45	std	-0.06	0.2510	-0.06	0.2510	-0.06	0.2510	-0.06	0.2510	-0.06	0.2510	-0.06	0.2510	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547	0.01	0.2547			
phi46	med	0.10	0.4123	0.10	0.4123	0.10	0.4123	0.10	0.4123	0.10	0.4123	0.10	0.4123	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952	0.01	0.4952			
phi56	std	0.29	0.4031	0.29	0.4031	0.29	0.4031	0.29	0.4031	0.29	0.4031	0.29	0.4031	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024	0.33	0.2024			
zeta1	med	1.40	1.2290	1.34	0.9625	1.44	1.1985	1.40	1.2064	1.34	0.9600	1.46	1.1850	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247	1.65	0.6247			
zeta12	std	0.01	0.4794	0.01	0.4794	0.01	0.4794	0.01	0.4794	0.01	0.4794	0.00	0.4766	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222	5.63	2.1222			
zeta2	med	1.47	1.0141	1.43	0.8657	1.53	1.0153	1.50	1.0180	1.45	0.8796	1.56	1.0306	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600	2.54	1.0600			
Simulação		coudiers1_ML_1			coudiers1_ML_2			coudiers1_ML_3			coudiers2_ML_1			coudiers2_ML_2			coudiers2_ML_3			normal_ML_1			normal_ML_2			normal_ML_3			relec_ML_1			relec_ML_2			relec_ML_3					
Modelo	Medida	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3			
gamma11	med	1.11	1.4626	0.99	0.0447	1.05	1.0188	1.03	1.0700	1.03	1.0700	0.99	0.0510	0.98	0.7799	1.02	0.8079	0.99	0.0493	1.02	0.7717	0.92	0.6941	0.99	0.0606	0.92	0.6941	1.02	0.7717	0.92	0.6941	0.99	0.0606	0.92	0.6941	1.02	0.7717			
gamma21	std	0.44	1.6841	0.38	0.8006	0.42	1.0675	0.42	0.6598	0.42	0.6598	0.40	0.5865	0.38	0.7659	0.41	0.6728	0.40	0.6779	0.40	0.7887	1.77	2.0711	1.62	2.0393	1.75	2.1169	0.40	0.7887	1.77	2.0711	1.62	2.0393	1.75	2.1169	0.40	0.7887			
gamma31	med	1.40	9.7224	1.20	9.7641	1.36	9.8149	1.02	2.7677	0.83	2.3921	1.00	2.5773	1.00	2.5773	1.00	1.6903	0.80	1.3537	0.95	1.6778	0.92	0.7893	0.90	0.7245	0.87	0.9938	0.95	1.6778	0.92	0.7893	0.90	0.7245	0.87	0.9938	0.95	1.6778			
gamma42	std	0.87	0.4659	0.99	0.0396	0.88	0.5521	1.52	3.9074	0.99	0.0688	1.34	2.5192	0.87	0.4479	0.99	0.0362	0.88	0.5149	0.86	0.4563	0.99	0.0324	0.88	0.6017	0.88	0.6017	0.86	0.4563	0.99	0.0324	0.88	0.6017	0.86	0.4563	0.99	0.0324			
gamma52	med	0.67	0.7158	0.66	0.6195	0.65	0.8015	0.93	4.6563	0.93	4.6563	0.55	0.9150	0.91	2.9972	0.69	0.6142	0.68	0.5536	0.66	0.7281	0.68	0.5405	0.67	0.4669	0.66	0.5414	0.66	0.7281	0.68	0.5405	0.67	0.4669	0.66	0.5414	0.66	0.7281			
gamma62	std	1.56	1.5538	1.34	1.3480	1.53	1.5729	8.13	32.2417	7.77	32.6526	1.57	1.5655	1.36	1.3426	1.58	1.5849	1.59	1.4340	1.37	1.2094	1.58	1.4592	1.58																

Tabela C.9: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Mínimos Quadrados Generalizados, no Exemplo 1.

Simulação Modelo	cassim1									cassim2									ccorrel1									coutliers1								
	1			2			3			1			2			3			1			2			3			1			2			3		
	mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std	
AIC	-5,03	0,0601		6,97	0,0601		-4,01	0,0571		-5,05	0,0591		6,95	0,0591		-4,02	0,0560		640,48	0,2750		379,66	0,1547		640,47	0,2750		-5,01	0,0621		6,87	0,0598		-4,08	0,0573	
CAIC	-46,38	0,0601		1,06	0,0601		-39,46	0,0571		-46,41	0,0591		1,04	0,0591		-35,47	0,0560		516,42	0,2750		291,04	0,1547		516,41	0,2750		-46,37	0,0621		0,96	0,0598		-39,53	0,0573	
chisq_rel	1,28	0,0086		8,97	0,0601		1,33	0,0095		1,28	0,0084		8,95	0,0591		1,33	0,0093		32,50	0,0131		27,31	0,0103		32,50	0,0131		1,28	0,0089		8,87	0,0598		1,32	0,0096	
GFI	1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		0,83	0,0001		0,90	0,0000		0,83	0,0001		1,00	0,0000		1,00	0,0000		1,00	0,0000	
AGFI	0,99	0,0001		0,94	0,0004		0,99	0,0001		0,99	0,0001		0,94	0,0001		0,99	0,0001		0,71	0,0001		0,75	0,0001		0,71	0,0001		0,99	0,0001		0,94	0,0004		0,99	0,0001	
NFI	0,98	0,0001		0,98	0,0001		0,99	0,0001		0,98	0,0001		0,98	0,0001		0,99	0,0001		0,40	0,0001		0,64	0,0001		0,40	0,0001		0,98	0,0001		0,98	0,0001		0,98	0,0001	
RFI	0,97	0,0002		0,70	0,0020		0,97	0,0002		0,97	0,0002		0,70	0,0020		0,97	0,0002		0,60	0,0001		0,52	0,0002		0,57	0,0001		0,96	0,0003		0,60	0,0027		0,96	0,0003	
TLI	0,99	0,0002		0,72	0,0021		0,99	0,0002		0,99	0,0002		0,72	0,0020		0,99	0,0002		0,61	0,0001		0,53	0,0002		0,58	0,0001		0,99	0,0003		0,63	0,0028		0,99	0,0003	
CFI	0,98	0,0001		0,98	0,0001		0,99	0,0001		0,98	0,0001		0,98	0,0001		0,99	0,0001		0,40	0,0001		0,64	0,0001		0,40	0,0001		0,98	0,0001		0,98	0,0001		0,98	0,0001	
IFI	1,00	0,0001		0,99	0,0001		1,00	0,0001		1,00	0,0001		0,99	0,0001		1,00	0,0001		0,40	0,0001		0,65	0,0001		0,40	0,0001		1,00	0,0001		0,98	0,0001		1,00	0,0001	
PGFI	0,47	0,0000		0,07	0,0000		0,40	0,0000		0,47	0,0000		0,07	0,0000		0,40	0,0000		0,62	0,0001		0,48	0,0000		0,62	0,0001		0,47	0,0000		0,07	0,0000		0,40	0,0000	
RMSEAEST	0,01	0,0002		0,09	0,0003		0,02	0,0002		0,01	0,0002		0,09	0,0003		0,02	0,0002		0,18	0,0000		0,16	0,0000		0,18	0,0000		0,01	0,0002		0,09	0,0003		0,02	0,0002	
PNFI	0,49	0,0001		0,05	0,0000		0,39	0,0000		0,49	0,0000		0,05	0,0000		0,39	0,0000		0,60	0,0002		0,48	0,0001		0,56	0,0002		0,49	0,0001		0,05	0,0000		0,39	0,0001	

