



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE MATEMÁTICA  
DEPARTAMENTO DE ESTATÍSTICA



# **Análise Fatorial Confirmatória através dos Softwares R e Mplus**

Daniela Andrea Droguett León  
Orientadora: Jandyra Maria Guimarães Fachel

Porto Alegre, 6 Julho de 2011

Universidade Federal do Rio Grande do Sul  
Instituto de Matemática  
Departamento de Estatística

# **Análise Fatorial Confirmatória através dos Softwares R e Mplus**

Autor: Daniela Andrea Droguett León

Monografia apresentada para obtenção  
do grau de Bacharel em Estatística.

Banca Examinadora:  
Professor Phd. Professora Jandyra Guimarães Fachel  
Psicóloga Tércia Davoglio, Doutoranda em Psicologia

Porto Alegre, 6 de Julho de 2011.

Agradeço a Deus por todos os dias vividos.

A Angelo pelo amor, apoio e carinho ao longo destes anos juntos.

À minha filha, Maria de la Gracia por seu infinito amor e por fazer meus dias mais belos.

À professora Jandyra por todo seu carinho, dedicação e amizade

Aos meus pais por todo seu ensinamento, carinho e atenção

À minha irmã Erika por ser meu pilar e companhia mesmo a distância e a minha sobrinha Mariana por ser me fazer tão feliz.

À minha tia Margarita por todo o interesse de nutrir minha alma com livros tão belos.

Além disso, e em especial, a todos os brasileiros que apoiaram, através de seus impostos, uma educação pública, gratuita e de qualidade.

# RESUMO

Nesta monografia apresentamos o trabalho desenvolvido com a finalidade de estudar a técnica de análise fatorial confirmatória (AFC) no que diz respeito à teoria e também a aplicação da técnica por meio computacional. São apresentados diversos conceitos e etapas da AFC, como por exemplo, a construção de diagramas de caminhos, conceito e diferenciação de variáveis latentes e observáveis, identificação e processo de modelagem estatística, estimação dos parâmetros, entre outros. Para tal, realizou-se uma revisão na literatura e foram desenvolvidos dois tutoriais: um mediante utilização do software R e outro mediante o software Mplus, este último com um estimador focado em variáveis categóricas (WLSMV).

Foi apresentado uma aplicação e resultados da AFC para a validação de um instrumento de medida (com escala ordinal) nos dois softwares acima citados provenientes de uma pesquisa real. Também, foi avaliado o desempenho de ambos os softwares a fim de ressaltar similaridades, diferenças e limitações de cada um.

# SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>6</b>
1.1 Motivação e Justificativa do Trabalho .....	7
1.2 Objetivos .....	7
1.3 Estrutura do Trabalho .....	9
<b>2 ANÁLISE FATORIAL CONFIRMATÓRIA .....</b>	<b>11</b>
2.1. Introdução .....	11
2.2 Especificação e Identificação do Modelo .....	20
2.3 Métodos de Estimação .....	22
2.4 Avaliação do Modelo.....	26
2.4.1 Índices de ajuste do modelo.....	27
2.4.2 Verificação do ajuste através dos Resíduos e Índices de Modificação. ....	31
2.4.3 Interpretabilidade dos parâmetros estimados.....	33
<b>3 APLICAÇÃO DA ANÁLISE FATORIAL CONFIRMATÓRIA PARA UM INSTRUMENTO DE MEDIDA NOS SOFTWARES R E MPLUS.....</b>	<b>35</b>
3.1. Especificação e identificação dos modelos.....	36
3.2. Resultados das Análises Fatoriais Confirmatórias usando o software R ...	48
3.3 Resultados das Análises Fatoriais Confirmatórias usando o software Mplus .....	53
<b>4 TUTORIAIS DA ANÁLISE FATORIAL CONFIRMATÓRIA NOS SOFTWARES R E MPLUS.....</b>	<b>64</b>
4.1 Tutorial da Análise Fatorial Confirmatória no software Mplus .....	64
4.2 Tutorial da Análise Fatorial Confirmatória no pacote SEM do software R ..	70
<b>5 COMPARAÇÃO DAS ANÁLISES E RESULTADOS ENTRE R E MPLUS FATORES .....</b>	<b>76</b>
<b>6 CONCLUSÕES .....</b>	<b>84</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS.....</b>	<b>86</b>
<b>ANEXOS .....</b>	<b>89</b>

## 1 INTRODUÇÃO

A técnica de Análise Fatorial é o nome geral dado a um tipo de método estatístico multivariado cujo propósito principal é decifrar a estrutura fatorial subjacente a um conjunto de dados correlacionados. Essa técnica analisa a estrutura das inter-relações entre um grande número de variáveis não exigindo nenhuma distinção entre variáveis dependentes e independentes. Utilizando essa informação, baseia-se no cálculo de um conjunto de dimensões latentes, conhecidas como Fatores, que procuram explicar essas relações. É, portanto, uma técnica de redução de dados, já que a informação contida no conjunto de variáveis observadas pode ser expressa por um número menor de dimensões representadas por tais fatores. Pode-se dizer que uma análise fatorial só tem sentido se a condição de parcimônia (procura do modelo mais simples) e interpretabilidade (solução coerente e tenha sentido ao pesquisador) estão presentes.

A Análise Fatorial pode ser do tipo exploratório ou confirmatório. A Análise Fatorial Exploratória ou AFE (*Exploratory Factor Analysis - EFA*) tem a característica de não se conhecer a priori o número de fatores e é na aplicação empírica onde esse número é determinado. Assim, a EFA é utilizada pelos pesquisadores como uma técnica exploratória ou descritiva para determinar apropriadamente o número de fatores comuns e para descobrir quais variáveis mensuradas são indicadores razoáveis de várias dimensões latentes. Já a Análise Fatorial Confirmatória ou AFC (*Confirmatory Factor Analysis - CFA*) é um procedimento que forma parte dos modelos de equações estruturais (*Structural Equation Models, SEM*), cujo propósito se centra no estudo de modelos para instrumentos de medida, ou seja, em analisar as relações entre um conjunto de indicadores ou variáveis observadas e uma ou mais variáveis latentes ou fatores. Os indicadores podem ser, por exemplo, os itens de um teste, as pontuações obtidas por sujeitos em diferentes escalas, ou nos resultados que provêm de instrumentos de medida.

A AFC tem se tornado nos últimos anos um dos procedimentos de análises mais utilizados, onde uma característica essencial é que o investigador deve definir primeiramente todos os aspectos relevantes do modelo. Esses aspectos devem estar solidamente fundamentados na teoria prévia e na evidência conhecida. Assim, deve-se especificar com anterioridade à análise quais fatores e quais indicadores formam o modelo, se existe relação ou não entre os fatores e assim sucessivamente.

A AFC é realizada através de vários softwares estatísticos, entre eles, os mais conhecidos são, LISREL, AMOS, EQS, SAS CALLIS e, mais recentemente, o Mplus e R.

### 1.1 MOTIVAÇÃO E JUSTIFICATIVA DO TRABALHO

O presente trabalho foi motivado por duas razões:

- a) Interesse em aprofundar conhecimentos na área de estatística multivariada aplicada às ciências sociais e ciências do comportamento. Nessas áreas, numerosos pesquisadores não contam com especialistas (no caso, estatísticos) que possam auxiliar no método adequado de, por exemplo, avaliação psicométrica de instrumentos de medida, testes ou validação de construtos.
- b) Possibilidade de analisar os dados de uma pesquisa real pertencente a um estudante de doutorado, cujo objetivo é validar os construtos existentes em uma escala para medir traços de personalidade.

### 1.2 OBJETIVOS

O objetivo geral deste trabalho é caracterizar, de maneira prática e com enfoque computacional, o desenvolvimento da AFC através dos softwares estatísticos R e Mplus. Assim, unindo o aspecto estatístico e computacional, é

possível fornecer uma visão adequada e enriquecedora de como utilizar esta técnica de análise estatística.



### Objetivos Específicos

- Apresentar o embasamento teórico da técnica de Análise Fatorial Confirmatória dando ênfase para a análise de variáveis categóricas (com 3 ou mais categorias).
- Explicar, passo a passo, a técnica de Análise Fatorial Confirmatória mediante o desenvolvimento de um tutorial para o pacote R e outro para o software Mplus.
- Avaliar as diferenças entre o pacote SEM do R com o do software Mplus, já que o primeiro não possui a opção de análise para variáveis categóricas. As comparações entre os dois programas computacionais serão feitas para variáveis categóricas e num segundo momento para variáveis contínuas.
- Exemplificar a técnica através da validação de construtos teóricos provenientes para uma escala de medidas, mediante aplicação a um banco de dados real.

### 1.3 ESTRUTURA DO TRABALHO

Este trabalho está dividido em 5 capítulos, com os conteúdos descritos a seguir:

No capítulo 1 são apresentadas a introdução, a motivação e as justificativas do trabalho, assim como os objetivos gerais e específicos.

O capítulo 2 traz alguns conceitos sobre Análise Fatorial Confirmatória geral e focada em variáveis categóricas. São apresentados os diversos conceitos e etapas da AFC, como por exemplo, a construção de diagramas de caminhos, conceito e

diferenciação de variáveis latentes e observáveis, identificação e processo de modelagem estatística, estimação dos parâmetros, entre outros.

O capítulo 3 traz a aplicação e resultados da AFC para a validação de um instrumento de medida nos dois softwares acima citados provenientes de dados de uma pesquisa real.

O capítulo 4 traz uma descrição detalhada sobre os passos da AFC, na forma de tutorial, nos software MPLUS 6.1 (versão corrente) e R pacote SEM (Structural Equation Models) versão 0.9-2.

O capítulo 5 realiza uma comparação entre os resultados do Mplus e o R afim de ressaltar similaridades, diferenças e limitações de cada um para realizar a técnica de AFC.

O capítulo 6 encerra esta monografia apresentando considerações finais, perspectivas e limitações da Análise Fatorial Confirmatória.

## 2 ANÁLISE FATORIAL CONFIRMATÓRIA

### 2.1. INTRODUÇÃO

A Análise Fatorial Confirmatória (AFC) é um método de análise de dados que pertence à família das técnicas de modelagem de equações estruturais (SEM). Esta técnica permite a verificação de ajustes entre os dados observados e um modelo hipotetizado a priori, o qual é baseado na teoria que especifica as relações causais hipotéticas entre fatores latentes (variáveis não observáveis) e suas variáveis indicadoras (observáveis).

Segundo Ullman (2006), os Modelos de Equações Estruturais (SEM) permitem que um conjunto de relações entre uma ou mais variáveis indicadoras e uma ou mais variáveis latentes possam ser descritas por variáveis contínuas e/ou discretas. Além disso, SEM também engloba como modelos causais, análise causal, modelagem de equações simultâneas, análise de estruturas de covariâncias, análises de caminhos ou análise fatorial confirmatória (AFC).

O termo “análise fatorial” descreve uma série de métodos, todos os quais têm o propósito de facilitar o entendimento dos fatores latentes que são subjacentes a um conjunto de variáveis observáveis. Segundo Schumacker (2004), a análise fatorial se propõe a determinar qual conjunto de variáveis observadas compartilha características da variância e co-variância que definem a construção dos fatores (variáveis latentes). Na prática, coleta-se dados de variáveis observadas e usa-se técnicas analíticas de análise fatorial para confirmar quais variáveis definem esses construtos ou fatores, ou explora-se quais variáveis estão relacionados aos fatores. Na abordagem exploratória procura-se definir os fatores, impor vínculos sobre estes, não existindo restrições sobre os padrões de relações entre variáveis observadas e latentes. O objetivo da análise exploratória é descobrir a natureza da estrutura subjacente entre as variáveis indicadoras.

Na AFE várias soluções são estimadas com diferentes números de elementos e diversos tipos de rotações. O pesquisador escolhe entre as soluções e seleciona a melhor, baseado na teoria. Segundo Brown (2006), o objetivo primordial da análise fatorial exploratória é avaliar a dimensionalidade de um conjunto de múltiplos indicadores (por exemplo, itens de um questionário) para descobrir o menor número de fatores interpretáveis necessários para explicar as correlações entre eles. Isto define a diferença entre EFA e AFC. Na EFA não são impostas restrições a priori nos padrões das relações entre as variáveis enquanto que na AFC o pesquisador deve especificar diversos aspectos do modelo fatorial, tais como, o número de fatores e o padrão das cargas fatoriais, determinando diferentes modelos alternativos para encontrar o que mais se ajusta aos dados, e que tenha suporte teórico.

Segundo Kline (2006), um pioneiro em psicometria, L.L. Thurstone (1887-1955), foi um dos primeiros a desenvolver e popularizar a análise fatorial, mas não somente para estudos exploratórios. Ele usualmente começava o estudo formulando uma hipótese de: como os fatores comuns eram prováveis de serem encontrados. Então ele executava quase uma análise fatorial confirmatória, pois a hipótese não era especificada explicitamente em termos dos parâmetros do modelo.

Segundo Raykov (2000), na AFC a teoria vem em primeiro lugar, o modelo é derivado da teoria e por último o modelo é testado para obter a consistência com os dados observados, usando uma abordagem de SEM. Assim, a questão é se o modelo produz uma matriz de covariância populacional consistente com a matriz de covariância amostral (observada). Se o modelo for bom, os parâmetros estimados produzirão uma matriz de covariância populacional estimada próxima à matriz de covariância amostral. Essa “proximidade” é avaliada primeiramente pelo teste qui-quadrado (desenvolvido por Joreskog, 1960) e, posteriormente, pelos índices de ajuste que serão apresentados no decorrer deste trabalho.

A Análise Fatorial Confirmatória tem se tornado uma das técnicas estatísticas mais comumente usada na pesquisa aplicada. Isto porque AFC é adequada a vários

tipos de questões as quais são comuns aos pesquisadores nesta área. Segundo Brown (2006) os três usos mais importantes da AFC são os seguintes:

- a) Avaliação psicométrica de instrumentos de medida. AFC é quase sempre usada durante o processo de desenvolvimento de uma escala para examinar a estrutura latente de um instrumento de medida (por exemplo, uma escala de medida). Neste contexto, AFC é usada para verificar o número de dimensões subjacentes (fatores) do instrumento e o padrão de relações entre os itens e os fatores (cargas fatoriais).
- b) Validação de Construtos: Semelhante ao fator em AFE, um construto é um conceito teórico. Na psicologia clínica e psiquiatria, por exemplo, doenças mentais, como depressão ou esquizofrenia, são construtos manifestados por vários grupos de sintomas que são reportados pelos pacientes ou observados por outras pessoas. Na sociologia, delinqüência juvenil poderia ser construída como um constructo multidimensional definido por várias formas de mau comportamento como, por exemplo, crimes contra a propriedade, violência interpessoal, uso de drogas, má conduta, etc. Assim, os resultados da AFC podem fornecer evidência da validade convergente ou discriminante dos construtos teóricos (validade convergente ou discriminante indica a evidência com que diferentes variáveis indicadoras são ou não fortemente relacionadas).
- c) “Methods Effects”. Frequentemente, uma parte da covariância das medidas observadas é devida a outras fontes além da existente pelos fatores latentes, ou seja, existe uma covariância que não é produto dos construtos subjacentes e sim pela introdução de covariância adicional entre as variáveis indicadoras. Por exemplo, “methods effects” estão presentes em instrumentos de medida que contém alguma combinação de resposta em sentido contrário para algum item.