Simulação												relac											
Modelo						normal						coutliers2						1					
1			2			3			1			2			3			1			2		
Mea	std		Mea	std		Mea	std		Mea	std		Mea	std		Mea	std		Mea	std		Mea	std	
AIC	-4,96	0,0605	7,01	0,0601		-4,03	0,0561		-5,00	0,0606		7,00	0,0606		-4,01	0,0573		-5,09	0,0586		6,91	0,0586	
CAIC	-46,31	0,0605	1,11	0,0601		-39,48	0,0561		-46,36	0,0606		1,09	0,0606		-39,45	0,0573		-46,45	0,0586		1,00	0,0586	
chisq_rel	1,29	0,0086	9,01	0,0601		1,33	0,0093		1,29	0,0087		9,00	0,0606		1,33	0,0095		1,27	0,0084		8,91	0,0586	
GFI	1,00	0,0000	1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000		1,00	0,0000	
AGFI	0,99	0,0001	0,94	0,0004		0,99	0,0001		0,99	0,0001		0,94	0,0004		0,99	0,0001		0,99	0,0001		0,94	0,0004	
NFI	0,98	0,0001	0,98	0,0001		0,98	0,0001		0,98	0,0001		0,98	0,0001		0,99	0,0001		0,99	0,0001		0,99	0,0001	
RFI	0,96	0,0003	0,59	0,0027		0,95	0,0003		0,97	0,0002		0,70	0,0020		0,97	0,0002		0,97	0,0002		0,74	0,0017	
TLI	0,99	0,0003	0,62	0,0028		0,99	0,0003		0,99	0,0002		0,72	0,0021		0,99	0,0002		0,99	0,0002		0,76	0,0018	
CFI	0,98	0,0001	0,98	0,0001		0,98	0,0001		0,98	0,0001		0,98	0,0001		0,99	0,0001		0,99	0,0001		0,99	0,0001	
IFI	1,00	0,0001	0,98	0,0001		1,00	0,0001		1,00	0,0001		0,99	0,0001		1,00	0,0001		1,00	0,0001		0,99	0,0001	
PGFI	0,47	0,0000	0,07	0,0000		0,40	0,0000		0,47	0,0000		0,07	0,0000		0,40	0,0000		0,47	0,0000		0,07	0,0000	
RMSEAEST	0,01	0,0002	0,09	0,0003		0,02	0,0002		0,01	0,0002		0,09	0,0003		0,02	0,0002		0,01	0,0002		0,09	0,0003	
PNFI	0,49	0,0001	0,05	0,0000		0,39	0,0000		0,49	0,0001		0,05	0,0000		0,39	0,0000		0,49	0,0001		0,05	0,0000	

Tabela C.10: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 1000, por Máxima Verossimilhança, no Exemplo 1.

Simulação Modelo	casim1						casim2						ccorrel1						coutliers1					
	1		2		3		1		2		3		1		2		3		1		2		3	
	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std
AIC	-4,93	0,0614	7,07	0,0614	-3,93	0,0582	-4,96	0,0603	7,04	0,0603	-3,94	0,0571	#####	1,3143	990,51	0,7219	2206,00	1,3143	-4,93	0,0633	6,96	0,0610	-4,01	0,0584
CAIC	-46,29	0,0614	1,16	0,0614	-39,38	0,0582	-46,31	0,0603	1,14	0,0603	-39,39	0,0571	#####	1,3143	901,89	0,7219	2081,94	1,3143	-46,28	0,0633	1,06	0,0610	-39,46	0,0584
chisq_rel	1,30	0,0088	9,07	0,0614	1,34	0,0097	1,29	0,0086	9,04	0,0603	1,34	0,0095	107,05	0,0626	68,03	0,0481	107,05	0,0626	1,30	0,0090	8,96	0,0610	1,33	0,0097
GFI	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	0,65	0,0001	0,86	0,0001	0,65	0,0001	1,00	0,0000	1,00	0,0000	1,00	0,0000
AGFI	0,99	0,0001	0,94	0,0004	0,99	0,0001	0,99	0,0001	0,94	0,0004	0,99	0,0001	0,40	0,0002	0,66	0,0001	0,40	0,0002	0,99	0,0001	0,94	0,0004	0,99	0,0001
NFI	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,54	0,0002	0,79	0,0001	0,54	0,0002	0,99	0,0001	0,99	0,0001	0,99	0,0001
RFI	0,99	0,0001	0,87	0,0009	0,99	0,0001	0,99	0,0001	0,87	0,0008	0,99	0,0001	0,69	0,0001	0,72	0,0002	0,67	0,0001	0,98	0,0001	0,83	0,0012	0,98	0,0001
TLI	1,00	0,0001	0,89	0,0009	1,00	0,0001	1,00	0,0001	0,89	0,0009	1,00	0,0001	0,69	0,0001	0,72	0,0002	0,67	0,0001	1,00	0,0001	0,84	0,0012	1,00	0,0001
CFI	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,99	0,0000	0,54	0,0002	0,79	0,0001	0,54	0,0002	0,99	0,0001	0,99	0,0001	0,99	0,0001
IFI	1,00	0,0000	0,99	0,0000	1,00	0,0000	1,00	0,0000	0,99	0,0000	1,00	0,0000	0,54	0,0002	0,79	0,0001	0,54	0,0002	1,00	0,0001	0,99	0,0001	1,00	0,0001
PGFI	0,47	0,0000	0,07	0,0000	0,40	0,0000	0,47	0,0000	0,07	0,0000	0,40	0,0000	0,49	0,0001	0,46	0,0000	0,49	0,0001	0,47	0,0000	0,07	0,0000	0,40	0,0000
RMSEAEST	0,01	0,0002	0,09	0,0003	0,02	0,0002	0,01	0,0002	0,09	0,0003	0,02	0,0002	0,33	0,0001	0,26	0,0001	0,33	0,0001	0,01	0,0002	0,09	0,0003	0,02	0,0002
PNFI	0,50	0,0000	0,05	0,0000	0,40	0,0000	0,50	0,0000	0,05	0,0000	0,40	0,0000	0,80	0,0003	0,59	0,0001	0,75	0,0003	0,50	0,0000	0,05	0,0000	0,40	0,0000

Simulação Modelo	coutliers2						normal						relac					
	1		2		3		1		2		3		1		2		3	
	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std
AIC	-4,87	0,0616	7,11	0,0613	-3,96	0,0571	-4,91	0,0619	7,09	0,0619	-3,93	0,0584	-5,00	0,0598	7,00	0,0598	-4,01	0,0559
CAIC	-46,23	0,0616	1,20	0,0613	-39,41	0,0571	-46,26	0,0619	1,19	0,0619	-39,37	0,0584	-46,36	0,0598	1,09	0,0598	-39,45	0,0559
chisq_rel	1,30	0,0088	9,11	0,0613	1,34	0,0095	1,30	0,0088	9,09	0,0619	1,35	0,0097	1,29	0,0085	9,00	0,0598	1,33	0,0093
GFI	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000
AGFI	0,99	0,0001	0,94	0,0004	0,99	0,0001	0,99	0,0001	0,94	0,0004	0,99	0,0001	0,99	0,0001	0,94	0,0004	0,99	0,0001
NFI	0,99	0,0001	0,99	0,0001	0,99	0,0001	0,99	0,0000	0,99	0,0000	0,99	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000
RFI	0,98	0,0002	0,77	0,0015	0,97	0,0002	0,99	0,0001	0,87	0,0009	0,99	0,0001	0,99	0,0001	0,91	0,0006	0,99	0,0001
TLI	0,99	0,0002	0,79	0,0016	0,99	0,0002	1,00	0,0001	0,89	0,0009	1,00	0,0001	1,00	0,0001	0,92	0,0006	1,00	0,0001
CFI	0,99	0,0001	0,99	0,0001	0,99	0,0001	0,99	0,0000	0,99	0,0000	0,99	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000
IFI	1,00	0,0001	0,99	0,0001	1,00	0,0001	1,00	0,0000	0,99	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000	1,00	0,0000
PGFI	0,47	0,0000	0,07	0,0000	0,40	0,0000	0,47	0,0000	0,07	0,0000	0,40	0,0000	0,47	0,0000	0,07	0,0000	0,40	0,0000
RMSEAEST	0,01	0,0002	0,09	0,0003	0,02	0,0002	0,01	0,0002	0,09	0,0003	0,02	0,0002	0,01	0,0002	0,09	0,0003	0,02	0,0002
PNFI	0,49	0,0000	0,05	0,0000	0,40	0,0000	0,50	0,0000	0,05	0,0000	0,40	0,0000	0,50	0,0000	0,05	0,0000	0,40	0,0000

Tabela C.11: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Mínimos Quadrados Generalizados, no Exemplo 1.