Análise Fatorial Confirmatória, como exposto anteriormente, é uma técnica que pertence aos modelos de equações estruturais e, para permitir ao pesquisador hipotetizar o conjunto de relações do modelo é usado o que se conhece por

Diagramas de Caminho (Path Diagram). Estes diagramas são úteis para clarificar as idéias em relação às relações entre variáveis.

É comum mostrar um modelo fatorial confirmatório através de um diagrama de caminho (em inglês, path diagram) em que os quadrados representam variáveis observadas e os círculos representam as variáveis latentes.

Cabe salientar que, neste contexto complexo, as variáveis latentes podem ser exógenas ou endógenas. Segundo Brown (2006), uma variável exógena é uma variável que não é causada por outras variáveis do modelo. Contrariamente, uma variável endógena é causada por uma ou mais variáveis no modelo, ou seja, outras variáveis na solução exercem efeitos diretos sobre a variável. Assim, variáveis exógenas podem ser vistas como sinônimo de variáveis preditoras e variáveis endógenas podem ser vistas como equivalentes às variáveis dependentes. Os modelos de AFC são tipicamente considerados como tendo variáveis exógenas, mas em modelos mais complexos de ordem mais alta (onde fatores latentes explicam outros fatores latentes) muitas das variáveis latentes são consideradas endógenas.

A figura 2.1 possui duas variáveis latentes,  $\xi_1$  e  $\xi_2$ , representadas por círculos e que são manifestadas pelas variáveis observadas  $x_1$  a  $x_6$  representadas pelos quadrados. Setas unidirecionais são usadas para definir a relação de causa entre duas variáveis, setas bi-direcionais representam a covariância entre duas variáveis latentes. Variáveis latentes “causam” as variáveis observadas, como mostrado pelas setas unidirecionais apontadas desde os círculos até as variáveis observadas.

Os círculos chamados  $\xi$  representam as variáveis latentes ou fatores comuns. Um fator pode apontar para mais de uma variável observada; na figura 2.1,  $\xi_1$  explica três variáveis observadas  $x_1$  até  $x_3$  e  $\xi_2$  explica  $x_3$  a  $x_6$ . É esperado que os dois  $\xi_i$  estejam correlacionados representado pela covariância  $\Phi_{21}$ . As cargas fatoriais são representadas por  $\lambda_{ij}$  onde, por exemplo,  $\lambda_{31}$  é o efeito (coeficiente de regressão) de  $\xi_1$  sobre  $x_3$ . O quadrado da carga fatorial  $\lambda_{2ij}^2$  se refere às comunalidades representadas como a proporção de variância explicada pela  $j$ -ésima variável latente (Brown, 2006). Os círculos etiquetados por  $\delta_i$  representam fatores únicos, pois eles são afetados somente por uma variável observada e

incorporam toda a variância em cada  $\xi_i$ , tal como a medida de erro, que não é capturada pelos fatores comuns. Também, o termo de erro para cada variável indicadora, denotado por  $\delta_i$ , representa a quantidade de variação na variável indicadora que é devido a erros de medição ou que permanece inexplicado pela variação do fator latente em que as variáveis estão inseridas.

Finalmente, poder-se-ia representar a correlação entre o erro na medida de  $x_3$  com o erro na medida  $x_6$ , por  $\delta_{63}$ . Segundo Brown (2006), a AFC oferece ao pesquisador a habilidade de especificar a natureza das relações entre os erros de medida (variâncias únicas) das variáveis indicadoras. Cabe destacar, que embora AFE e AFC diferencem as variâncias comuns e as variâncias únicas, dentro da AFE a especificação das relações entre variâncias únicas não pode ser realizada. Quando no modelo não existem correlações entre os termos de erros é dito que todas as variâncias únicas são aleatórias.

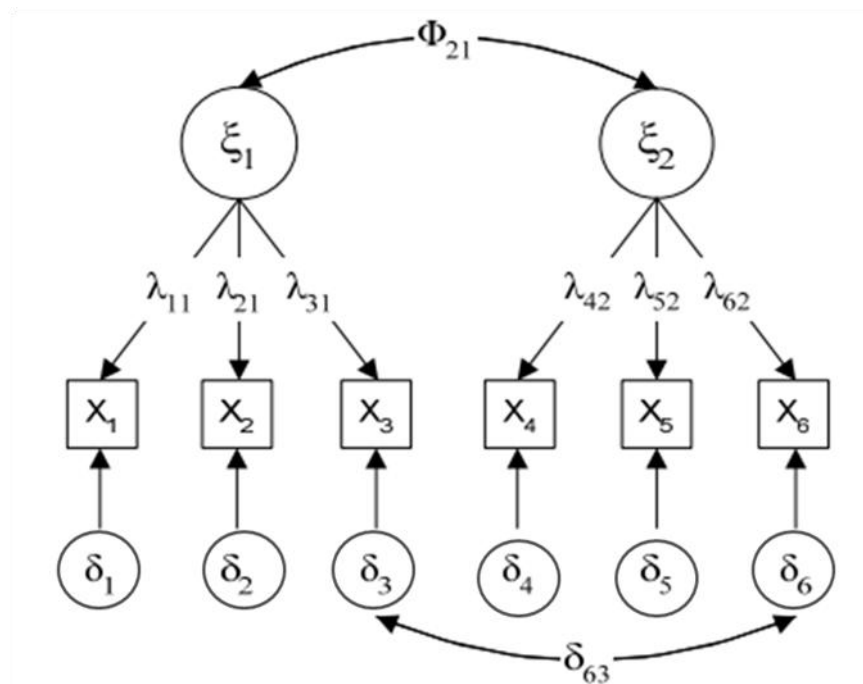


Figura 2.1.- Diagrama de Caminho, fonte Albright J. & Park H., (2009)

O modelo de Análise Fatorial Confirmatória pode ser resumido pela seguinte equação:

$$X = \Lambda \xi + \delta$$

onde  $X$  é o vetor de variáveis observadas,  $\Lambda$  (lambda) é a matriz de cargas fatoriais conectando  $\xi_i$  a  $x_i$ ,  $\xi$  é o vetor de fatores comuns, e  $\delta$  é o vetor de fatores únicos. É assumido que o termo do erro tem média zero,  $E(\delta) = 0$ , e que os fatores comuns e únicos são não correlacionados  $E(\xi\delta') = 0$ . A equação acima pode ser reescrita como:

$$\begin{array}{lll} x_1 = \lambda_{11}\xi_1 + \delta_1 & x_2 = \lambda_{21}\xi_1 + \delta_2 & x_3 = \lambda_{31}\xi_1 + \delta_3 \\ x_4 = \lambda_{42}\xi_2 + \delta_4 & x_5 = \lambda_{52}\xi_2 + \delta_5 & x_6 = \lambda_{62}\xi_2 + \delta_6 \end{array}$$

Até aqui, as similaridades com análise de regressão são evidentes. Cada  $x_i$  é uma função linear de um ou mais fatores comuns mais um termo de erro (não existindo intercepto uma vez que as variáveis são centralizadas na média). A diferença mais importante entre essas equações fatoriais e a análise de regressão é que, na AFC,  $\xi_i$  são não observáveis.

Uma das vantagens da AFC é a possibilidade de verificar a qualidade do ajuste do modelo aos dados. Os softwares fornecem um número considerável de medidas para auxiliar o pesquisador a decidir se rejeita ou mantém o modelo especificado a priori. Por exemplo, os índices absolutos de ajuste são aqueles que melhoram à medida que a discrepância entre  $S$  (matriz de covariância amostral) e  $\Sigma$  (matriz de covariância estimada) diminui. Exemplos de tais medidas inclui a estatística qui-quadrado, que testa a hipótese nula de  $H_0: \Sigma = \Sigma(\theta)$ . Assim, quanto maior a probabilidade associada com o qui-quadrado melhor é o ajuste entre o modelo hipotético e os dados. Entretanto, o tamanho de amostra afeta o modelo e a análise de covariâncias é baseada em teorias com grandes amostras, assim conseguir modelos hipotéticos bem ajustados é muito raro em SEM na maioria das pesquisas empíricas (Brown, 2006).



Para contornar as limitações do teste, os pesquisadores desenvolveram os índices de qualidade do ajuste (*goodness of fit*) para avaliar o ajuste do modelo aos dados e serão tratados no presente trabalho de maneira mais aprofundada.

Uma característica importante dos modelos de equações estruturais é a subdivisão que apresentam, ou seja, eles podem ser divididos em dois submodelos: o modelo de medida e o modelo estrutural (figura 2.2).

Segundo Brown (2006), a maior parte da pesquisa aplicada em SEM trata com modelos de medida. De fato, várias questões da pesquisa aplicada são abordados usando AFC como um primeiro procedimento analítico (por exemplo, testes de avaliação psicométrica ou validação de construtos).

Outros estudos em SEM estudam os modelos de regressão estrutural, quer dizer, a maneira em que os fatores latentes estão inter-relacionados. Não é o objetivo nos estudos de AFC este tipo de modelos, mas poderia ser considerado um modelo estrutural. Cabe mencionar que quando um ajuste ruim no modelo é encontrado, é mais provável que provenha de uma má especificação no modelo de medida (a maneira na qual as variáveis observadas estão relacionadas com os fatores latentes) que do modelo estrutural.

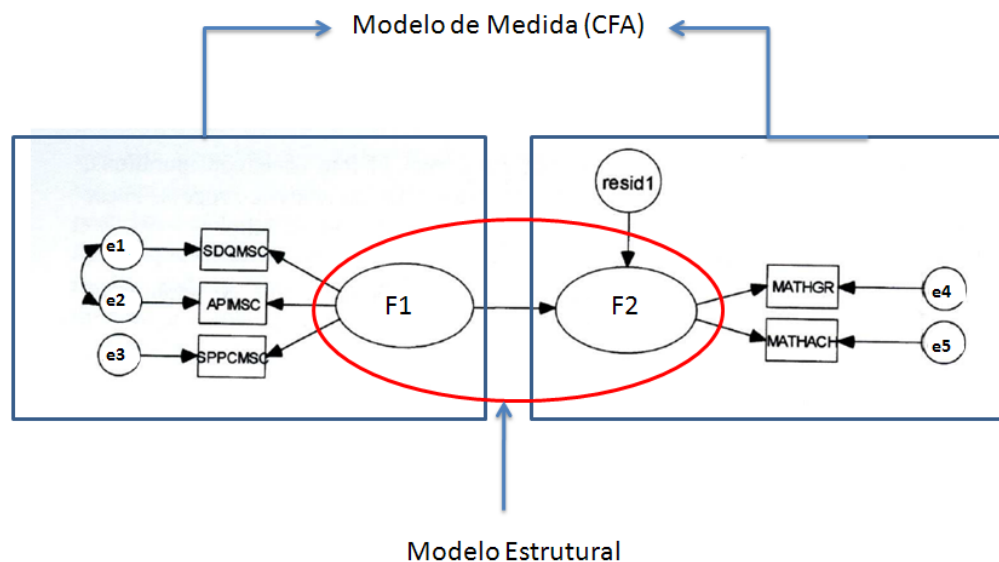


Figura 2.2. – Decomposição do modelo geral de SEM. Fonte: Michael Friendly.  
[HTTP://www.math.yorku.ca/SCS/Courses/Factor](http://www.math.yorku.ca/SCS/Courses/Factor)

Já especificamos, anteriormente, que o modelo de AFC pode ser resumido da seguinte forma  $X = \Lambda \xi + \delta$ . Na figura 2.1 temos que  $\lambda_{11}$  indica que X1 mede a carga no primeiro fator exógeno  $\xi_1$  e  $\lambda_{21}$  indica que X2 também possui uma carga sobre  $\xi_1$ . Esta notação numérica assume que as variáveis indicadoras foram ordenadas X1, X2, X3, X4, X5 e X6 na matriz de covariância. Sendo assim, a matriz  $\Lambda$  segue o modelo:

	$\xi_1$	$\xi_2$
X1	$\lambda_{x11}$	0
X2	$\lambda_{x21}$	0
X3	$\lambda_{x31}$	0
X4	0	$\lambda_{x42}$
X5	0	$\lambda_{x52}$
X6	0	$\lambda_{x62}$

Assim, a matriz  $\Lambda$  é definida por p linhas (número de variáveis indicadoras) e m colunas (número de fatores). O elemento igual a zero na matriz indica a falta de relação entre  $X_i$  e  $\xi_j$  (por exemplo, entre X1 e  $\xi_2$ ).

Um sistema similar é usado para definir as variâncias e covariâncias entre os fatores (representados por  $\Phi$ ) e os termos de erro (representados por  $\delta$ ). Por exemplo, a matriz de covariância entre os fatores seria:

	$\xi_1$	$\xi_2$
$\xi_1$	$\phi_{11}$	
$\xi_2$	$\phi_{21}$	$\phi_{22}$

Onde  $\phi_{11}$  e  $\phi_{22}$  são as variâncias fatoriais e  $\phi_{21}$  é uma covariância fatorial.

Similarmente, temos uma matriz de fatores únicos onde  $\delta_{11}$  e  $\delta_{66}$  são os termos de erro para cada variável indicadora e  $\delta_{65}$  é a covariância dos erros de medida entre X5 e X6.

	X1	X2	X3	X4	X5	X6
X1	$\delta_{11}$					
X2	0	$\delta_{22}$				
X3	0	0	$\delta_{33}$			
X4	0	0	0	$\delta_{44}$		
X5	0	0	0	0	$\delta_{55}$	
X6	0	0	0	0	$\delta_{65}$	$\delta_{66}$

Segundo Harrington (2009), as cargas fatoriais são coeficientes de regressão para prever os indicadores do fator latente. Em geral, as cargas fatoriais altas são melhores, e tipicamente cargas abaixo de 0.30 não são interpretadas, mas permanecem na estrutura do modelo.

Na literatura em geral, o processo de Análise Fatorial Confirmatória é apresentado segundo estágios de realização. Segundo Ullman (2006), o primeiro passo, para estimar um modelo de AFC é a especificação do modelo. Este estágio consiste em: declarar a hipótese a ser testada; identificar estatisticamente o modelo e, avaliar os pressupostos subjacentes ao modelo.

## 2.2 ESPECIFICAÇÃO E IDENTIFICAÇÃO DO MODELO

A especificação do modelo é realizada, como visto anteriormente, através do diagrama de caminho, hipotetizando quais variáveis indicadoras se relacionam com quais fatores.

Para estimar os parâmetros da AFC, o modelo de medida deve ser identificado. Um modelo é identificado se sobre uma base de informação conhecida (a matriz de covariância amostral) é possível obter um único conjunto de parâmetros estimados para cada parâmetro no modelo cujos valores são desconhecidos (cargas fatoriais, correlações entre os fatores, etc.).

Para poder conduzir a AFC, cada variável latente deve ter uma escala de medida identificada. Por definição, as variáveis latentes são não observáveis e assim, não possuem um sistema métrico. Assim, a unidade de medida deve ser determinada pelo pesquisador. Em análise fatorial confirmatório essa “determinação” é realizada por duas vias.

Segundo Harrington (2009), a primeira opção é dar a mesma unidade de medida de uma variável indicadora para que assim, a variância amostral seja passada à variável latente. A segunda opção é fixar a variância da variável latente no valor (usualmente) 1. Em geral, a primeira opção é mais popular embora essas duas opções geralmente resultem em ajustes similares.

Os parâmetros de um modelo AFC (cargas fatoriais, variâncias únicas e correlações entre os erros das variáveis) podem ser estimados somente se o número de parâmetros estimados não excede o número de parâmetros conhecidos (valores da matriz de covariância). Sendo assim, podem acontecer três tipos de modelos:

- a) Modelo *Underidentified*: Este modelo existe quando o número de parâmetros desconhecidos são maiores que o número de parâmetros conhecidos. Um excelente exemplo de Brown (2006) retrata esta situação:

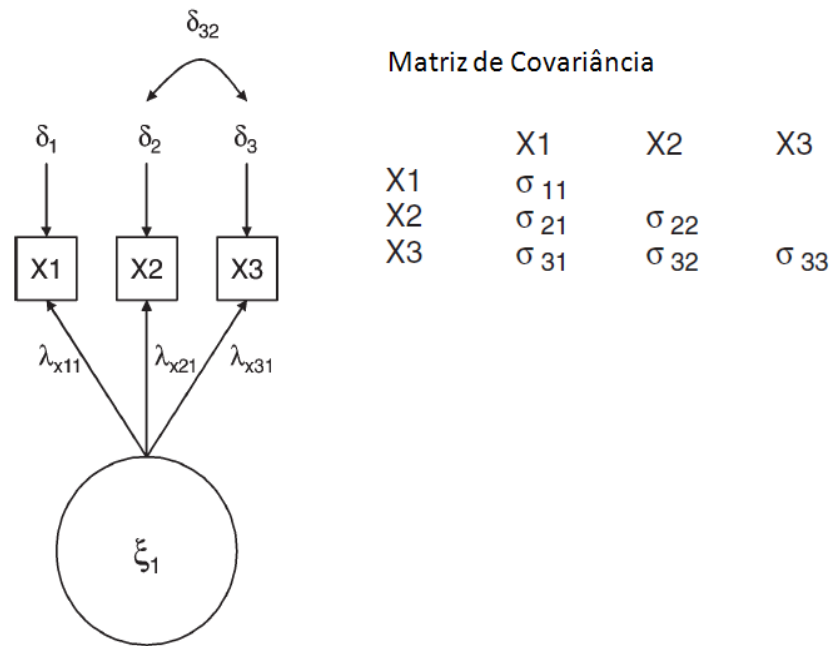


Figura 2.3. – Modelo Underidentified, fonte: Brown (2006).

Temos que a matriz de covariância possui 6 elementos e que os parâmetros desconhecidos a serem identificados são 7 (3 cargas fatoriais, 3 variâncias únicas e uma correlação entre os erros da variável X2 e X3). Assim, segundo Harrington (2009), o modelo não tem solução porque existe um infinito número de parâmetros que produz um ajuste perfeito. Neste caso, temos graus de liberdade (gl) negativos indicando que o modelo não pode alcançar uma solução única.

- b) Modelo *Just-Identified*: Representa aqueles modelos que possuem igual número de parâmetros desconhecidos e conhecidos. Neste caso o grau de liberdade é igual a zero. Nesta situação, existe um único conjunto de parâmetros que ajusta perfeitamente e reproduz os dados. Embora pareça ser uma boa idéia, na prática modelos de perfeito ajuste não são informativos, pois não permitem testar o modelo.
- c) Modelo *Overidentified*: Neste modelo o número de parâmetros conhecidos da matriz de covariâncias é maior que o número de parâmetros a serem

estimados. Esta diferença constitui os graus de liberdade positivos no modelo, ou seja,  $df > 0$ .

Resumindo, o número de graus de liberdade do modelo se dá pela diferença entre o número de parâmetros conhecidos (elementos da matriz de covariância) menos o número de parâmetros desconhecidos (cargas fatoriais, variâncias únicas e correlações entre os erros da variável). Ou seja, por

$$df = p(p + 1)/2 - k$$

Onde  $p$  é o número de variáveis indicadoras da matriz e  $k$  é o número de parâmetros livres. O termo  $p(p+1)/2$  indica o número de elementos da matriz de covariância.

### 2.3 MÉTODOS DE ESTIMAÇÃO

O objetivo da AFC é obter estimativas para cada parâmetro do modelo de medida (cargas fatoriais, variâncias e covariâncias fatoriais e variâncias e covariâncias dos erros de medida) para assim reproduzir a matriz de covariância predita ( $\Sigma$ ) que represente a matriz de covariância amostral ( $S$ ) tanto quanto possível (BROWN, 2006). Dito de outra forma, o que se deseja testar é se o modelo ajusta os dados ( $\Sigma = S$ ). Assim, existem múltiplos métodos de estimação disponíveis para testar o ajuste de um modelo overidentified.

Segundo Harrington (2009), ajustar um modelo é um processo iterativo que começa com um ajuste inicial, testa quão bem o modelo está se ajustando, ajusta o modelo, testa de novo e assim por diante, até que o modelo converge ou se ajusta bem. Esse ajuste é realizado por um software estatístico e geralmente não é visível. Neste trabalho usaremos, como mencionado no capítulo 1, os software R e Mplus para esses tipos de ajustes.

Para realizar esta tarefa de “ajuste”, é preciso uma função matemática que minimize a diferença entre  $\Sigma$  e  $S$ . Estas funções são chamadas de estimadores e a

mais usada em AFC e em geral na metodologia de SEM é o estimador de Máxima Verossimilhança. Porém, outros estimadores são usados, dependendo da natureza das variáveis (contínuas, categóricas, mistas), do tipo de distribuição associada e do tamanho amostral. No presente trabalho abordaremos 2 tipos de estimadores: o de Máxima Verossimilhança (ML) e o estimador de mínimos quadrados ponderados robustos ajustados pela média e variância (WLSMV).

Estimador de máxima verossimilhança (ML): Esta é a opção mais amplamente usada em pesquisa aplicada de AFC. A função que é minimizada em ML é:

$$F_{ML} = \ln|S| - \ln|\Sigma| + \text{trace}[(S)(\Sigma^{-1})] - p$$

Onde  $|S|$  é o determinante da matriz de covariância amostral,  $|\Sigma|$  é o determinante da matriz de covariância predita e  $p$  é o número de variáveis indicadoras.

Segundo Brown (2006), no passo inicial, o determinante de  $S$  será igual ao determinante de  $\Sigma$  e a diferença dos logaritmos desses determinantes será igual a zero. Similarmente,  $(S)(\Sigma^{-1})$  será igual a uma matriz identidade com a diagonal composta de 1. Quando os elementos da diagonal são somados (usando o traço da matriz) o resultado será o valor de  $p$ . Assim, se obtém um ajuste perfeito e a função de verossimilhança será zero.

Cada iteração que o programa realiza é um esforço para minimizar a função de máxima verossimilhança, ou seja, as iterações se desenvolvem até que seja alcançada a melhor estimativa de  $S$ .

Segundo Harrington (2009), o estimador ML possui diversas propriedades estatísticas: 1) Fornece os erros padrões para cada parâmetro estimado, os quais são usados para testar a significância estatística dos parâmetros e a precisão das estimativas através dos intervalos de confiança e 2) a função de ajuste é usada para calcular vários dos índices de qualidade de ajuste, como veremos mais adiante.

Cabe mencionar, que o estimador de máxima verossimilhança é um dos vários métodos que podem ser usados. De fato, segundo Brown (2006), este estimador tem diversos pressupostos:

- a) O procedimento de estimação requer grandes tamanhos amostrais (assintóticos).
- b) As variáveis indicadoras devem ser contínuas.
- c) As variáveis indicadoras devem ter distribuição normal multivariada. Kline (2006) ainda recomenda que, embora seja difícil estabelecer todos os aspectos de normalidade multivariada. Testar normalidade univariada e existência de *outliers* deve detectar a maior parte da não normalidade multivariada.

Quando as variáveis observadas são categóricas (ou seja, dicotômicas, politômicas), não se deve usar o método de estimação de máxima verossimilhança (ML), pois as conseqüências de tratar as variáveis categóricas como contínuas em AFC são numerosas. Por exemplo: 1) as estimativas obtidas das relações (correlações) entre as variáveis são atenuadas especialmente quando estas possuem menos do que cinco categorias e exibem um alto grau de assimetria, 2) produz erros nos testes estatísticos e nas estimativas dos erros das variâncias, como também estimações incorretas dos parâmetros. Assim, é importante utilizar outro estimador que não seja o ML na presença de variáveis categóricas ou na presença severa de não normalidade dos dados.

Segundo Harrington (2009), quando as variáveis não são contínuas, mas são tratadas como contínuas, como por exemplo, uma escala onde os respondentes são perguntados o quanto eles concordam ou não com alguma declaração e existem poucas alternativas de escolha (por exemplo, muito, mais o menos, não) problemas, como os citados acima, podem acontecer quando for usado o estimador ML. No entanto, é possível tratar variáveis como contínuas quando a escala possui um construto subjacente contínuo, como muitas das escalas de Likert, como por exemplo, 5 categorias de resposta, quando o tamanho amostral é grande e também



quando os dados não são severamente assimétricos (i.é, quando seguem uma distribuição aproximadamente normal).

Estimador WLSMV (*mean- and variance-adjusted weighted least squares*): Existem estimadores úteis que podem ser usados quando as suposições para a utilização do método de Máxima Verossimilhança não estiverem satisfeitas, como, por exemplo: Mínimos Quadrados Ponderados (WLS), Mínimos Quadrados Ponderados Robustos (WLSMV) e Mínimos quadrados não ponderados (ULS). No presente trabalho, será utilizado o estimador WLSMV fornecido unicamente pelo software Mplus como uma das melhores opções de modelagem com dados categóricos. Segundo Muthén & Muthén (2004), o estimador WLSMV fornece estimativas de mínimos quadrados ponderados usando uma matriz ponderada ( $W$ ), e média e desvios padrões robustos – e variância ajustada para o teste qui-quadrado.

A AFC usando variáveis categóricas precisa de uma grande amostra comparada a modelos que usam variáveis contínuas, mas o tamanho de amostra usando o estimador WLSMV é menos restritivo que o WLS. Isto foi comprovado por Flora & Curran (2004), mostrando que WLSMV tem bom desempenho com amostras tão pequenas quanto  $n=200$ . Além disso, o estimador WLS com variáveis categóricas não é recomendável (hipersensibilidade do qui-quadrado e vieses negativos consideráveis nos erros padrões à medida que a complexidade do modelo aumenta).

Segundo Brown (2006), Muthén tem estudos de simulação não publicados com resultados que mostram que tamanhos amostrais de 150 ou 200 casos podem ser suficientes para modelos que contemplam 10 ou 15 variáveis categóricas. Flora & Curran (2004) confirmou estes resultados mostrando que WLSMV produz testes estatísticos, parâmetros estimados e erros padrões para modelos de AFC acurados sob uma variedade de condições (por exemplo, tamanho amostral desde 100 a 1000 variando os graus de não normalidade e complexidade do modelo).

A função que é minimizada em WLSMV, através de um processo iterativo similar ao realizado no estimador de ML, é realizado através da função do estimador de WLS:

$$FWLS(\theta) = (S - \Sigma)' W D^{-1} (S - \Sigma)$$

Onde **S** é uma matriz de correlação policórica (usada para variáveis indicadoras politômicas). A correlação policórica mede a correlação entre duas variáveis politômicas, supondo uma distribuição subjacente contínua para os construtos destas variáveis, embora elas sejam observadas de forma discreta.

**$\Sigma$**  é a matriz de covariância estimada pelo modelo.

**W** é uma matriz de pesos positiva definida. W é baseada em estimativas de variâncias e covariâncias de cada elemento de S e momentos de quarta ordem baseados em curtose multivariada. Assim, a função ajustada WLS é ponderada pelas variâncias/covariâncias e curtoses para ajustar desvios de normalidade multivariada. Mas, estimar momentos de quarta ordem requer grandes amostras (ver Brown, 2006 página 388).

Para resolver os problemas encontrados usando WLS em amostras pequenas ou de tamanho moderado, Muthén, Du Toit e Spisic (1997) apresentaram um WLS robusto.

## 2.4 AVALIAÇÃO DO MODELO

Depois que o modelo de AFC é especificado, deve-se considerar três aspectos para a avaliação do modelo:

- 1) Medir os principais Índices de Ajuste do Modelo
- 2) Identificação de partes específicas de falta de ajuste no modelo através de Resíduos e índices de modificação.
- 3) Interpretabilidade dos parâmetros estimados.

Um erro comum em pesquisa aplicada de AFC é avaliar modelos exclusivamente na base de índices de ajuste, e é por isso que é importante avaliar os outros dois últimos pontos.

#### **2.4.1 Índices de ajuste do modelo**

Segundo Yu (2002), depois que o modelo de AFC é especificado e as estimativas são obtidas, o pesquisador deseja avaliar o ajuste do modelo e verificar se o modelo é consistente com os dados. Os índices de ajustes estabelecem se a hipótese  $S = \Sigma$  é válida ou não e, se não, esses índices medem a discrepância entre  $S$  e  $\Sigma$ . Segundo Hu e Bentler (1999), existem dois tipos de medidas de ajuste. Um tipo são as medidas baseadas na estatística qui-quadrado ( $\chi^2$ ) e os outros tipos são medidas compostas.

É importante notar cada tipo de índice fornece uma informação diferente. Existem várias recomendações e são estipulados pontos de corte para esses índices para avaliar de forma adequada o modelo. Neste trabalho usaremos os propostos por Brown (2006), pois tratam-se de índices selecionados baseados na sua popularidade em estudos aplicados e, o mais importante, o seu favorável desempenho em simulações de Monte Carlo. A literatura em geral, propõe que existem três categorias de índices: a) índices de ajuste absoluto, b) índices de ajuste parcimoniosos e c) índices de ajuste comparativos ou incrementais.

##### **a) Índices de ajuste absoluto “Overall Fit”**

Como mencionado anteriormente, o que se deseja testar é se a matriz de covariância predita  $\Sigma$  se ajusta à matriz de covariância amostral  $S$ , ou seja,  $H_0: \Sigma = S$ . A estatística qui-quadrado de bondade de ajuste determina esta resposta. Um valor grande para esta estatística, conduz à rejeição de  $H_0$ , significando que o modelo estimado não reproduz bem a matriz de covariância amostral, ou seja, que os dados não se ajustam bem ao modelo. Em contraste, um valor baixo desta estatística mostra que não é possível rejeitar  $H_0$  e significa que existe um bom ajuste do modelo (Albright J.J. e Park H.M., 2009).