Simulação Modelo			cassim1									cassim2									ccorrel1									coutliers1								
			1			2			3			1			2			3			1			2			3			1			2			3		
Medida	mea	std	mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std				
AIC	-5,56	0,0514	6,42	0,0507		-4,54	0,0473		-5,51	0,0520		6,47	0,0518		-4,50	0,0488		35,17	0,0988		18,05	0,0652		35,09	0,0985		-5,47	0,0531		6,43	0,0515		-4,63	0,0481				
CAIC	-30,80	0,0514	2,81	0,0507		-26,17	0,0473		-30,75	0,0520		2,86	0,0518		-26,13	0,0488		-40,54	0,0988		-36,03	0,0652		-40,62	0,0985		-30,71	0,0531		2,83	0,0515		-26,26	0,0481				
chisq_rel	1,21	0,0073	8,42	0,0507		1,24	0,0079		1,21	0,0074		8,47	0,0518		1,25	0,0081		3,67	0,0047		3,20	0,0043		3,67	0,0047		1,22	0,0076		8,43	0,0515		1,23	0,0080				
GFI	0,97	0,0002	0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,81	0,0002		0,88	0,0002		0,81	0,0002		0,97	0,0002		0,97	0,0002		0,98	0,0002				
AGFI	0,91	0,0005	0,40	0,0036		0,91	0,0006		0,91	0,0005		0,40	0,0037		0,91	0,0006		0,67	0,0004		0,71	0,0004		0,67	0,0004		0,91	0,0005		0,40	0,0036		0,91	0,0006				
NFI	0,87	0,0007	0,87	0,0007		0,89	0,0007		0,87	0,0007		0,87	0,0007		0,89	0,0007		0,37	0,0004		0,61	0,0005		0,37	0,0004		0,86	0,0009		0,86	0,0008		0,88	0,0007				
RFI	0,75	0,0014	-1,54	0,0143		0,72	0,0016		0,74	0,0015		-1,55	0,0146		0,72	0,0017		0,58	0,0003		0,48	0,0006		0,55	0,0003		0,72	0,0017		-1,80	0,0166		0,70	0,0019				
TLI	0,95	0,0019	-2,22	0,0206		0,94	0,0022		0,95	0,0020		-2,23	0,0211		0,93	0,0023		0,66	0,0003		0,57	0,0007		0,63	0,0004		0,94	0,0023		-2,78	0,0267		0,94	0,0026				
CFI	0,87	0,0007	0,87	0,0007		0,89	0,0007		0,87	0,0007		0,87	0,0007		0,89	0,0007		0,37	0,0004		0,61	0,0005		0,37	0,0004		0,86	0,0009		0,86	0,0008		0,88	0,0007				
IFI	0,98	0,0009	0,89	0,0007		0,98	0,0008		0,98	0,0009		0,89	0,0007		0,98	0,0008		0,45	0,0005		0,69	0,0005		0,45	0,0005		0,97	0,0010		0,87	0,0008		0,98	0,0009				
PGFI	0,45	0,0001	0,06	0,0000		0,39	0,0001		0,45	0,0001		0,06	0,0000		0,39	0,0001		0,60	0,0002		0,47	0,0001		0,60	0,0002		0,45	0,0001		0,06	0,0000		0,39	0,0001				
PNFI	0,44	0,0004	0,04	0,0000		0,36	0,0003		0,44	0,0004		0,04	0,0000		0,35	0,0003		0,56	0,0006		0,46	0,0003		0,52	0,0005		0,43	0,0004		0,04	0,0000		0,35	0,0003				
RMSEAEST	0,04	0,0006	0,27	0,0009		0,04	0,0006		0,04	0,0006		0,27	0,0010		0,04	0,0006		0,16	0,0001		0,15	0,0001		0,16	0,0001		0,04	0,0006		0,27	0,0010		0,04	0,0006				

Simulação																		relac															
Modelo			1			2			3			normal			1			2			3			1			2			3			
Medida	mea	std	mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		mea	std		
AIC	-5,38	0,0534		6,51	0,0521		-4,68	0,0490		-5,57	0,0494		6,41	0,0490		-5,66	0,0504		6,34	0,0504		-4,57	0,0481		-5,66	0,0504		6,34	0,0504		-4,57	0,0481	
CAIC	-30,61	0,0534		2,90	0,0521		-26,32	0,0490		-30,81	0,0494		2,81	0,0490		-30,90	0,0504		2,73	0,0504		-26,20	0,0481		-30,90	0,0504		2,73	0,0504		-26,20	0,0481	
chisq_rel	1,23	0,0076		8,51	0,0521		1,22	0,0082		1,20	0,0071		8,41	0,0490		1,19	0,0072		8,34	0,0504		1,24	0,0077		1,19	0,0072		8,34	0,0504		1,24	0,0080	
GFI	0,97	0,0002		0,97	0,0002		0,98	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002		0,97	0,0002	
AGFI	0,91	0,0005		0,40	0,0037		0,91	0,0006		0,91	0,0005		0,41	0,0035		0,92	0,0005		0,41	0,0036		0,91	0,0006		0,92	0,0005		0,41	0,0036		0,91	0,0006	
NFI	0,83	0,0010		0,84	0,0009		0,86	0,0008		0,87	0,0007		0,87	0,0007		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,90	0,0006	
RFI	0,67	0,0019		-2,27	0,0187		0,65	0,0021		0,74	0,0014		-1,55	0,0138		0,72	0,0016		-1,27	0,0128		0,75	0,0015		-1,27	0,0128		0,75	0,0015		0,75	0,0015	
TLI	0,93	0,0028		-3,77	0,0323		0,93	0,0032		0,95	0,0019		-2,23	0,0199		0,94	0,0022		-1,75	0,0176		0,94	0,0020		-1,75	0,0176		0,94	0,0020		0,94	0,0020	
CFI	0,84	0,0010		0,84	0,0009		0,86	0,0008		0,87	0,0008		0,87	0,0007		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,89	0,0006		0,90	0,0006	
IFI	0,97	0,0012		0,85	0,0010		0,98	0,0010		0,98	0,0008		0,89	0,0007		0,98	0,0007		0,90	0,0007		0,98	0,0007		0,98	0,0007		0,90	0,0007		0,98	0,0007	
PGFI	0,45	0,0001		0,06	0,0000		0,39	0,0000		0,45	0,0001		0,06	0,0000		0,45	0,0001		0,06	0,0000		0,39	0,0001		0,45	0,0001		0,06	0,0000		0,39	0,0001	
PNFI	0,42	0,0005		0,04	0,0000		0,34	0,0000		0,44	0,0003		0,04	0,0000		0,44	0,0003		0,04	0,0000		0,36	0,0003		0,44	0,0003		0,04	0,0000		0,36	0,0002	
RMSEAEST	0,04	0,0006		0,27	0,0010		0,04	0,0006		0,04	0,0006		0,27	0,0009		0,04	0,0006		0,26	0,0010		0,04	0,0006		0,26	0,0010		0,04	0,0006		0,04	0,0006	

Tabela C.12: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 100, por Máxima Verossimilhança, no Exemplo 1.