Considerando um modelo usando o estimador de máxima verossimilhança pode-se observar que a estatística  $\chi^2$  é calculada como:

$$\chi^2 = F_{ML}(N - 1)$$

Cabe observar que a fórmula  $\chi^2$  testa se a variância amostral  $\sigma_2^2$  difere da variância populacional  $\sigma_1^2$ . Assim,

$$\chi^2 = \frac{(N - 1)\sigma_2^2}{\sigma_1^2}$$

Esta equação pode ser reescrita como  $(\sigma_2^2/\sigma_1^2)(N - 1)$  na qual a primeira parte é equivalente a  $\ln(\sigma_2^2) - \ln(\sigma_1^2)$  e que na sua totalidade é equivalente a  $\chi^2 = (\ln|S| - \ln|\Sigma|)(N - 1)$  ou  $F_{ML}(N - 1)$ .

Embora o  $\chi^2$  é uma estatística comum na análise de modelos de análise fatorial confirmatória, esta estatística é raramente usada como um índice de ajuste isolado. De fato, existem críticas importantes a esta estatística. Em primeiro lugar, para N pequeno ou dados com distribuição não normal, a distribuição subjacente não segue  $\chi^2$  comprometendo o teste de H0. Em segundo lugar, esta estatística sempre rejeitará H0, se o tamanho amostral for grande.

Além disso, Yu (2002) destaca que, como o teste qui-quadrado é em parte uma função do tamanho amostral (N), então o estimador desta estatística aumenta em direta proporção de N-1 e, conseqüentemente, o poder diminui se N diminui. Segundo Tanaka (1993), em pequenas amostras este poder não é suficiente e a chance de cometer um erro do tipo II (não rejeitar H0, quando em realidade é falsa) aumenta.

Existe também outro tipo de índice que se encaixa na categoria de índices absolutos, chamado SRMR (do inglês, Standardized Root Mean Square Residual)

que é baseado na discrepância entre as correlações na matriz amostral e as correlações previstas pelo modelo, ou seja, é baseado nas diferenças entre as covariâncias previstas e observadas. Idealmente, esses resíduos devem ser todos iguais a zero para um modelo de ajuste aceitável.

A estatística chamada de RMR (do inglês Root Mean Residual Square) foi originalmente introduzida no software LISREL, mas agora é calculada por outros programas. Um ajuste perfeito é indicado por um  $RMR=0$ , e quanto mais alto o valor, pior o ajuste. Segundo Brown (2006), um problema com o RMR é que o índice é calculado com variáveis não padronizadas e a amplitude de variação do índice depende da escala de medida das variáveis observadas. Se essas escalas são todas diferentes, pode ser difícil interpretar um valor de RMR.

O índice SRMR é baseado na versão padronizada do índice RMR introduzido por Bentler (1995). O SRMR pode ser visto como uma média da discrepância entre a matriz de correlação amostral e a matriz de correlação hipotetizada (estimada), ou seja, é uma medida da média das correlações não explicadas no modelo. Assim, derivado da matriz de correlação residual, o SRMR pode ser calculado somando o quadrado dos elementos da matriz e dividindo essa soma pelo número de elementos da matriz (abaixo da diagonal), ou seja,  $b=p(p+1)/2$ . Logo, toma-se a raiz quadrada deste resultado: Hu e Bentler (1999) recomendam um valor de corte perto de 0,08 ou menor. Brown (2006) afirma que quanto mais próximo de zero, melhor será o ajuste do modelo.

#### b) Índice de ajuste parcimonioso

O RMSEA é um índice criado por Stieger e Lind no ano de 1980 e estima quão bem os parâmetros do modelo reproduzem a covariância populacional. Se um modelo estimado reproduz exatamente as covariâncias populacionais então o RMSEA será igual a zero. Segundo Brown (2006), valores próximos de 0,06 ou menores indicam um ajuste razoável do modelo. Assim, também o RMSEA é um índice de correção parcimoniosa, já que incorpora uma penalização pelo número de parâmetros estimados (expressos em graus de liberdade), desta forma modelos complexos são penalizados por ter um ajuste pobre.

Suponhamos que o modelo A e o modelo B ajustam igualmente bem a matriz de covariância amostral S, e que a especificação do modelo B implica em estimar mais parâmetros que o modelo A (ou seja, A possui mais graus de liberdade que B). Índices parcimoniosos estão a favor do modelo A em relação ao modelo B, já que a solução do modelo A ajusta os dados amostrais com menor número de parâmetros que o modelo B. Assim, o RMSEA serve para comparar modelos e selecionar qual é melhor que o outro.

Segundo Yu (2002), os autores Cudeck e Henly no ano 1991 mencionaram que existem 3 tipos de funções de discrepâncias que podem ser usadas para a seleção de modelos. Elas são: discrepância amostral, discrepância global e discrepância devido ao erro de aproximação. Assim, o RMSEA está nesta última categoria e é calculado como:

$$\text{RMSEA} = \text{SQRT} [d/df]$$

Este índice baseia-se na distribuição qui-quadrado não centralizada, que é uma distribuição de uma função de ajuste (por exemplo, função de máxima verossimilhança) quando o ajuste do modelo não é perfeito. Esta distribuição inclui um parâmetro não centralizado, o qual expressa o grau de má especificação do modelo. Este parâmetro é estimado como:  $\text{NCP} = \chi^2 - df$ . Quando o ajuste do modelo é perfeito, o parâmetro será igual a zero e se não for, NCP será maior que zero. Assim,  $d = \text{NCP}/(N-1)$  e DF é os graus de liberdade do modelo. Portanto, RMSEA compensa os efeitos da complexidade do modelo, transmitindo discrepância no ajuste de d para cada grau de liberdade no modelo. Assim, este índice é sensível ao número de parâmetros no modelo.

A distribuição qui-quadrado não centralizada pode ser usada para obter os intervalos de confiança para o RMSEA, porém, segundo Brown (2006), os pesquisadores devem ter cuidado, pois a amplitude do intervalo é afetada pelo tamanho amostral e pelo número de parâmetros estimados no modelo.

c) Índices de ajuste comparativo ou incremental

O CFI (*Comparative Fit Index*) mede uma melhora relativa no ajuste do modelo do pesquisador em relação a um modelo padrão. Tipicamente, o modelo padrão é um modelo independente em que as covariâncias entre todas as variáveis indicadoras são zero. O índice é calculado como:

$$CFI = 1 - \max[(\chi^2_T - df_T), 0] / \max[(\chi^2_T - df_T), (\chi^2_B - df_B), 0]$$

Onde  $\chi^2_T$  é o valor do qui-quadrado do modelo sob avaliação e  $df_T$  são os graus de liberdade do modelo padrão. Assim também,  $\chi^2_B$  é o valor do qui-quadrado do modelo independente (ou modelo base) e  $df_B$  representam os graus de liberdade do mesmo modelo. O CFI pode variar entre 0 e 1 sendo que valores próximos de 1 implicam em um modelo bem ajustado.

Outro índice bastante usado é o TLI (*Tucker-Lewis Index*) ou NNFI (Índice de Tucker-Lewis não padronizado). Este índice tem aspectos que compensam os efeitos da complexidade do modelo. Assim como o RMSEA, o TLI inclui uma função de penalização pela adição de mais parâmetros estimados e que podem não melhorar o ajuste do modelo. O TLI é calculado pela seguinte fórmula:

$$TLI = [(\chi^2_B / df_B) - (\chi^2_T / df_T)] / [(\chi^2_B / df_B) - 1]$$

Ao contrário do CFI, o TLI é não normalizado o que quer dizer que o valor pode cair fora da amplitude de 0 a 1. De qualquer forma, é interpretado de maneira similar ao CFI em que valores próximos de 1 estão de acordo com um bom ajuste. Segundo Brown (2006), alguns pesquisadores (como Bentler, 1990) notaram que valores menores de 0,9 indicariam suspeitas de rejeição do modelo, e valores de 0,90 a 0,95 poderiam ser indicativo de um ajuste aceitável.

#### **2.4.2 Verificação do ajuste através dos Resíduos e Índices de Modificação.**

Em alguns casos, pode acontecer que, apesar dos índices de ajuste global sugerirem um ajuste aceitável, as relações entre variáveis indicadoras nos dados amostrais podem não serem reproduzidas adequadamente. Estes índices podem indicar se a matriz amostral está ou não bem reproduzida. No entanto, estes índices não fornecem informação sobre as razões de por quê o modelo ajusta os dados de forma tão deficiente.

Para isso, duas estatísticas são freqüentemente usadas para identificar a perda de ajuste numa solução de AFC: resíduos e índices de modificação.

- a) Resíduos: Existem três matrizes associadas a um modelo de AFC. A matriz de covariância amostral ( $S$ ), matriz de covariância predita ( $\Sigma$ ) e a matriz de covariância residual ( $S-\Sigma$ ). Esta última fornece a informação específica acerca de quão bem cada variância e covariância foi reproduzida pelos parâmetros estimados do modelo.

Os resíduos podem ser difíceis de interpretar, pois são afetados pela métrica e dispersão das variáveis observadas. Assim, são usados os resíduos padronizados, que são os resíduos divididos pelos seus erros padrões assintóticos. Eles representam uma estimativa do número de desvios padrões que os resíduos observados estão do resíduo zero, que existiria caso o modelo fosse perfeitamente ajustado, ou seja,  $\Sigma - S = 0$ . Segundo Ullman (2006), estes índices podem ser interpretados como as correlações residuais não explicadas pelo modelo.

Os resíduos podem ser positivos, negativos ou zero. Um resíduo padronizado positivo sugere que os parâmetros do modelo subestimam a relação entre duas variáveis. Um resíduo positivo alto pode ser sinal de que parâmetros adicionais são necessários no modelo para melhorar a covariância entre as variáveis indicadoras. Analogamente, um resíduo padronizado negativo sugere que os parâmetros do modelo superestimam a relação entre duas variáveis indicadoras. Valores residuais entre -2 e 2 são considerados normais, ou seja, não indicariam uma relação de subestimação ou superestimação entre as variáveis indicadoras.



b) Índices de modificação: O índice de modificação reflete uma aproximação de quanto o qui-quadrado pode diminuir quando é incorporado alguma relação, ou caminho, não considerado no modelo inicial. Dito de outra forma, estes índices de modificação podem ser conceituados como a estatística qui-quadrado com um grau de liberdade. Assim, índices maiores ou iguais a 3,84 (reflete o valor crítico do qui-quadrado para  $p < 0,05$ , 1 gl) sugerem que o ajuste do modelo pode ser melhorado. Para cada parâmetro especificado existe um índice de modificação, valor que representa a queda esperada no valor do qui-quadrado se o parâmetro não fosse mais fixo e sim livremente estimável. Em geral, um modelo bem ajustado deveria produzir índices de modificação pequenos em magnitude, mas deve-se ter cuidado para não adicionar parâmetros em excesso e produzir modelos mais complexos do necessário.

#### **2.4.3 Interpretabilidade dos parâmetros estimados.**

Usualmente se o modelo está bem ajustado, o pesquisador deve ainda examinar a significância estatística das relações dentro do modelo. Assim, o passo inicial deste processo é determinar se o parâmetro estimado faz ou não sentido dentro do modelo. Do ponto de vista da perspectiva estatística, os parâmetros estimados não devem estar fora de uma amplitude admissível como, por exemplo, correlações maiores a 1, variâncias negativas e matrizes de covariâncias e/ou correlações que não são positivas definidas. Se isto acontecer, pode ser indicativo de erro na especificação do modelo e/ou problemas com a amostra por não trazer informação suficiente nos seus dados.

Cada parâmetro, livremente estimado, possui uma significância estatística associada a uma razão e interpretada como a estatística z, testando se o parâmetro é estatisticamente diferente de zero:

$$z = \text{parâmetro estimado} / \text{erro padrão da estimativa (SE)}$$

Baseado no nível de significância 0,05, o teste estatístico precisa ser  $|z| > 1,96$  para que a hipótese nula possa ser rejeitada.

Também, é importante avaliar se a magnitude dos erros padrões é apropriada (não excessivamente grandes ou pequenos). Embora erros padrões pequenos podem indicar precisão da estimativa do parâmetro, a significância do teste z poderia não ser calculada se o erro padrão é próximo de zero. Assim, também erros padrões muito grandes indicam imprecisão das estimativas dos parâmetros devido à grande amplitude dos intervalos de confiança.

Erros padrões problemáticos poderiam ter uma variedade de origens tais como: modelo mal especificado, tamanho de amostra pequeno, ou uso de um estimador impróprio. Lamentavelmente, não existe um guia para orientar o pesquisador a determinar se a magnitude dos erros padrões é problemática ou não, dado um conjunto de dados. Isto porque o tamanho dos erros padrões é determinado em parte pela métrica das variáveis indicadoras e o tamanho do parâmetro estimado (para maior discussão, ver Brown, 2006 p. 129).

### **3 APLICAÇÃO DA ANÁLISE FATORIAL CONFIRMATÓRIA PARA UM INSTRUMENTO DE MEDIDA NOS SOFTWARES R E MPLUS.**

Neste capítulo será aplicada, passo a passo, a metodologia da AFC tendo em conta, de forma geral, os três grandes estágios apresentados por Brown (2006). Esses estágios englobam três grandes tópicos: especificação, estimação e avaliação do modelo.

Para exemplificar a aplicação da AFC para validação de um instrumento de medida serão utilizados os dados de uma pesquisa real. Os dados são de uma amostra de 217 indivíduos, com idades que variam entre 15 e 20 anos. O objetivo da pesquisa é validar os construtos existentes numa escala para medir traços de personalidade. Na escala denominada escala 1 (ESC1), os valores ordinais estão definidos de 0 a 2, sendo que o valor 0 é a ausência da característica observada e o valor 2 é a forte presença da característica.

Para realizar a Análise Fatorial Confirmatória serão utilizados dois tipos de softwares: R e Mplus. Serão comparados os resultados, e além disso, verificados o desempenho dos softwares no que diz respeito às facilidades ofertadas. No software R será utilizado o pacote SEM (Structural Equation Models) versão 0.9-21 criado pelo professor John Fox da McMaster University (Canadá). A versão do software Mplus utilizada será a versão 6.1 (versão corrente). Os diagramas de caminhos foram desenhados através do software Grapviz – Graph Visualization versão 2.28.

Para a especificação dos modelos serão utilizados modelos definidos conforme os paradigmas teóricos relacionados com o instrumento de medida a ser validado. Também serão apresentados estes modelos com seus respectivos diagramas de caminhos, detalhando cada um deles com a especificação dos parâmetros a serem estimados e a composição dos fatores. Para o mesmo modelo, serão obtidas duas análises, primeiramente pelo software Mplus e após pelo R. Teoricamente, conforme especificado no capítulo relativo à estimação de parâmetros, o software R utiliza o estimador de máxima verossimilhança (EMV) e no

software Mplus será utilizado o estimador WLSMV. Dada a característica discreta das variáveis indicadoras (tipo escala de Likert de 3 pontos), o estimador EMV será utilizado baseando-se no fato de que é possível tratar variáveis categóricas como contínuas quando a escala possui um constructo subjacente contínuo. Um dos objetivos deste trabalho é comparar os resultados usando estes dois estimadores mesmo que, pelo método de estimação de máxima verossimilhança, seja requerida uma série de pressupostos mencionados no capítulo 2. Neste capítulo apresentaremos a especificação e identificação dos modelos relativos ao marco teórico da escala a ser validada (Secção 3.1), e na seqüência os resultados das estimativas dos modelos pelo software R (secção 3.2) e Mplus (Secção 3.3). A análise comparativa dos resultados obtidos pelos dois softwares será abordada no capítulo 5.