Simulação Modelo		cassim1						cassim2						ccorrel1						coutliers1					
		1		2		3		1		2		3		1		2		3		1		2		3	
		mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std
Medida	AIC	-4,67	0,0622	7,31	0,0618	-3,81	0,0569	-4,60	0,0635	7,38	0,0634	-3,74	0,0588	200,39	0,4187	85,40	0,2393	200,39	0,4187	-4,58	0,0634	7,33	0,0628	-3,90	0,0576
	CAIC	-29,91	0,0622	3,70	0,0618	-25,44	0,0569	-25,84	0,0635	3,78	0,0634	-25,37	0,0588	124,68	0,4187	31,32	0,2393	124,68	0,4187	-25,82	0,0634	3,73	0,0628	-25,53	0,0576
	chisq_rel	1,33	0,0089	9,31	0,0618	1,36	0,0095	1,34	0,0091	9,38	0,0634	1,38	0,0098	11,54	0,0199	7,69	0,0160	11,54	0,0199	1,35	0,0091	9,33	0,0628	1,35	0,0096
	GFI	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,64	0,0004	0,84	0,0002	0,64	0,0004	0,97	0,0002	0,97	0,0002	0,97	0,0002
	AGFI	0,91	0,0005	0,39	0,0038	0,91	0,0006	0,91	0,0006	0,38	0,0039	0,91	0,0006	0,37	0,0007	0,62	0,0005	0,37	0,0007	0,91	0,0006	0,39	0,0038	0,91	0,0006
	NFI	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,52	0,0006	0,77	0,0004	0,52	0,0006	0,93	0,0005	0,93	0,0005	0,94	0,0004
	RFI	0,88	0,0008	-0,21	0,0080	0,87	0,0009	0,88	0,0008	-0,21	0,0082	0,87	0,0009	0,68	0,0004	0,70	0,0006	0,66	0,0005	0,86	0,0010	-0,38	0,0098	0,85	0,0011
	TLI	0,97	0,0009	-0,24	0,0093	0,96	0,0010	0,97	0,0009	-0,25	0,0095	0,96	0,0010	0,70	0,0004	0,72	0,0006	0,68	0,0005	0,96	0,0011	-0,45	0,0119	0,96	0,0012
	CFI	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,52	0,0006	0,77	0,0004	0,52	0,0006	0,93	0,0005	0,93	0,0005	0,94	0,0004
	IFI	0,98	0,0004	0,95	0,0004	0,99	0,0004	0,98	0,0004	0,95	0,0004	0,99	0,0004	0,54	0,0007	0,80	0,0004	0,54	0,0007	0,98	0,0005	0,94	0,0005	0,98	0,0004
	PGFI	0,45	0,0001	0,06	0,0000	0,39	0,0001	0,45	0,0001	0,06	0,0000	0,39	0,0001	0,48	0,0003	0,45	0,0001	0,48	0,0003	0,45	0,0001	0,06	0,0000	0,39	0,0001
	PNFI	0,47	0,0002	0,05	0,0000	0,38	0,0001	0,47	0,0002	0,05	0,0000	0,38	0,0002	0,78	0,0010	0,58	0,0003	0,73	0,0009	0,47	0,0002	0,05	0,0000	0,38	0,0002
	RMSEAEST	0,05	0,0006	0,28	0,0011	0,05	0,0006	0,05	0,0006	0,28	0,0011	0,05	0,0007	0,33	0,0003	0,26	0,0003	0,33	0,0003	0,05	0,0006	0,28	0,0011	0,05	0,0006

Simulação						coutliers2						relac													
Modelo		1		2		3		1		2		3		1		2		3		1		2		3	
Medida	AIC	-4,50	0,0636	7,39	0,0628	-4,02	0,0580	-4,69	0,0596	7,30	0,0594	-3,84	0,0553	-4,78	0,0613	7,22	0,0613	-3,83	0,0566						
	CAIC	-25,74	0,0636	3,78	0,0628	-25,65	0,0580	-29,93	0,0596	3,70	0,0594	-25,47	0,0553	-30,02	0,0613	3,61	0,0613	-25,46	0,0566						
	chisq_rel	1,36	0,0091	9,39	0,0628	1,33	0,0097	1,33	0,0085	9,30	0,0594	1,36	0,0092	1,32	0,0088	9,22	0,0613	1,36	0,0094						
	GFI	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002	0,97	0,0002						
	AGFI	0,91	0,0006	0,38	0,0039	0,91	0,0006	0,91	0,0005	0,39	0,0037	0,91	0,0006	0,91	0,0005	0,39	0,0038	0,91	0,0006						
	NFI	0,90	0,0007	0,90	0,0007	0,91	0,0006	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,95	0,0003	0,95	0,0003	0,95	0,0003						
	RFI	0,79	0,0014	-1,05	0,0137	0,78	0,0015	0,88	0,0008	-0,21	0,0076	0,87	0,0009	0,91	0,0006	0,08	0,0061	0,88	0,0008						
	TLI	0,94	0,0016	-1,37	0,0183	0,94	0,0019	0,97	0,0008	-0,24	0,0089	0,96	0,0010	0,98	0,0007	0,09	0,0067	0,97	0,0009						
	CFI	0,90	0,0007	0,90	0,0007	0,91	0,0006	0,94	0,0004	0,94	0,0004	0,95	0,0004	0,95	0,0003	0,95	0,0003	0,95	0,0003						
	IFI	0,97	0,0007	0,91	0,0007	0,98	0,0007	0,99	0,0004	0,95	0,0004	0,99	0,0004	0,99	0,0003	0,96	0,0003	0,99	0,0003						
	PGFI	0,45	0,0001	0,06	0,0000	0,39	0,0001	0,45	0,0001	0,06	0,0000	0,39	0,0001	0,45	0,0001	0,06	0,0000	0,39	0,0001						
	PNFI	0,45	0,0003	0,04	0,0000	0,37	0,0002	0,47	0,0002	0,05	0,0000	0,38	0,0001	0,48	0,0002	0,05	0,0000	0,38	0,0001						
	RMSEAEST	0,05	0,0006	0,28	0,0011	0,05	0,0007	0,05	0,0006	0,28	0,0010	0,05	0,0006	0,05	0,0006	0,28	0,0011	0,05	0,0006						

Tabela C.14: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 30, por Máxima Verossimilhança, no Exemplo 1.

Simulação		cassim1_ML						cassim2_ML						ccorrel1_ML						coutliers1_ML					
Modelo		1		2		3		1		2		3		1		2		3		1		2		3	
Medida		mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std
AIC	-3,81	0,0683	8,15	0,0681	-3,41	0,0615	-3,70	0,0686	8,25	0,0683	-3,36	0,0610	47,22	0,2497	17,31	0,1538	47,22	0,2497	-3,68	0,0682	8,25	0,0679	-3,45	0,0598	
CAIC	-20,62	0,0683	5,74	0,0681	-17,81	0,0615	-20,51	0,0686	5,85	0,0683	-17,76	0,0610	-3,21	0,2497	-18,71	0,1538	-3,21	0,2497	-20,49	0,0682	5,85	0,0679	-17,85	0,0598	
chisq_rel	1,46	0,0098	10,15	0,0681	1,43	0,0102	1,47	0,0098	10,25	0,0683	1,44	0,0102	4,25	0,0119	3,15	0,0103	4,25	0,0119	1,47	0,0097	10,25	0,0679	1,43	0,0100	
GFI	0,91	0,0005	0,91	0,0005	0,92	0,0005	0,91	0,0005	0,91	0,0005	0,92	0,0005	0,60	0,0007	0,79	0,0004	0,60	0,0007	0,91	0,0005	0,91	0,0005	0,92	0,0005	
AGFI	0,72	0,0015	-0,92	0,0102	0,72	0,0016	0,72	0,0015	-0,94	0,0103	0,72	0,0016	0,31	0,0012	0,51	0,0009	0,31	0,0012	0,72	0,0015	-0,94	0,0102	0,72	0,0016	
NFI	0,82	0,0011	0,82	0,0011	0,85	0,0010	0,82	0,0012	0,82	0,0012	0,85	0,0010	0,48	0,0011	0,72	0,0008	0,48	0,0011	0,81	0,0012	0,81	0,0012	0,84	0,0010	
RFI	0,64	0,0023	-2,55	0,0227	0,63	0,0025	0,64	0,0024	-2,60	0,0236	0,62	0,0025	0,65	0,0007	0,63	0,0010	0,63	0,0008	0,62	0,0025	-2,76	0,0244	0,61	0,0026	
TLI	0,87	0,0032	-4,49	0,1092	0,87	0,0037	0,86	0,0033	-4,38	0,0671	0,86	0,0037	0,71	0,0008	0,72	0,0012	0,69	0,0009	0,85	0,0035	-4,91	0,1170	0,86	0,0039	
CFI	0,82	0,0011	0,82	0,0011	0,85	0,0010	0,82	0,0012	0,82	0,0012	0,85	0,0010	0,48	0,0011	0,73	0,0008	0,48	0,0011	0,81	0,0012	0,81	0,0012	0,85	0,0010	
IFI	0,42	0,0002	0,06	0,0000	0,37	0,0002	0,42	0,0002	0,06	0,0000	0,37	0,0002	0,45	0,0005	0,43	0,0002	0,45	0,0005	0,42	0,0002	0,06	0,0000	0,37	0,0002	
PGFI	0,94	0,0013	0,84	0,0011	0,96	0,0011	0,94	0,0013	0,84	0,0012	0,95	0,0012	0,55	0,0013	0,79	0,0009	0,55	0,0013	0,94	0,0014	0,83	0,0012	0,95	0,0012	
PNFI	0,41	0,0006	0,04	0,0001	0,34	0,0004	0,41	0,0006	0,04	0,0001	0,34	0,0004	0,72	0,0017	0,54	0,0006	0,67	0,0016	0,41	0,0006	0,04	0,0001	0,34	0,0004	
RMSEAEST	0,11	0,0012	0,54	0,0021	0,10	0,0012	0,11	0,0012	0,55	0,0021	0,10	0,0012	0,33	0,0006	0,27	0,0007	0,33	0,0006	0,11	0,0012	0,55	0,0021	0,10	0,0012	

Simulação		coutliers2_ML						normal_ML						relac_ML						
Modelo		1		2		3		1		2		3		1		2		3		
Medida		mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	
AIC	-3,69	0,0691	8,19	0,0684	8,19	0,0684	-3,89	0,0580	-3,76	0,0688	8,19	0,0686	-3,44	0,0608	-3,71	0,0685	8,27	0,0683	-3,12	0,0624
CAIC	-20,49	0,0691	5,79	0,0684	-18,30	0,0580	-20,57	0,0688	-20,57	0,0688	5,79	0,0686	-17,85	0,0608	-20,52	0,0685	5,86	0,0683	-17,52	0,0624
chisq_rel	1,47	0,0099	10,19	0,0684	1,35	0,0097	1,46	0,0097	1,46	0,0098	10,19	0,0686	1,43	0,0101	1,47	0,0098	10,27	0,0683	1,48	0,0104
GFI	0,91	0,0005	0,91	0,0005	0,91	0,0005	0,92	0,0005	0,91	0,0005	0,91	0,0005	0,92	0,0005	0,91	0,0005	0,91	0,0005	0,92	0,0005
AGFI	0,72	0,0015	-0,93	0,0103	0,73	0,0016	0,73	0,0016	0,72	0,0015	-0,93	0,0103	0,72	0,0016	0,72	0,0015	-0,94	0,0103	0,71	0,0017
NFI	0,75	0,0016	0,75	0,0016	0,80	0,0013	0,80	0,0013	0,82	0,0012	0,82	0,0012	0,85	0,0010	0,85	0,0009	0,85	0,0009	0,87	0,0008
RFI	0,50	0,0033	-3,97	0,0324	0,51	0,0033	0,51	0,0033	0,64	0,0023	-2,60	0,0231	0,62	0,0025	0,71	0,0019	-1,92	0,0187	0,68	0,0021
TLI	0,81	0,0121	-7,48	2,7520	0,92	0,0385	0,92	0,0385	0,86	0,0034	-4,32	0,0871	0,85	0,0169	0,89	0,0024	-2,83	0,0340	0,88	0,0028
CFI	0,75	0,0017	0,75	0,0017	0,81	0,0013	0,81	0,0013	0,82	0,0012	0,82	0,0012	0,85	0,0010	0,86	0,0009	0,85	0,0009	0,88	0,0009
IFI	0,42	0,0002	0,06	0,0000	0,37	0,0002	0,37	0,0002	0,42	0,0002	0,06	0,0000	0,37	0,0002	0,42	0,0002	0,06	0,0000	0,37	0,0002
PGFI	0,92	0,0020	0,77	0,0016	0,95	0,0017	0,95	0,0017	0,94	0,0013	0,84	0,0012	0,96	0,0011	0,95	0,0010	0,87	0,0009	0,96	0,0009
PNFI	0,37	0,0008	0,04	0,0001	0,32	0,0005	0,32	0,0005	0,41	0,0006	0,04	0,0001	0,34	0,0004	0,43	0,0005	0,04	0,0000	0,35	0,0003
RMSEAEST	0,11	0,0012	0,54	0,0021	0,09	0,0012	0,09	0,0012	0,11	0,0012	0,54	0,0021	0,10	0,0012	0,11	0,0012	0,55	0,0021	0,11	0,0012

Tabela C.15: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Mínimos Quadrados Generalizados, no Exemplo 1.