### 3.1. ESPECIFICAÇÃO E IDENTIFICAÇÃO DOS MODELOS

Neste tópico apresentaremos a descrição, identificação e os diagramas de caminhos dos modelos para a validação fatorial do instrumento de medida citado anteriormente. A idéia da validação de construtos é identificar se os fatores ou construtos obtidos pela AFC são os mesmos hipotetizados pelo marco teórico.

Ao todo, são 6 modelos utilizados: 3 baseados em modelos teóricos já conhecidos na literatura e testados a partir de uma amostra norte americana e 3 baseados numa amostra brasileira utilizando análise fatorial exploratória pelo método de Fator Principal (Principal Axis Factoring - PAF) com rotação oblíqua Promax. A rotação escolhida para a análise fatorial deve-se ao fato de se supor correlação entre os fatores ou construtos extraídos.

Em AFC, a forma pela qual se representa um modelo hipotetizado pelo pesquisador é através do diagrama de caminho (Path Diagram). Assim, a apresentação do diagrama é uma forma efetiva de visualizar as relações entre as variáveis indicadoras e as variáveis latentes, bem como todos os parâmetros a

serem estimados. Um modelo a ser testado, precisa ser entendido com todos os símbolos contidos neste tipo de diagrama

A seguir apresenta-se em detalhe, cada um dos 6 modelos a serem testados:

**Modelo 1:** O primeiro modelo (figura 3.1) origina-se numa análise fatorial exploratória pelo método PAF com rotação Promax para a amostra brasileira, utilizando-se todos os 20 itens da escala original e com a especificação de ser 4 o número de fatores, de acordo com os construtos teóricos especificados.

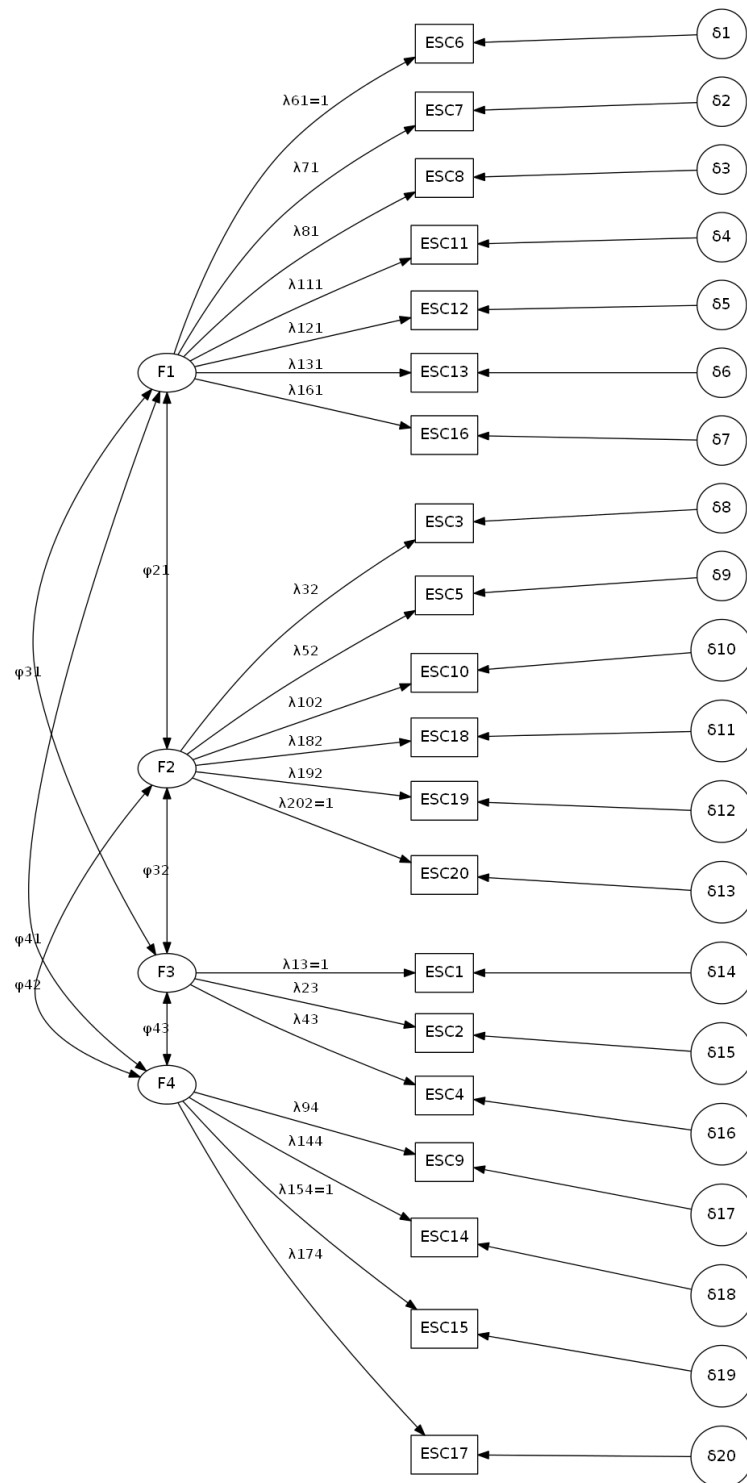


Fig. 3.1.- Modelo 1 de 4 fatores obtidos por AFE, método de PAF com rotação Promax, todos os 20 itens da escala ESC.

Ao examinar a figura 3.1, podemos listar as seguintes características estabelecidas a priori para o modelo hipotético 1:

- Existem 4 fatores latentes, indicados pelas elipses. São: F1, F2, F3 e F4.
- Os 4 fatores são intercorrelacionados (consistentes com a teoria), indicados pelas setas bi-direcionais. Cada correlação ( $\Phi$ ) entre fatores latentes é livremente estimada.
- Existem 20 variáveis observadas indicadas pelos retângulos (ESC1 – ESC20).
- As variáveis observadas formam os fatores de acordo com o seguinte padrão:
  - ESC6, ESC7, ESC8, ESC11, ESC12, ESC13, ESC16 ao fator 1 (F1).
  - ESC3, ESC5, ESC10, ESC18, ESC19, ESC20 ao fator 2 (F2).
  - ESC1, ESC2, ESC4 ao fator 3 (F3).
  - ESC9, ESC14, ESC15, ESC17 ao fator 4 (F4).
- Cada variável observada está relacionada a um e apenas a um fator (denotada a carga fatorial por  $\lambda$  e livremente estimada).

Os erros de medida, associados a cada variável observada ( $\delta_1$ - $\delta_{20}$ ), são não correlacionados. Os erros representam a proporção de variância nas variáveis indicadoras, que não são explicados pelo fator latente. De outra forma, o modelo de medida presume que todos os erros de medida são aleatórios já que a relação observada entre quaisquer duas cargas fatoriais no mesmo fator é devido totalmente à influência compartilhada da dimensão latente.

É importante mencionar que, para produzir uma análise fatorial confirmatória, cada fator latente deve ter uma escala de medida identificada, como mencionado anteriormente. Assim essas unidades de medida devem ser estabelecidas pelo pesquisador com um critério adequado. Existem duas formas de alcançar este objetivo. O primeiro é escolhendo uma variável indicadora pertencente a cada fator

como sendo a variável “marker indicator” e terá carga fatorial igual ao valor 1. As variáveis escolhidas foram selecionadas pela opção padrão do Mplus já que ele seleciona automaticamente a primeira variável indicadora listada em cada fator latente. Cabe destacar que, como todas as variáveis indicadoras possuem a mesma métrica (0 a 2) os resultados das análises independem da escolha de uma ou outra.

No caso do software R, é usada a segunda forma de traspassar a métrica ao fator latente que é definindo cada variância do fator com o valor 1 (veja tutorial do software R na etiqueta `## Factor Variances fixed at 1`). Assim, as soluções pelo R serão padronizadas. Esse procedimento no R é comum a todos os modelos propostos. Apesar dos dois softwares utilizarem métodos diferentes, o ajuste do modelo usando este último é idêntico ao modelo usando variáveis “marker indicator” (veja Brown, 2006, página 63). Cabe mencionar que a solução padronizada do Mplus contempla essas variâncias fatoriais fixadas em 1.

Na figura 3.1 são mostradas as variáveis que tem carga fatorial igual a 1 (para a análise no Mplus), estas são: ESC6 para F1 ( $\lambda_{61}$ ), ESC20 para F2 ( $\lambda_{202}$ ), ESC15 para F3 ( $\lambda_{153}$ ) e ESC1 para F4 ( $\lambda_{14}$ ) (veja no tutorial do Mplus, para cada fator latente definido F1, F2, F3 e F4 depois da expressão BY; figura 4.3 do capítulo 4).

Os parâmetros do modelo de AFC podem ser estimados somente se o número de parâmetros livremente estimados não excede o número de elementos da matriz de covariância baseada na amostra estudada (modelo overidentified). Ao todo, são 46 parâmetros a serem estimados dos quais:

- 20 correspondem às cargas fatoriais (representados pelos  $\lambda$  do digrama de caminho).
- 20 correspondem aos erros de medida (representados por  $\delta$ )
- 6 correspondem às correlações fatoriais (representados por  $\Phi$ )

A matriz de covariância amostral é dada por:



	ESC1	ESC2	ESC3	ESC4	ESC5	ESC6	ESC7	ESC8	ESC9	ESC10	ESC11	ESC12	ESC13	ESC14	ESC15	ESC16	ESC17	ESC18	ESC19	ESC20
ESC1	σ11																			
ESC2	σ21	σ22																		
ESC3	σ31	σ32	σ33																	
ESC4	σ41	σ42	σ43	σ44																
ESC5	σ51	σ52	σ53	σ54	σ55															
ESC6	σ61	σ62	σ63	σ64	σ65	σ66														
ESC7	σ71	σ72	σ73	σ74	σ75	σ76	σ77													
ESC8	σ81	σ82	σ83	σ84	σ85	σ86	σ87	σ88												
ESC9	σ91	σ92	σ93	σ94	σ95	σ96	σ97	σ98	σ99											
ESC10	σ101	σ102	σ103	σ104	σ105	σ106	σ107	σ108	σ109	σ1010										
ESC11	σ111	σ112	σ113	σ114	σ115	σ116	σ117	σ118	σ119	σ1110	σ1111									
ESC12	σ121	σ122	σ123	σ124	σ125	σ126	σ127	σ128	σ129	σ1210	σ1211	σ1212								
ESC13	σ131	σ132	σ133	σ134	σ135	σ136	σ137	σ138	σ139	σ1310	σ1311	σ1312	σ1313							
ESC14	σ141	σ142	σ143	σ144	σ145	σ146	σ147	σ148	σ149	σ1410	σ1411	σ1412	σ1413	σ1414						
ESC15	σ151	σ152	σ153	σ154	σ155	σ156	σ157	σ158	σ159	σ1510	σ1511	σ1512	σ1513	σ1514	σ1515					
ESC16	σ161	σ162	σ163	σ164	σ165	σ166	σ167	σ168	σ169	σ1610	σ1611	σ1612	σ1613	σ1614	σ1615	σ1616				
ESC17	σ171	σ172	σ173	σ174	σ175	σ176	σ177	σ178	σ179	σ1710	σ1711	σ1712	σ1713	σ1714	σ1715	σ1716	σ1717			
ESC18	σ181	σ182	σ183	σ184	σ185	σ186	σ187	σ188	σ189	σ1810	σ1811	σ1812	σ1813	σ1814	σ1815	σ1816	σ1817	σ1818		
ESC19	σ191	σ192	σ193	σ194	σ195	σ196	σ197	σ198	σ199	σ1910	σ1911	σ1912	σ1913	σ1914	σ1915	σ1916	σ1917	σ1818	σ1919	
ESC20	σ201	σ202	σ203	σ204	σ205	σ206	σ207	σ208	σ209	σ2010	σ2011	σ2012	σ2013	σ2014	σ2015	σ2016	σ2017	σ1818	σ2019	σ2020

Assim, o número de graus de liberdade do modelo é dado pela diferença entre o número de parâmetros conhecidos (elementos da matriz de covariância/correlação) menos o número de parâmetros desconhecidos (cargas fatoriais, variâncias únicas e correlações entre os erros da variável). Ou seja, por

$$df = p(p + 1)/2 - k$$

Onde  $p=20$  é o número de variáveis indicadoras da matriz de covariância e  $k=46$  é o número de parâmetros livres. O termo  $p(p+1)/2=210$  indica o número de elementos da matriz de covariância. Assim, o número de graus de liberdade do modelo é 164 sendo que como  $df>0$  o modelo pode ser estimado.

A seguir, serão apresentados, de forma sucinta, os 5 modelos restantes. Cada um destes modelos hipotetizados está definido de forma análoga ao modelo 1, embora sejam descritas as características próprias de cada um.

**Modelo 2:** No segundo modelo (figura 3.2) os itens 11 e 17 da escala foram excluídos e origina-se de uma análise fatorial exploratória pelo método PAF com rotação promax e com a restrição de 4 o número de fatores para a amostra brasileira.

Neste modelo temos que o número de variáveis indicadoras é 18 e o número de parâmetros a serem estimados é 42 (18 cargas fatoriais, 18 erros de medida e 6

correlações fatoriais). Assim, sabendo que o número de elementos da matriz de covariância amostral é  $p(p+1)/2 = 171$ , o número de graus de liberdade é  $171 - 42 = 129$  sendo que como  $df > 0$  o modelo então pode ser estimado.

As mesmas variáveis indicadoras (ESC6, ESC20, ESC15 e ESC1), pertencentes a cada fator, terão carga fatorial igual ao valor 1 para o software Mplus.

**Modelo 3:** No terceiro modelo (figura 3.3) excluem-se os itens 10, 11, 12, 17, 18, 19 e 20 e surgiu de uma análise fatorial exploratória pelo método PAF com rotação Promax. Não foram considerados estes itens para comparar o resultado com o modelo teórico proposto pela literatura. Cabe mencionar que neste modelo as disposições dos itens nos três fatores resultantes na AFE na amostra brasileira ficaram levemente diferentes do modelo teórico proposto que será analisado no modelo 5.

O modelo considerado possui 3 fatores sendo que o número de variáveis indicadoras é 13 e o número de parâmetros a serem estimados são 29 (13 cargas fatoriais, 13 erros de medida e 3 correlações fatoriais). Assim, sabendo que o número de elementos da matriz de covariância amostral é  $p(p+1)/2 = 91$ , o número de graus de liberdade é  $91 - 29 = 62$  sendo que como  $df > 0$  o modelo então pode ser estimado.

As variáveis indicadoras: ESC6, ESC15 e ESC1 pertencentes a cada fator terá carga fatorial igual ao valor 1 para o software Mplus.

**Modelo 4:** O quarto modelo (figura 3.4.) é proposto na literatura que define a Escala que estamos validando. Ele não considera os itens 11 e 17 e foi originado numa amostra americana, sendo um modelo com 4 fatores.