Simulação																								
Modelo	cassim1_GLS						cassim2_GLS						ccorrel1_GLS						coutliers1_GLS					
	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3			
Medida	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std		
AIC	-7,36	0,0284	4,49	0,0267	-6,42	0,0265	-7,36	0,0287	4,50	0,0272	-6,40	0,0268	-22,02	0,0513	-16,83	0,0342	-23,35	0,0399	-7,34	0,0291	4,47	0,0264	-6,42	0,0277
CAIC	-19,32	0,0284	2,79	0,0267	-16,67	0,0265	-19,32	0,0287	2,79	0,0272	-16,65	0,0268	-57,89	0,0513	-42,45	0,0342	-59,22	0,0399	-19,30	0,0291	2,77	0,0264	-16,67	0,0277
chisq_rel	0,95	0,0041	6,49	0,0267	0,93	0,0044	0,95	0,0041	6,50	0,0272	0,93	0,0045	0,95	0,0024	0,88	0,0023	0,89	0,0019	0,95	0,0042	6,47	0,0264	0,93	0,0046
GFI	0,84	0,0007	0,85	0,0006	0,87	0,0006	0,84	0,0007	0,85	0,0006	0,87	0,0006	0,64	0,0009	0,76	0,0006	0,67	0,0007	0,84	0,0007	0,85	0,0006	0,87	0,0007
AGFI	0,53	0,0020	-2,25	0,0134	0,54	0,0022	0,53	0,0020	-2,25	0,0136	0,53	0,0022	0,39	0,0016	0,44	0,0015	0,43	0,0012	0,52	0,0021	-2,24	0,0132	0,54	0,0023
NFI	0,57	0,0017	0,57	0,0016	0,64	0,0013	0,57	0,0016	0,58	0,0016	0,64	0,0013	0,26	0,0008	0,51	0,0011	0,31	0,0008	0,56	0,0017	0,57	0,0016	0,64	0,0014
RFI	0,13	0,0033	-7,52	0,0315	0,10	0,0034	0,14	0,0032	-7,46	0,0311	0,10	0,0033	0,51	0,0005	0,34	0,0014	0,50	0,0006	0,12	0,0034	-7,56	0,0316	0,09	0,0035
TLI	-1,01	1,5546	29,59	9,3182	-1,68	2,8829	-1,73	1,3200	61,95	39,44	-1,06	0,7851	1,12	0,0038	1,76	0,1681	1,22	0,0054	-1,92	1,3969	27,43	10,23	-0,76	0,9532
CFI	0,57	0,0018	0,54	0,0018	0,64	0,0014	0,57	0,0017	0,54	0,0017	0,64	0,0014	1,13	0,0149	0,52	0,0011	0,33	0,0008	0,56	0,0018	0,53	0,0018	0,64	0,0015
IFI	1,17	0,0266	0,62	0,0017	1,11	0,0055	1,29	0,1203	0,62	0,0017	1,13	0,0149	0,48	0,0007	1,23	0,0053	1,34	0,3685	1,16	0,0405	0,61	0,0017	1,12	0,0061
PGFI	0,39	0,0003	0,06	0,0000	0,35	0,0003	0,39	0,0003	0,06	0,0000	0,35	0,0003	0,39	0,0003	0,41	0,0003	0,50	0,0005	0,39	0,0003	0,06	0,0000	0,35	0,0003
PNFI	0,28	0,0008	0,03	0,0001	0,26	0,0005	0,28	0,0008	0,03	0,0001	0,26	0,0005	0,39	0,0012	0,38	0,0008	0,43	0,0011	0,28	0,0009	0,03	0,0001	0,25	0,0006
RMSEAEST	0,05	0,0009	0,62	0,0016	0,05	0,0009	0,05	0,0009	0,62	0,0016	0,05	0,0010	0,03	0,0007	0,02	0,0005	0,01	0,0004	0,05	0,0009	0,62	0,0016	0,05	0,0010
Simulação																								
Modelo	coutliers2_GLS						normal_GLS						relac_GLS											
Medida	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3	1	2	3			
AIC	-6,90	0,0399	4,69	0,0321	-6,25	0,0342	-7,43	0,0284	4,43	0,0269	-6,45	0,0264	-7,40	0,0281	4,51	0,0272	-6,30	0,0261	-6,30	0,0261	-6,30	0,0261		
CAIC	-18,86	0,0399	2,98	0,0321	-16,50	0,0342	-19,38	0,0284	2,72	0,0269	-16,70	0,0264	-19,35	0,0281	2,80	0,0272	-16,55	0,0261	-16,55	0,0261	-16,55	0,0261		
chisq_rel	1,01	0,0057	6,69	0,0321	0,96	0,0057	0,94	0,0041	6,43	0,0269	0,92	0,0044	0,94	0,0040	6,51	0,0272	0,95	0,0043	0,95	0,0043	0,95	0,0043		
GFI	0,83	0,0009	0,84	0,0008	0,86	0,0008	0,84	0,0007	0,85	0,0006	0,87	0,0006	0,87	0,0006	0,84	0,0007	0,86	0,0006	0,86	0,0006	0,86	0,0006		
AGFI	0,49	0,0028	-2,35	0,0160	0,52	0,0029	0,53	0,0020	-2,22	0,0135	0,54	0,0022	0,54	0,0020	0,59	0,0015	0,53	0,0022	0,53	0,0022	0,53	0,0022		
NFI	0,52	0,0023	0,55	0,0019	0,62	0,0018	0,57	0,0016	0,58	0,0016	0,64	0,0013	0,58	0,0015	0,59	0,0015	0,64	0,0013	0,64	0,0013	0,64	0,0013		
RFI	0,04	0,0045	-8,08	0,0380	0,04	0,0044	0,14	0,0033	-7,47	0,0314	0,10	0,0034	0,17	0,0031	-7,20	0,0299	0,11	0,0032	0,11	0,0032	0,11	0,0032		
TLI	0,86	0,7169	-22,77	36,15	-1,15	0,60	1,52	1,9918	86,27	60,57	-0,58	0,5785	-4,78	4,4815	32,27	10,68	-0,88	0,8120	-0,88	0,8120	-0,88	0,8120		
CFI	0,52	0,0024	0,50	0,0021	0,62	0,0019	0,57	0,0018	0,54	0,0018	0,64	0,0014	0,59	0,0015	0,56	0,0017	0,65	0,0014	0,65	0,0014	0,65	0,0014		
IFI	1,11	0,0235	0,59	0,0020	1,22	0,0893	1,15	0,0078	0,62	0,0017	1,12	0,0050	1,11	0,0046	0,63	0,0016	1,08	0,0034	1,08	0,0034	1,08	0,0034		
PGFI	0,39	0,0004	0,06	0,0001	0,35	0,0003	0,39	0,0003	0,06	0,0000	0,35	0,0003	0,39	0,0003	0,06	0,0000	0,35	0,0002	0,35	0,0002	0,35	0,0002		
PNFI	0,26	0,0011	0,03	0,0001	0,25	0,0007	0,28	0,0008	0,03	0,0001	0,26	0,0005	0,29	0,0008	0,03	0,0001	0,26	0,0005	0,26	0,0005	0,26	0,0005		
RMSEAEST	0,06	0,0011	0,63	0,0017	0,05	0,0011	0,05	0,0009	0,61	0,0016	0,05	0,0009	0,05	0,0009	0,05	0,0009	0,62	0,0016	0,05	0,0010	0,62	0,0016		

Tabela C.16: Medidas de qualidade de ajuste dos parâmetros dos Modelos 1 a 3 sobre todas as amostras simuladas de tamanho 15, por Máxima Verossimilhança, no Exemplo 1.

Simulação		cassim1_ML						cassim2_ML						ccorrel1_ML						coutliers1_ML					
Modelo		1		2		3		1		2		3		1		2		3		1		2		3	
Medida		mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	mea	std
AIC	-1,77	0,0810	10,16	0,0806	-2,55	0,0672	-1,75	0,0822	10,17	0,0819	-2,51	0,0685	19,58	0,2092	7,00	0,1494	19,58	0,2092	-1,83	0,0794	10,09	0,0790	-2,68	0,0662	
CAIC	-13,72	0,0810	8,45	0,0806	-12,80	0,0672	-13,71	0,0822	8,46	0,0819	-12,76	0,0685	-16,29	0,2092	-18,62	0,1494	-16,29	0,2092	-13,78	0,0794	8,38	0,0790	-12,92	0,0662	
chisq_rel	1,75	0,0116	12,16	0,0806	1,58	0,0112	1,75	0,0117	12,17	0,0819	1,58	0,0114	2,93	0,0100	2,47	0,0100	2,93	0,0100	1,74	0,0113	12,09	0,0790	1,55	0,0110	
GFI	0,83	0,0007	0,83	0,0007	0,85	0,0007	0,83	0,0007	0,83	0,0007	0,85	0,0007	0,55	0,0009	0,73	0,0006	0,55	0,0009	0,83	0,0007	0,83	0,0007	0,85	0,0007	
AGFI	0,48	0,0022	-2,65	0,0152	0,48	0,0025	0,48	0,0022	-2,65	0,0155	0,48	0,0025	0,23	0,0015	0,35	0,0014	0,23	0,0015	0,48	0,0021	-2,64	0,0150	0,49	0,0025	
NFI	0,68	0,0018	0,68	0,0018	0,76	0,0014	0,68	0,0018	0,69	0,0018	0,76	0,0014	0,42	0,0014	0,65	0,0012	0,42	0,0014	0,68	0,0019	0,68	0,0018	0,75	0,0015	
RFI	0,36	0,0036	-5,31	0,0358	0,39	0,0036	0,37	0,0037	-5,28	0,0364	0,39	0,0036	0,61	0,0009	0,53	0,0015	0,58	0,0010	0,35	0,0037	-5,45	0,0368	0,39	0,0037	
TLI	0,63	0,0153	-19,22	18,26	0,70	0,0442	0,59	0,0310	-12,04	2,2847	0,73	0,0414	0,71	0,0011	0,66	0,0020	0,68	0,0012	0,60	0,0202	-14,31	4,2359	0,63	0,2175	
CFI	0,69	0,0019	0,67	0,0019	0,76	0,0015	0,69	0,0019	0,68	0,0019	0,76	0,0015	0,42	0,0014	0,65	0,0012	0,42	0,0014	0,68	0,0019	0,67	0,0019	0,76	0,0015	
IFI	0,85	0,0027	0,70	0,0018	0,91	0,0020	0,85	0,0024	0,71	0,0019	0,91	0,0020	0,52	0,0018	0,76	0,0014	0,52	0,0018	0,83	0,0138	0,70	0,0019	0,92	0,0022	
PGFI	0,39	0,0003	0,06	0,0000	0,34	0,0003	0,39	0,0003	0,06	0,0000	0,34	0,0003	0,41	0,0007	0,39	0,0003	0,41	0,0007	0,39	0,0003	0,06	0,0000	0,34	0,0003	
PNFI	0,34	0,0009	0,03	0,0001	0,30	0,0006	0,34	0,0009	0,03	0,0001	0,30	0,0006	0,62	0,0021	0,49	0,0009	0,58	0,0020	0,34	0,0009	0,03	0,0001	0,30	0,0006	
RMSEAEST	0,20	0,0018	0,86	0,0032	0,17	0,0019	0,20	0,0019	0,86	0,0033	0,17	0,0019	0,36	0,0010	0,31	0,0012	0,36	0,0010	0,20	0,0018	0,86	0,0032	0,17	0,0018	