O número de variáveis indicadoras é 18 e o número de parâmetros a serem estimados são 42 (18 cargas fatoriais, 18 erros de medida e 6 correlações fatoriais). O número de graus de liberdade é 129.

As variáveis indicadoras: ESC6, ESC10, ESC1 e ESC15 pertencentes a cada fator terão carga fatorial igual ao valor 1 para o software Mplus.

**Modelo 5:** Este quinto modelo (figura 3.5) é considerado nas análises, pois é um modelo teórico que também é aceito na literatura, tem 3 fatores e não considera os itens 10, 11, 12, 17, 18, 19 e 20.

O número de variáveis indicadoras é 13 e o número de parâmetros a serem estimados são 29 (13 cargas fatoriais, 13 erros de medida e 3 correlações fatoriais). O número de graus de liberdade é 62. As variáveis indicadoras: ESC6, ESC3 e ESC1 pertencentes a cada fator terá carga fatorial igual ao valor 1 para o software Mplus.

**Modelo 6:** Este sexto modelo teórico (figura 3.6) também se origina a partir da revisão de literatura relacionada á escala que estamos validando. Este modelo utiliza a soma de alguns itens da escala para formar novos itens aditivos, ou compostos. Assim o modelo é composto não pelos itens originais, mas pela soma entre itens específicos, o que foi denominado na teoria de modelo parcelado:

ESC6+ESC16; ESC8+ESC7 no fator 1 (F1).

ESC10+ESC12; ESC18+ESC20 no fator 2 (F2).

ESC1+ESC2; ESC4+ESC5 no fator 3 (F3).

ESC9+ESC13; ESC14+ESC3+ESC15 no fator 4 (F4).

Assim, o modelo considerado possui 4 fatores, sendo que o número de variáveis indicadoras é 8 e o número de parâmetros a serem estimados é 22 (8 cargas fatoriais, 8 erros de medida e 6 correlações fatoriais). Assim, sabendo que o número de elementos da matriz de covariância amostral é  $p(p+1)/2 = 36$ , o número de graus de liberdade é  $36 - 22 = 14$  sendo que como  $df > 0$  o modelo então pode ser estimado. As variáveis indicadoras pertencentes a cada fator terão carga fatorial igual ao valor 1 no software Mplus.

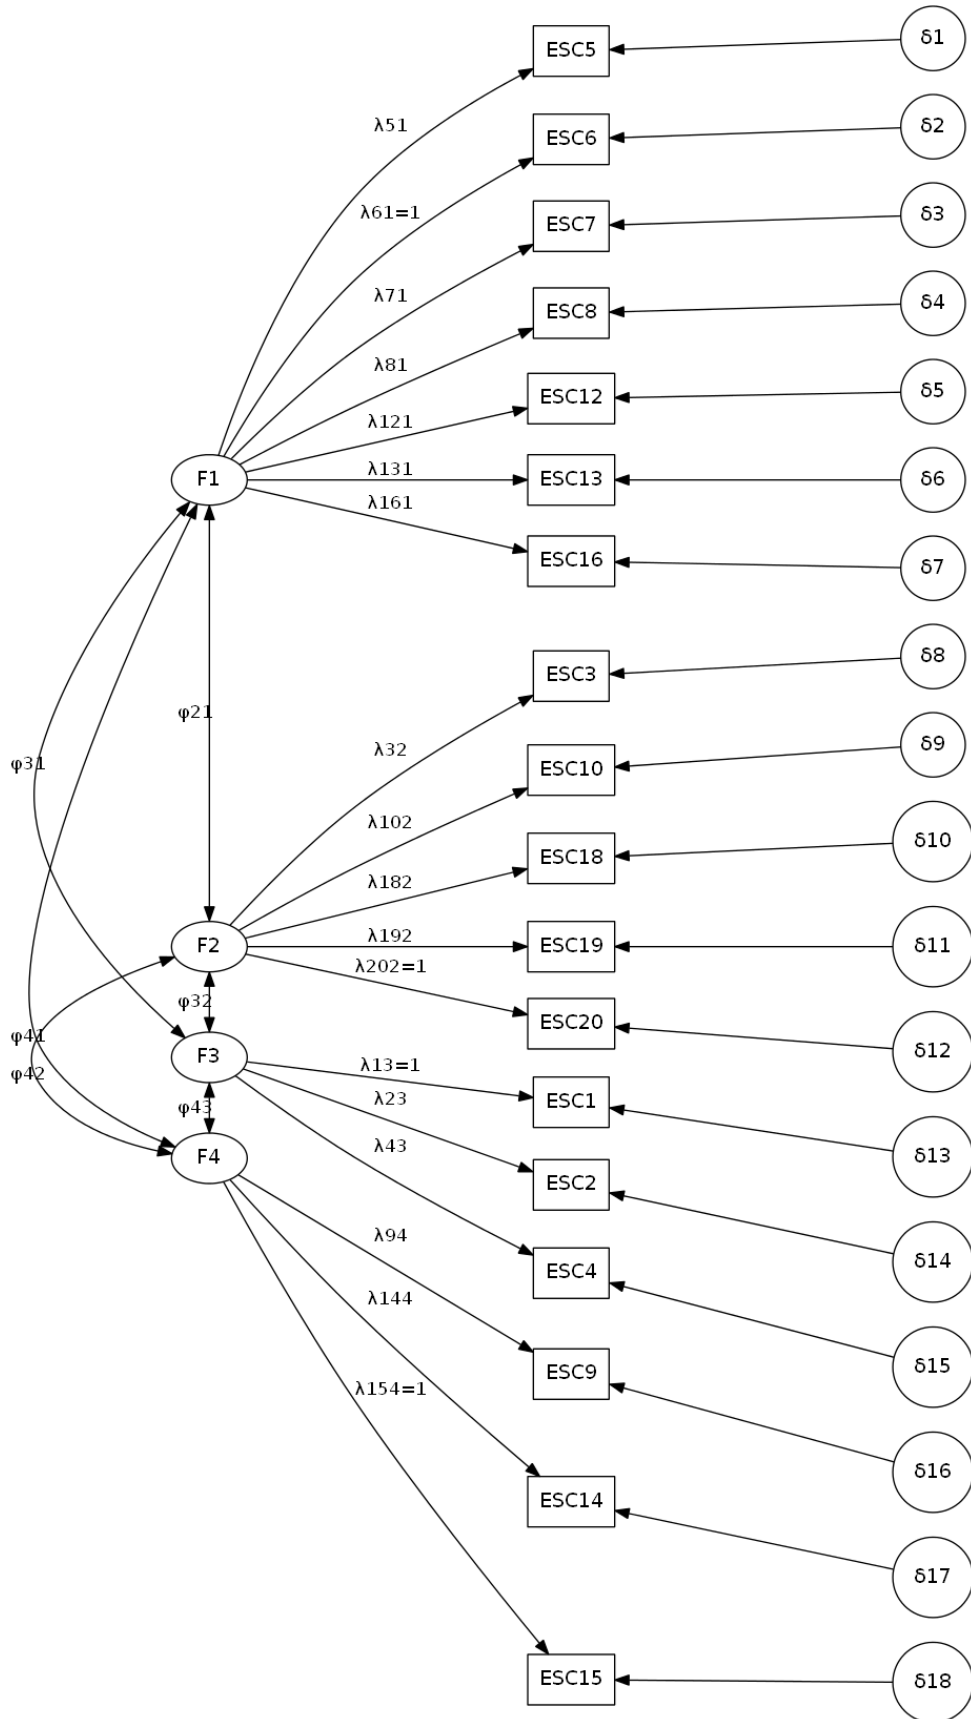


Fig. 3.2- Modelo 2 – Modelo de 4 fatores obtidos por AFE, método de PAF com rotação Promax, considerando todos os itens menos o 11 e 17



Fig. 3.3 - Modelo 3 – modelo de 3 fatores obtidos por AFE, método de PAF com rotação Promax, considerando todos os itens menos os itens 10, 11, 12, 17, 18, 19, e 20

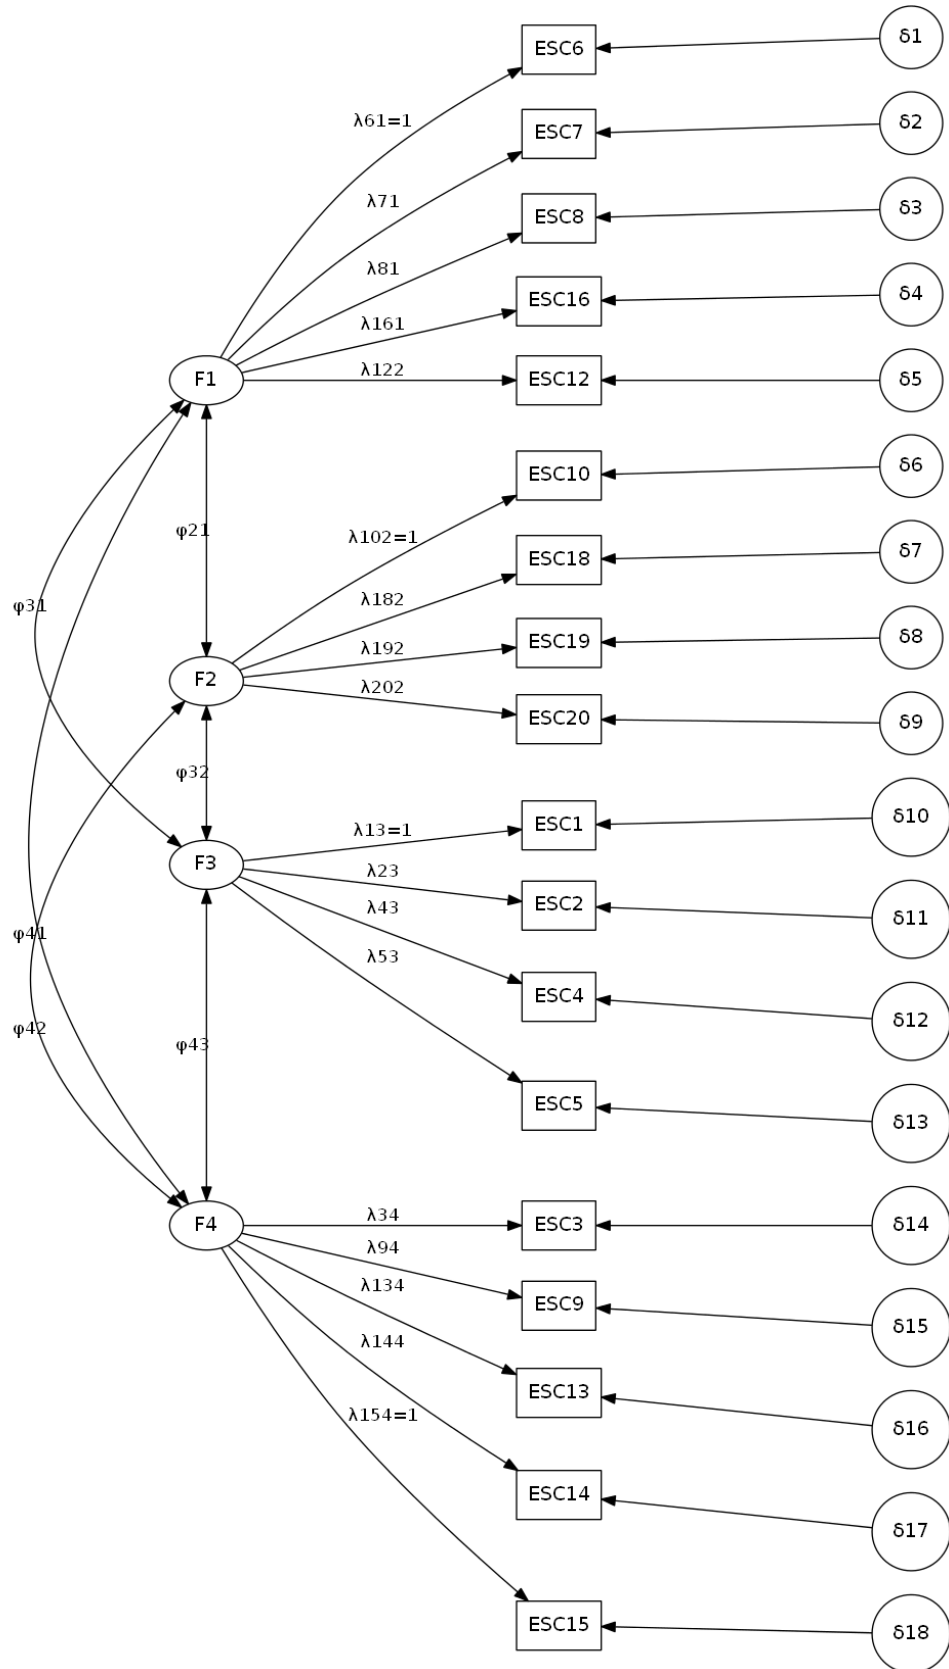


Fig. 3.4 - Modelo 4 - Modelo 4 fatores baseado no modelo teórico, considerando todos os itens menos o 11 e 17