Simulação		normal_ML						relac_ML						
Modelo		1		2		3		1		2		3		
Medida		mea	std	mea	std	mea	std	mea	std	mea	std	mea	std	
AIC	-1,61	0,0816	10,26	0,0813	-2,86	0,0658	-1,91	0,0810	-1,68	0,0824	10,26	0,0821	-2,00	0,0718
CAIC	-13,56	0,0816	8,55	0,0813	-13,11	0,0658	-13,86	0,0810	-13,64	0,0824	8,56	0,0821	-12,25	0,0718
chisq_rel	1,77	0,0117	12,26	0,0813	1,52	0,0110	1,73	0,0116	1,76	0,0118	12,26	0,0821	1,67	0,0120
GFI	0,82	0,0007	0,83	0,0007	0,86	0,0007	0,83	0,0007	0,82	0,0007	0,83	0,0007	0,85	0,0007
AGFI	0,47	0,0022	-2,67	0,0152	0,50	0,0025	0,48	0,0022	0,47	0,0022	-2,66	0,0155	0,46	0,0026
NFI	0,63	0,0021	0,63	0,0021	0,73	0,0016	0,68	0,0019	0,73	0,0016	0,73	0,0016	0,78	0,0014
RFI	0,25	0,0042	-6,40	0,0414	0,32	0,0039	0,36	0,0037	0,45	0,0032	-4,46	0,0321	0,45	0,0034
TLI	0,55	0,0516	-16,01	11,84	0,48	0,2367	0,62	0,0183	0,69	0,0059	-10,27	1,6803	0,72	0,0081
CFI	0,63	0,0022	0,61	0,0022	0,73	0,0016	0,69	0,0019	0,73	0,0017	0,72	0,0017	0,78	0,0014
IFI	0,82	0,0031	0,65	0,0021	0,92	0,0034	0,85	0,0025	0,87	0,0020	0,74	0,0016	0,91	0,0017
PGFI	0,38	0,0003	0,06	0,0000	0,34	0,0003	0,39	0,0003	0,38	0,0003	0,06	0,0000	0,34	0,0003
PNFI	0,31	0,0011	0,03	0,0001	0,29	0,0006	0,34	0,0009	0,36	0,0008	0,04	0,0001	0,31	0,0005
RMSEAEST	0,20	0,0018	0,87	0,0032	0,16	0,0018	0,20	0,0018	0,20	0,0019	0,87	0,0033	0,18	0,0019

Referências

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, AC-19: 716-723.
- Anderson, T. W. e Rubin, H. (1956). Statistical inference in factor analysis. *Proceedings of the Third Berkeley Symposium for Mathematical Statistics Problems*, 5: 111-150.
- Arbuckle, J. L. (1999). *AMOS 4.0 User's Guide*. SmallWaters Corporation.
- Asparouhov, T. e Muthén, B. (2009). Exploratory structural equation modeling. *Structural Equation Modeling*, 16: 397-438.
- Babakus, E., Ferguson, C. E. Jr., e Jöreskog, K. G. (1987). The Sensitivity of Confirmatory Maximum Likelihood Factor Analysis to Violations of Measurement Scale and Distributional Assumptions. *Journal of Marketing Research*, 24: 222-228.
- Bartolo, A. D. (2000). Human capital estimation through structural equation models with some categorical observed variables. *IRISS Working Paper*, 2000-02.
- Bentler, P. M. (1985). *Theory and implementation of EQS: A structural equation program*. Los Angeles: BMDP Statistical Software.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological Bulletin*, 107: 238-246.
- Bentler, P. M. e Bonett, D. G. (1980). Significance tests and Goodnessof- Fit in the analysis of covariance structures. *Psychological Bulletin*, 88: 588-600.

- Bentler, P. M. e Weeks, D. G. (1980). Multivariate analysis with latent variables. Em: Krishnaiah, P. R. e Kanai, L. (eds.), *Handbook of Statistics*, 2: 747-771.
- Bistaffa B. C. (2010). *Incorporação de indicadores categóricos ordinais em modelos de equações estruturais*. Dissertação de Mestrado, Instituto de Matemática e Estatística, Universidade de São Paulo.
- Blalock, H. M. (1963). Making causal inferences for unmeasured variables from correlations among indicators. *American Journal of Sociology*, 69: 53-62.
- Bock, R. D. e Bargmann, R. E. (1966). Analysis of covariance structures. *Psychometrika*, 31: 507-534.
- Bollen, K. A. (1984). Multiple indicators: Internal consistency or no necessary relationship? *Quality and Quantity*, 18: 377-385.
- Bollen, K. A. (1986). Sample size and Bentler and Bonett's nonnormed fit index. *Psychometrika*, 51: 375-377.
- Bollen, K. A. (1989a). *Structural Equations with Latent Variables*. Wiley, New York, USA.
- Bollen, K. A. (1989b). A new incremental fit index for general structural equation models. *Sociological Methods and Research*, 17: 303-316.
- Bollen, K. A. e Lennox, R. (1991). Conventional wisdom on measurement: A structural equation perspective. *Psychological Bulletin*, 110: 305-314.
- Bozdogan, H. (1987). Model selection and Akaike's Information Criterion (AIC): The general theory and its analytical extensions. *Psychometrika*, 52: 345-370.
- Browne, M. W. (1974). Generalized least square estimators in the analysis of covariance structures. *South Africa Statistical Journal*, 8: 1-24.
- Browne, M. W. (1982). Covariance structures. Em: D.M.Hawkins (ed.), *Topics in applied*

multivariate analysis. London: Cambridge University Press.

Browne, M. W. (1984). Asymptotic distribution free methods in analysis of covariance structures. *British Journal of Mathematical and Statistical Psychology*, 37: 62-83.

Campana, A. N., Tavares, M. C. e Silva, D. (2009). Modelagem de Equações Estruturais: Apresentação de uma abordagem estatística multivariada para pesquisas em Educação Física. *Motricidade (Santa Maria da Feira)*, 5: 59-80.

Ferguson, C. A., Bowman, A. W., Scott, E. M. e Carvalho, L. (2009). Multivariate varying-coefficient models for an ecological system. *Environmetrics*, 20 (4): 460-476.