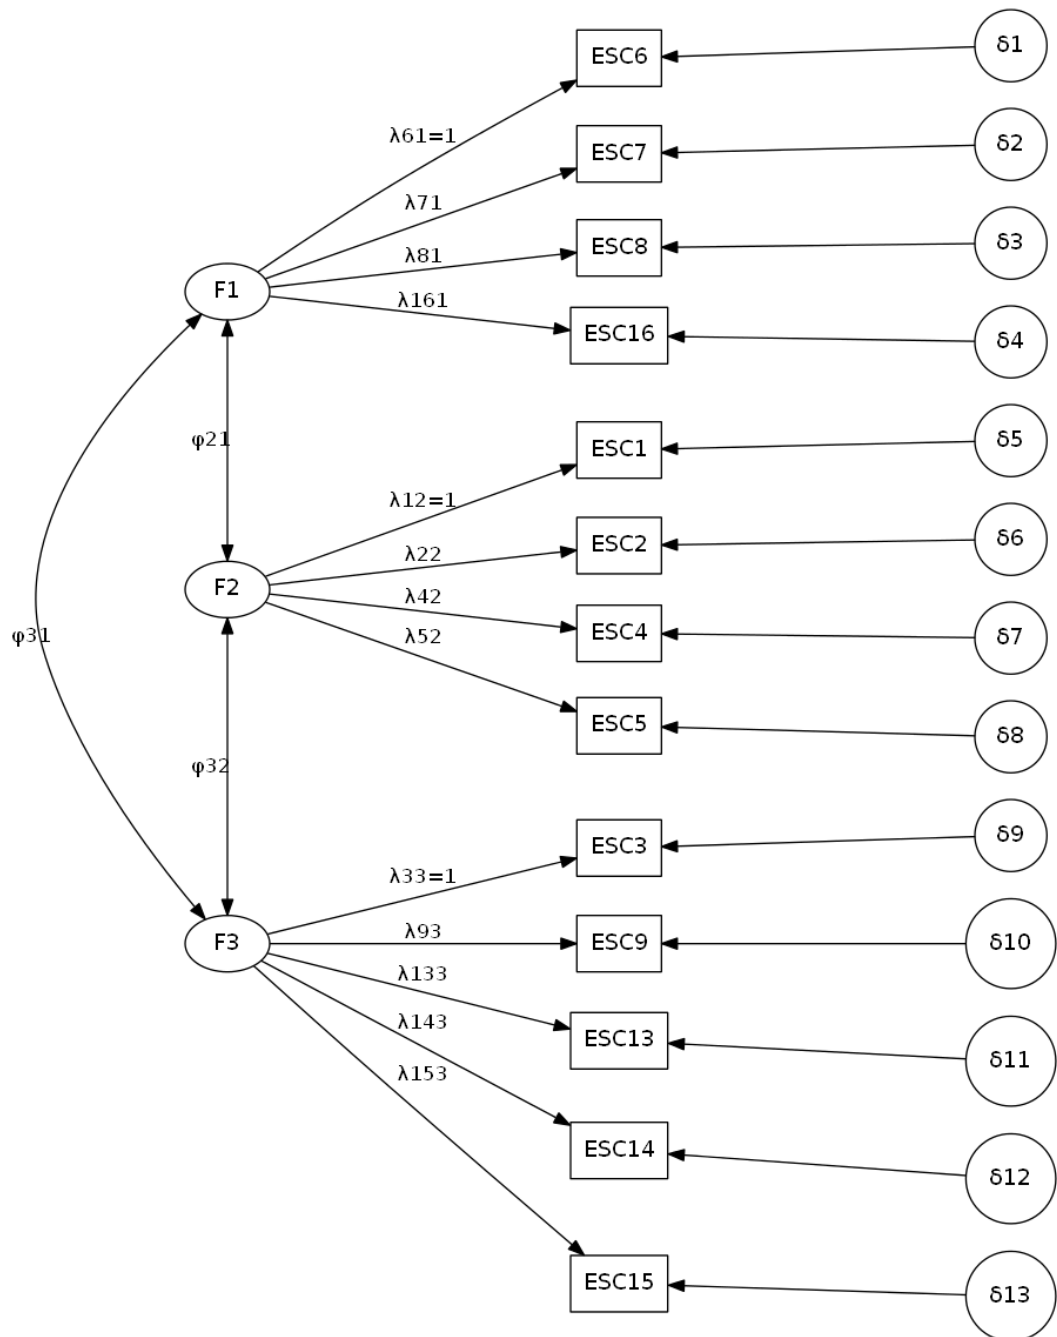


Fig. 3.5. - Modelo 5 – Modelo de 3 fatores baseado no modelo teórico da literatura, considerando todos os itens menos os itens 10, 11, 12, 17, 18, 19 e 20

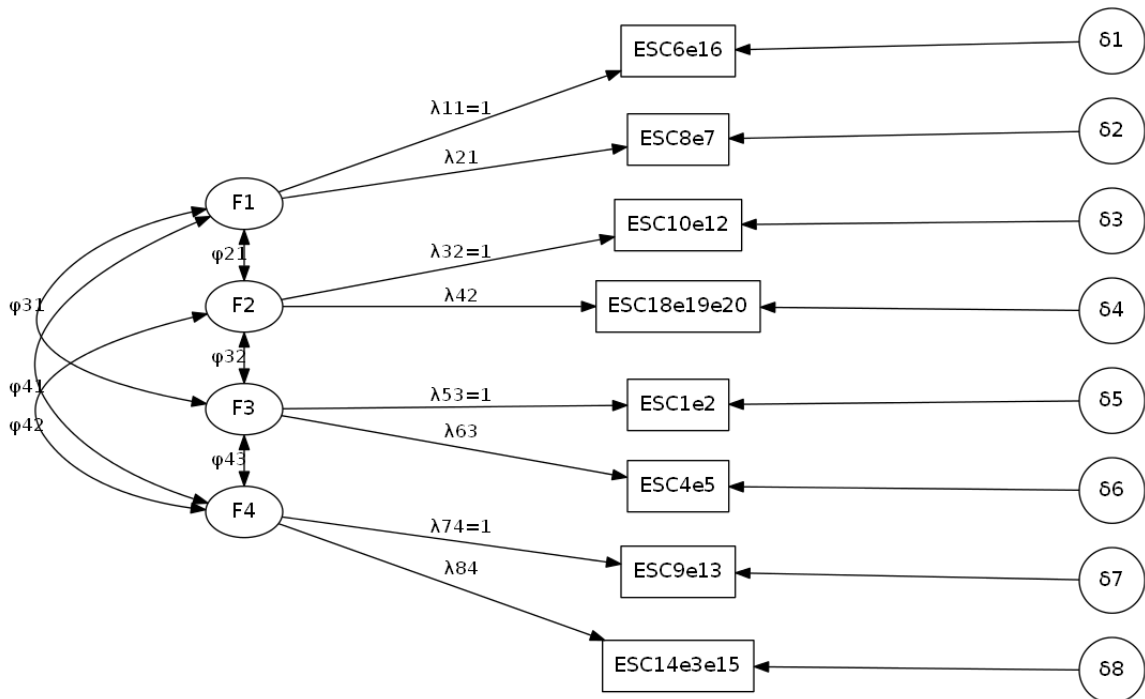


Fig. 3.6. - Modelo 6 – modelo de 4 fatores baseados no modelo teórico parcelado da literatura

### 3.2. RESULTADOS DAS ANÁLISES FATORIAIS CONFIRMATÓRIAS USANDO O SOFTWARE R

Na análise dos resultados após a estimação dos parâmetros do modelo vamos apresentar os índices de ajuste, ou seja, os índices de qualidade do ajuste dos modelos aos dados da amostra brasileira. Estes índices de ajustamento foram apresentados no capítulo 2, e optamos por mostrar os índices mais comuns utilizados na literatura relacionada. O pacote SEM do R oferece alguns índices de ajuste que apresentaremos abaixo. É importante mencionar que não todos estes índices se encontram no Mplus, pois este último apresenta também outros índices que serão comentados nos resultados.

Item	Qui(df)	GFI	AGFI	SRMR	RMSEA	IC RMSEA	CFI	NFI	NNFI (TLI)
<b>M1 - 4 Fatores</b>	242,2 (164)	0,902	0,875	0,055	0,047	[0,034;0,059]	0,920	0,792	0,907
<b>M2 - 4 Fatores</b>	209,56 (129)	0,905	0,874	0,057	0,054	[0,040;0,067]	0,911	0,803	0,895
<b>M3 - 3 Fatores</b>	84,98 (62)	0,947	0,922	0,048	0,041	[0,014;0,062]	0,957	0,861	0,946
<b>M4 - 4 Fatores</b>	251,53 (129)	0,883	0,846	0,064	0,066	[0,054;0,078]	0,865	0,763	0,840
<b>M5 - 3 Fatores</b>	119,79 (62)	0,924	0,889	0,062	0,066	[0,048;0,083]	0,892	0,804	0,864
<b>M6 - 4 Fatores</b>	51,452 (14)	0,948	0,865	0,051	0,111	[0,080;0,145]	0,921	0,898	0,842



Tabela 3.1. – Índices de ajustes dos 6 modelos testados pelo R

A tabela 3.1. mostra os índices de ajuste dos modelos testados. Em termos do Índice de ajuste RMSEA, que aponta para um ajuste parcimonioso (modelo que envolva o mínimo de parâmetros possíveis a serem estimados e que explique bem o comportamento da amostra brasileira), os modelos 1, 2 e 3 tiveram um bom ajuste ( $RMSEA < 0,06$ ). Já os modelos 4, 5 e 6 não cumpriram esta condição, ou seja, em termos do RMSEA, não seriam modelos apropriados. Entre os modelos 1, 2 e 3, foi este último o que obteve melhor RMSEA o que significa que os parâmetros do modelo conseguem reproduzir “melhor” ou de forma mais aproximada a covariância populacional, sendo, portanto, este o melhor modelo de acordo com este índice.

Em termos de ajuste absoluto, temos que o melhor modelo segundo o índice SRMR é o modelo 3 de 3 fatores, pois apresenta o valor mais próximo de zero o que representa a discrepância média entre as matrizes de correlação observada e a hipotética. Entretanto, todos os modelos possuem um SRMR adequado, inferior ao ponto de corte de 0.08. Os índices GFI e AGFI medem a quantidade relativa de variância e covariância na matriz S que é conjuntamente explicada pela matriz de covariância estimada ( $\Sigma$ ). Seus valores flutuam entre 0 e 1, sendo que valores próximos de 1 são indicativos de bom ajuste. O modelo 3 foi o único que obteve valores acima de 0,9 nestes dois índices. Cabe destacar que estes dois últimos índices não são muito utilizados, pois demonstraram pobre comportamento em estudos de simulação (Ver Brown, 2006).

Considerando os resultados dos índices comparativos, e tendo em conta que os pontos de corte dos índices CFI, TLI e NFI devem ser  $> 0,90$  podemos indicar que o modelo 3 apresentou os melhores resultados já que CFI e TLI e o NFI estão neste intervalo. Entretanto o modelo 1 e 2 também apresenta um CFI  $> 0,90$  o que mostra que são modelos fáveis de serem considerados.

Nesta primeira avaliação poderíamos dizer que o modelo 3 que é o modelo de 3 fatores baseados na amostra brasileira é o melhor modelo, pois se ajusta bem aos dados. Porém, além de observar os resultados dos índices de ajuste é importante também observar os resultados no que diz respeito aos resíduos padronizados e aos

índices de modificação para identificar a chamada falta de especificação do modelo. No que diz respeito aos resíduos padronizados, todos os modelos apresentaram resíduos entre -2 e 2. O bom comportamento residual dá indícios que parâmetros adicionais em algum dos modelos não são necessários. Os índices de modificação (IM) são obtidos para achar novas relações (entre erros de covariância ou novas relações entre fatores latentes e variáveis observadas) a fim de re-especificar o modelo. Os IM para cada modelo são apresentados na tabela 3.2 (o pacote R apresenta os 5 índices mais importantes).

Modelo	IM	Relação	Modelo	IM	Relação
<b>M1 - 4 Fatores</b>	14,76	ESC20 <-> ESC16	<b>M4 - 4 Fatores</b>	15,24	ESC20 <-> ESC16
	9,98	ESC15 <-> ESC12		13,1	F3 -> ESC13
	9,53	ESC10 <-> ESC1		11,35	ESC4 <-> ESC1
	9,37	F3 -> ESC8		10,65	ESC20 <-> ESC6
	8,07	F4 -> ESC20		10,03	ESC10 <-> ESC1
<b>M2 - 4 Fatores</b>	14,14	ESC20 <-> ESC16	<b>M5 - 3 Fatores</b>	10,44	ESC4 <-> ESC1
	10,84	ESC15 <-> ESC12		9,85	ESC6 <-> ESC2
	9,64	ESC10 <-> ESC1		8,93	F3 -> ESC13
	9,36	ESC5 <-> ESC4		8,23	ESC5 <-> ESC1
	8,55	F3 -> ESC20		7,09	F1 -> ESC6
<b>M3 - 3 Fatores</b>	10,19	ESC5 <-> ESC4	<b>M6 - 4 Fatores</b>	11,72	F3 <-> ESC9E13
	8,94	ESC8 <-> ESC2		9,86	ESC18E19E20 <-> ESC6E16
	8,86	F3 ->ESC6		8,62	F4 ->ESC9E13
	6,38	ESC7 <-> ESC1		6,9	F3 -> ESC14E3E15
	5,61	ESC6 <-> ESC2		6,19	ESC10E12 <-> ESC1E2

Tabela 3.2. – Índices de modificação dos 6 modelos testados pelo R

É importante salientar que a escolha das novas relações nascem do bom senso do pesquisador e baseado na teoria. Assim, optou-se por gerar os novos modelos considerando somente a primeira relação de covariância entre os erros de medida, neste caso,  $\delta_{ESC20} <-> \delta_{ESC16}$  (primeira relação comum aos modelos 1, 2 e 3). Somente com fins didáticos mostram-se a seguir as novas re-especificações uma vez que os índices de modificação da tabela 3.2. não são relevantes. Assim, obtiveram-se novos índices de ajuste que resultaram na tabela 3.3.

Item	Qui(df)	GFI	AGFI	SRMR	RMSEA	IC RMSEA	CFI	NFI	NNFI (TLI)
<b>M1 - 4 Fatores</b>	226,56 (163)	0,909	0,882	0,053	0,042	[0,028;0,055]	0,935	0,806	0,924
<b>M2 - 4 Fatores</b>	194,53 (128)	0,911	0,886	0,054	0,049	[0,034;0,062]	0,927	0,817	0,912
<b>M3 - 3 Fatores</b>	74,452 (61)	0,953	0,930	0,045	0,032	[NA;0,055]	0,975	0,878	0,968
<b>M4 - 4 Fatores</b>	235,4 (128)	0,890	0,853	0,062	0,062	[0,049;0,074]	0,882	0,778	0,859
<b>M5 - 3 Fatores</b>	108,89 (61)	0,931	0,897	0,061	0,060	[0,041;0,078]	0,910	0,822	0,885
<b>M6 - 4 Fatores</b>	37,676 (13)	0,962	0,893	0,044	0,094	[0,059;0,129]	0,948	0,925	0,888

Tabela 3.3. – Índices de ajustes dos 6 modelos testados pelo R ajustados pelo índice de modificação

Podemos observar que novamente o modelo 3 continua sendo o melhor modelo, pois está melhor ajustado em comparação aos outros modelos hipotetizados. Um objetivo importante na re-especificação é não sobre especificar o modelo, ou seja, utilizar parâmetros a mais, pois o importante é obter soluções parcimoniosas. Comparando as soluções de ajuste antes e depois de introduzir os índices de modificação, temos que a melhora dos índices não foram excepcionais. Além disso, os resíduos normais dentro dos limites -2 e 2 já tinham evidenciado que não era preciso a adição de mais parâmetros nos modelos. Podemos ver na tabela 3.4. os resíduos padronizados do modelo 3:

	ESC1	ESC2	ESC3	ESC4	ESC5	ESC6	ESC7	ESC8	ESC9	ESC13	ESC14	ESC15	ESC16
ESC1	0,0000	-0,0194	-0,0794	0,0416	-0,0663	-0,0487	0,0917	-0,0611	-0,0261	-0,0698	-0,0198	0,0094	-0,0091
ESC2	-0,0194	0,0000	0,0448	-0,0146	0,0412	-0,0719	0,0411	0,1125	0,0084	-0,0087	-0,0500	0,0540	0,0269
ESC3	-0,0794	0,0448	0,0000	0,0362	0,0774	0,0195	0,0437	0,0435	-0,0623	-0,0070	0,0662	-0,0201	-0,0859
ESC4	0,0416	-0,0146	0,0362	0,0000	0,1635	-0,0852	-0,0253	-0,0048	-0,0130	0,0652	0,0328	-0,0524	0,0760
ESC5	-0,0663	0,0412	0,0774	0,1635	0,0000	-0,0428	-0,0297	0,0274	0,0133	-0,0036	-0,0058	0,0641	0,0094
ESC6	-0,0487	-0,0719	0,0195	-0,0852	-0,0428	0,0000	0,0126	0,0078	0,0357	-0,0244	-0,0995	0,0251	0,0573
ESC7	0,0917	0,0411	0,0437	-0,0253	-0,0297	0,0126	0,0000	-0,0093	0,0884	-0,0111	-0,0592	0,0095	-0,0192
ESC8	-0,0611	0,1125	0,0435	-0,0048	0,0274	0,0078	-0,0093	0,0000	0,0239	0,0177	-0,0972	-0,0450	-0,0472
ESC9	-0,0261	0,0084	-0,0623	-0,0130	0,0133	0,0357	0,0884	0,0239	0,0000	0,0308	-0,0043	-0,0043	0,0343
ESC13	-0,0698	-0,0087	-0,0070	0,0652	-0,0036	-0,0244	-0,0111	0,0177	0,0308	0,0000	0,0051	-0,0250	0,0935
ESC14	-0,0198	-0,0500	0,0662	0,0328	-0,0058	-0,0995	-0,0592	-0,0972	-0,0043	0,0051	0,0000	0,0380	-0,0207
ESC15	0,0094	0,0540	-0,0201	-0,0524	0,0641	0,0251	0,0095	-0,0450	-0,0043	-0,0250	0,0380	0,0000	-0,0873
ESC16	-0,0091	0,0269	-0,0859	0,0760	0,0094	0,0573	-0,0192	-0,0472	0,0343	0,0935	-0,0207	-0,0873	0,0000

Tabela 3.4. – Matriz de Resíduos padronizados do modelo 3.