Goldberger, A. S. (1964). *Econometric Theory*. Wiley, New York, USA.

Goldberger, A. S. (1972). Structural equation methods in the social sciences. *Econometrica*, 40: 979-1001.

Hair, J. F., Black, W. C., Babin, B. J. e Anderson, R. E. (2010). *Multivariate Data Analysis*. 7. Ed. Upper Saddle River: Prentice-Hall.

Iriondo, J. M., Albert, M. J. e Escudero, A. (2003). Structural equation modelling: an alternative for assessing causal relationships in threatened plant populations. *Biological Conservation*, 113 (3): 367-77.

James, L. R., Mulaik, S. A. e Brett, J. M. (1982). *Causal Analysis: Assumptions, Models and Data*, Sage, Beverly Hills.

Johnson, D. R. e Creech, J. C. (1983) . Ordinal measures in multiple indicator models: A simulation study of categorization error. *American Sociological Review*, 48: 398-40.

Jöreskog, K. G. (1967). Some contributions to maximum likelihood factor analysis. *Psychometrika*, 32: 443-482.

Jöreskog, K. G. (1969). A general approach to confirmatory maximum likelihood factor analysis. *Psychometrika*, 34: 183-202.

- Jöreskog, K. G. (1973). A general method for estimating a linear structural equation system. Em: Goldberger, A. S. e Duncan, O. D. (eds.), *Structural Equation Models in the Social Sciences*, New York, USA. Academic Press, 85-112.
- Jöreskog, K. G. e Goldberger, A. S. (1972). Factor analysis by generalized least square. *Psychometrika*, 37: 243-260.
- Jöreskog, K. G. e Lawley, D. N. (1968). New methods in maximum likelihood factor analysis. *British Journal of Mathematical Statistics*, 21: 85-96.
- Jöreskog, K. G. e Sörbom, D. (1986). *Lisrel VI: Analysis of Linear Structural Relationships by Maximum Likelihood and Least Square Methods*. Uppsala, Sweden: Scientific Software, Inc.
- Jöreskog, K. G. e Sörbom, D. (1988). *Lisrel 7: A Guide to the program and applications*. SPSS, Chicago.
- Kaplan, D. (2000). *Structural Equation Modeling: foundations and extensions*. Sage: Thousand Oaks.
- Keesing, J. W. (1972). *Maximum Likelihood Approaches to Causal Analysis*. Tese de Doutorado, Department of Education, University of Chicago.
- Kline, R. B. (2010). *Principles and Practice of Structural Equation Modeling*. 3. Ed. New York, Guilford. Press.
- Lawley, D. N. (1940). The estimation of factor loadings by the method of maximum likelihood. *Proceedings of the Royal Society of Edinburgh*, 60: 64-82.
- Lawley, D. N. e Maxwell, A. E. (1962). Factor Analysis as a Statistical Method. *The Statistician*, 12: 209-229.
- MacCallum, R. C. e Austin, J. T. (2000). Applications of structural equation modeling in psychological research. *Annual Review of Psychology*, 51: 201-226.

- Melhado, T. T. (2004). *Medidas de ajuste de modelos de equações estruturais*. Dissertação de Mestrado. Universidade de São Paulo.
- Mulaik, S. A., James, L. R., Van Alstine, J., Bennett, N., Lind, S. e Stilwell, C. D. (1989). Evaluation of goodness-of-fit indices for structural equation models. *Psychological Bulletin*, 105: 430-445.
- Muthén, B. (1978). Contributions to factor analysis of dichotomous variables. *Psychometrika*, 43: 551-560.
- Muthén, B. (1984). A general structural equation model with dichotomous, ordered categorical, and continuous latent variable indicators. *Psychometrika*, 49: 115-132.
- Muthén, B. e Kaplan, D. (1985). A comparison of some methodologies for the factor analysis of non-normal likert variables. *British Journal of Mathematical and Statistical Psychology*, 38: 171-189.
- Pedhazur, E. J. (1991). *Measurement, design and analysis - an integrated approach*. Hillsdale, New Jersey, Lawrence Erlbaum Associates Inc.
- Pilati, R. e Laros, J. (2007). Modelos de Equações Estruturais em Psicologia: Conceitos e Aplicações. *Psicologia: Teoria e Pesquisa*, 23: 205-216.
- R Development Core (2011). *R: a language and environment for statistical computing*. <http://www.R-project.org>.
- Raminelli, J. A., Cirillo, M. A., Barroso, L. P. (2010). Modelagem de equações estruturais aplicada a um estudo da qualidade de vida considerando critérios da OMS. Em: *Sinape*, 2010.
- Sanches, M. R. (2005). *Indicadores formativos em modelos de equações estruturais*. Dissertação de Mestrado, Instituto de Matemática e Estatística, Universidade de São Paulo.
- SAS Institute Inc. (2010). *SAS/STAT® 9.22 User's Guide*. Cary, NC: SAS Institute Inc.

- Schwarz, G. (1978). Estimating the Dimension of a Model. *Annals of Statistics*, 6: 461-464.
- Sclove, L. S. (1987). Application of Model-Selection Criteria to Some Problems in Multivariate Analysis. *Psychometrika*, 52: 333-343.
- Skrondal, A. e Rabe-Hesketh, S. (2005). Structural equation modeling: categorical variables. Em: Everitt, B. e Howell, D., (eds.) *Encyclopedia of statistics in behavioral science*. John Wiley & Sons, London.
- Spearman, C. (1904). General intelligence, objectively determined and mensured. *American Journal of Psychology*, 15: 201-293.
- Steiger, J. H. e Lind, J. C. (1980). *Statistically based test for the number of common factors*. Paper apresentado no Psychometric Society Annual Meeting, Iowa City, IA.
- Tanaka, J. S. e Huba, G. J. (1985). A fit index for covariance structure models under arbitrary gls estimation. *British Journal of Mathematical and Statistical Psychology*, 38: 197-201.
- Tucker, L. R. e Lewis, C. (1973). A reliability coefficient for maximum likelihood factor analysis. *Psychometrika*, 38: 1-10.
- Veraszto, E. V., Cunha, A. M., Silva, D., Miranda, N. A., Simon, F. O. e Barros Filho, J. (2009). Relações de causalidade entre concepções e atitudes frente ao desenvolvimento tecnológico: um estudo da opinião de graduandos do Estado de São Paulo. *VII ENPEC - Encontro Nacional de Pesquisadores em Educação em Ciências, 2009, Florianópolis/SC. Anais*. Florianópolis/SC, 1: 1-16.
- Veraszto, E. V., Silva, D., Barros Filho, J., Miranda, N. A., García, F., Amaral, S. F., Simon, F. O. e Camargo, E. P. (2011). Influência da sociedade no desenvolvimento tecnológico: um estudo das concepções de graduandos brasileiros do Estado de São Paulo. *Revista Iberoamericana de Ciencia, Tecnología y Sociedad*, 6: 1-30.

Vieira, K. M. (2006). *Modelagem de equações estruturais aplicada à reação a splits: integrando as hipóteses de liquidez, sinalização e nível ótimo de preço*. Tese de Doutorado, Escola de Administração, Universidade Federal do Rio Grande do Sul.

Wiley, D. E. (1973). The identification problem for structural equation models with unmeasured variables. Em: Goldberger, A. S. e Duncan, O. D. (eds.), *Structural Equation Models in the Social Sciences*, New York, USA. Academic Press, 69-83.

Wright, S. (1918). On the nature of size factors. *Genetics*, 3: 367-374.

Wright, S. (1921). Correlation and causation. *Journal of Agricultural Research*, 20: 557-585.

Wright, S. (1934). The method of path coefficients. *Annals of Mathematical Statistics*, 5: 161-215.

Wright, S. (1960). Path coefficients and path regressions: Alternative or complementary concepts? *Biometrics*, 16: 189-202.