A seguir (figura 3.7.) são apresentadas as estimativas padronizadas dos parâmetros para o modelo 3:

	Estimate	Std Error	z value	Pr(> z )	
theta05	0.53173	0.068520	7.7602	8.4377e-15	ESC5 <--- F1
theta06	0.79278	0.061717	12.8454	0.0000e+00	ESC6 <--- F1
theta07	0.66399	0.065082	10.2024	0.0000e+00	ESC7 <--- F1
theta08	0.80587	0.061271	13.1525	0.0000e+00	ESC8 <--- F1
theta13	0.41557	0.070595	5.8867	3.9404e-09	ESC13 <--- F1
theta16	0.31753	0.072269	4.3937	1.1146e-05	ESC16 <--- F1
theta23	0.44192	0.076919	5.7452	9.1794e-09	ESC3 <--- F2
theta29	0.50428	0.075726	6.6592	2.7534e-11	ESC9 <--- F2
theta34	0.40269	0.077487	5.1968	2.0271e-07	ESC14 <--- F2
theta35	0.74108	0.075997	9.7515	0.0000e+00	ESC15 <--- F2
theta41	0.44494	0.089997	4.9440	7.6539e-07	ESC1 <--- F3
theta42	0.56632	0.095679	5.9189	3.2404e-09	ESC2 <--- F3
theta44	0.56187	0.095431	5.8877	3.9170e-09	ESC4 <--- F3
theta61	0.80202	0.095238	8.4213	0.0000e+00	ESC1 <--> ESC1
theta62	0.67929	0.105044	6.4667	1.0018e-10	ESC2 <--> ESC2
theta63	0.80471	0.085774	9.3817	0.0000e+00	ESC3 <--> ESC3
theta64	0.68431	0.104486	6.5492	5.7834e-11	ESC4 <--> ESC4
theta65	0.71726	0.074698	9.6021	0.0000e+00	ESC5 <--> ESC5
theta66	0.37150	0.053586	6.9328	4.1265e-12	ESC6 <--> ESC6
theta67	0.55911	0.063249	8.8398	0.0000e+00	ESC7 <--> ESC7
theta68	0.35057	0.052610	6.6636	2.6724e-11	ESC8 <--> ESC8
theta69	0.74571	0.082911	8.9941	0.0000e+00	ESC9 <--> ESC9
theta73	0.82730	0.082830	9.9879	0.0000e+00	ESC13 <--> ESC13
theta74	0.83784	0.087396	9.5867	0.0000e+00	ESC14 <--> ESC14
theta75	0.45080	0.084817	5.3149	1.0672e-07	ESC15 <--> ESC15
theta76	0.89918	0.088447	10.1663	0.0000e+00	ESC16 <--> ESC16
theta81	0.67119	0.067625	9.9252	0.0000e+00	F2 <--> F1
theta82	0.37538	0.095047	3.9494	7.8341e-05	F3 <--> F1
theta83	0.49260	0.102696	4.7967	1.6130e-06	F3 <--> F2

Figura 3.7. – Estimativas padronizadas pelo software R

Podemos notar que todos os erros padrões são coerentes, mas também não são grandes, e também não são tão pequenos a ponto de comprometer o teste estatístico. Assim, podemos observar que todos os parâmetros do modelo são significativos já que  $|z| > 1,96$ . As estimativas obtidas pelo pacote SEM do R são padronizadas, mas isto não dificulta obter as estimativas não padronizadas (ver Brown, 2006; página 133). Por solução padronizada entende-se que a métrica das variáveis indicadoras e fatores latentes foram padronizados. Assim, as cargas fatoriais na solução padronizada podem ser interpretadas como um coeficiente de regressão padronizado. Conseqüentemente, temos que um aumento na pontuação de F1 está associada com o aumento padronizado de 0,806 na variável indicadora ESC8 (a maior para o fator F1); para F2 temos que o maior aumento padronizado se

dá na variável ESC15 (0.74108) e para o fator F3 o maior aumento se encontra na variável ESC2 (0,5632). Também, como na solução não existem cargas fatoriais cruzadas (relação entre um fator latente e alguma variável indicadora pertencente a outro fator latente) entre as variáveis indicadoras, as cargas fatoriais podem também ser interpretadas como a correlação entre a variável indicadora com o fator latente, pois o fator latente é o preditor único da variável indicadora. Assim, novamente as mesmas variáveis (ESC8, ESC15 e ESC2) possuem as maiores correlações com seus respectivos fatores. Elevando ao quadrado as cargas fatoriais padronizadas obtemos a proporção de variância na variável indicadora que é explicada pelo fator latente, desta forma, 64,9% da variância na variável ESC8 é explicada pelo fator F1, 54,9% da variância na variável ESC15 é explicada por F2 e 32% da variância na variável ESC2 é explicada por F3.

Pode-se observar que existe uma correlação fatorial importante entre o fator latente F1 e F2 (com o símbolo  $F1 \leftrightarrow F2$ ) de 0,67, sendo que as correlações entre F1 e F3 ( $F1 \leftrightarrow F3$ ) e F2 e F3 ( $F2 \leftrightarrow F3$ ) não superam o valor 0.5.

### 3.3 RESULTADOS DAS ANÁLISES FATORIAIS CONFIRMATÓRIAS USANDO O SOFTWARE MPLUS

Os resultados dos índices de ajuste para os mesmo modelos estudados se encontram apresentados na tabela 3.5. Os resultados do Mplus utilizam o método de estimação WLSMV, próprio para variáveis categóricas e a matriz de entrada de dados é a matriz de correlação policórica. Deve-se ter presente que a correlação policórica é uma medida de associação utilizada (como uma substituição para a correlação de Pearson) quando as variáveis são medições originais com 3 ou mais categorias.

Item	Qui(df)	SRMR	RMSEA	IC RMSEA	PCLOSE	CFI	NNFI (TLI)	WRMR
<b>M1 - 4 Fatores</b>	208,428 (164)	0,068	0,035	[0,018;0,049]	0,777	0,979	0,975	0,888
<b>M2 - 4 Fatores</b>	181,012 (129)	0,070	0,043	[0,027;0,057]	0,962	0,973	0,968	0,920
<b>M3 - 3 Fatores</b>	67,639(62)	0,058	0,020	[0;0,047]	0,970	0,995	0,993	0,769
<b>M4 - 4 Fatores</b>	225,146 (129)	0,080	0,059	[0,046;0,071]	0,131	0,950	0,941	1,060
<b>M5 - 3 Fatores</b>	107,6 (62)	0,076	0,058	[0,039;0,076]	0,221	0,957	0,946	1,021
<b>M6 - 4 Fatores</b>	40,884 (14)	0,053	0,094	[0,061;0,128]	0,016	0,969	0,937	0,924

Tabela 3.5. – Índices de ajustes dos 6 modelos testados pelo Mplus

Em termos do índice RMSEA de todos os modelos, com exceção do modelo 6, mostraram um bom ajuste ( $RMSEA < 0,06$ ). Entre os primeiros 5 modelos, foi o modelo 3 que obteve o menor RMSEA (0,02), seguido do modelo 1 (0,035). Pelos intervalos de confiança do RMSEA vemos que os mais aceitáveis correspondem aos modelos 1, 2 e 3 uma vez que o limite superior do IC continua estando abaixo do ponto de corte de 0,06. Uma característica do Mplus é a presença da estatística PCLOSE (que informa a probabilidade do RMSEA ser menor que 0,05). Do anterior, podemos observar que somente os modelos 2 e 3 possuem probabilidade maior do que 0,95 sendo o modelo 3 com o melhor PCLOSE (0,97).

Em termos de ajuste absoluto, temos que o melhor modelo segundo o índice SRMR é o modelo 6 de 4 fatores (parcelado), embora seu RMSEA seja próximo de 0,1. O importante para decidir o melhor modelo que ajusta os dados é a sua adequação em todos os índices, portanto, o modelo 3 de 3 fatores, novamente, apresenta um SRMR mais baixo (0,058) em relação aos modelos restantes. Entretanto, todos os modelos 1, 2 e 5 possuem um SRMR adequado inferior ao ponto de corte de 0,08.

Considerando os resultados dos índices comparativos, e tendo em conta que os pontos de corte dos índices CFI e TLI devem ser  $> 0,90$  podemos indicar que o modelo 3 apresentou os melhores resultados tanto no CFI como no TLI (ambos índices apresentaram valores maiores a 0,99) seguido pelo modelo 1 (0,979 e 0,975 respectivamente) e 2 (0,973 e 0,968 respectivamente).

É interessante notar que o índice de ajuste WRMR (*weighted root-mean-square residual*) fornecido apenas pelo Mplus é um índice semelhante ao SRMR que mede a diferença média ponderada entre as covariâncias amostrais e as covariâncias populacionais estimadas. Os resultados propostos por YU (2002) sugerem um ponto de corte de 1, mas é uma estatística que pode ser usada para modelos com variáveis binárias quando  $N > 250$ , portanto este índice não será considerado nos resultados.

Nesta primeira avaliação, poderíamos dizer que o modelo 3 é o melhor modelo, pois se ajusta bem aos dados. Porém, como mencionado na seção dos resultados do pacote R, além de observar os resultados dos índices de ajuste é importante também observar os resultados dos resíduos padronizados e os índices de modificação (para todos os modelos) para identificar a chamada falta de especificação.

Com respeito à correlação residual, todos os modelos apresentaram resíduos normais, ou seja, próximos de zero. O bom comportamento residual dá indícios que parâmetros adicionais em algum dos modelos não são necessários em termos de melhorar a covariância existente.

Como exemplo e para comparação com os resultados do software R, os índices de modificação obtidos para cada modelo foram os seguintes (sendo que o Mplus, por defeito, apresenta os índices com valor maior a 10, mas se optou por mostrar mesmo os menores a este valor para comparar com o R):

Modelo	IM (EPC)	Relação	Modelo	IM (EPC)	Relação
<b>M1 - 4 Fatores</b>	10,067 (-0,453)	ESC20 <-> ESC16	<b>M4 - 4 Fatores</b>	22,139 (0,324)	F3 -> ESC5
	9,824	F4 ->ESC20		16,485	F4 -> ESC5
	7,725	ESC10 <-> ESC1		15,054	ESC4 <-> ESC1
<b>M2 - 4 Fatores</b>	10,33 (-0,460)	ESC20 <-> ESC16	<b>M5 - 3 Fatores</b>	26,942 (-0,321)	F3 -> ESC5
	10,779	F3 ->ESC20		14,979	F3 -> ESC4
	11,005	F1 -> ESC10		14,265	ESC4 <-> ESC1
<b>M3 - 3 Fatores</b>	6,652 (0,33)	ESC5 <-> ESC4	<b>M6 - 4 Fatores</b>	16,608 (-0,396)	F2 -> ESC14E3E15
	3,18	ESC8 <-> ESC2		16,593	F2 -> ESC9E13
				10,203	ESC18E19E20 <-> ESC6E16

Tabela 3.6. – Índices de ajustes dos 6 modelos testados pelo Mplus ajustados pelo índice de modificação

Vemos na tabela 3.6, que os índices de modificação apresentados pelo Mplus são similares aos apresentados pelo R com a diferença que no Mplus os índices têm valores mais baixos com exceção do modelo 5 e 6. Considerando os índices de modificação para os erros de medida, e não as relações para os coeficientes de regressão (pois idealizou-se um modelo sem cargas fatoriais cruzadas entre os construtos, isto é, não existe uma relação entre um fator latente e alguma variável indicadora pertencente a outro fator latente) temos as mesmas relações encontradas pelo R a exceção do modelo 4, pois não foi encontrada a relação entre ESC20 <->

ESC16 e sim a relação ESC4 <-> ESC1. Porém, esta última relação se encontra em segundo lugar de importância no software R.

Também podemos notar que, associado a cada índice de modificação, existe uma estatística chamada EPC (*expected parameter change*), a qual fornece uma estimativa de quanto o parâmetro é esperado mudar numa direção, positiva ou negativa, se fosse livremente estimado numa análise subsequente. Este valor é apresentado na versão padronizada, pois o valor não padronizado é proporcional à escala de medida das variáveis indicadoras. Podemos dizer que existe uma correlação moderada entre os erros de medida, sendo que o valor mais alto se encontra no modelo 1 (-0,453). Cabe mencionar também, que os índices de modificação mostram o quanto o qui-quadrado poderia ser reduzido se incorporado a correlação entre, por exemplo, os erros de medida de ESC20 <-> ESC16 (neste caso a redução seria de 10,067 para o modelo 1). Assim é importante avaliar se é vantajoso seguir melhorando os modelos através destes índices sem cair na sobre especificação e principalmente, se as novas relações tenham sentido ao pesquisador. Como exemplo, se re-especificaram os 6 modelos com as novas relações entre as covariâncias dos erros de medida e se obteve novos índices de ajuste mostrados na tabela 3.7:

Item	Qui(df)	SRMR	RMSEA	IC RMSEA	PCLOSE	CFI	NNFI (TLI)	WRMR
<b>M1 - 4 Fatores</b>	*	*	*	*	*	*	*	*
<b>M2 - 4 Fatores</b>	*	*	*	*	*	*	*	*
<b>M3 - 3 Fatores</b>	60,806 (61)	0,055	0,000	[0;0,041]	0,990	1,000	1,000	0,721
<b>M4 - 4 Fatores</b>	211,54 (128)	0,077	0,055	[0,041;0,068]	0,263	0,957	0,948	1,016
<b>M5 - 3 Fatores</b>	94,402 (61)	0,071	0,050	[0,029;0,069]	0,471	0,968	0,960	0,940
<b>M6 - 4 Fatores</b>	30,088 (13)	0,046	0,078	[0,041;0,115]	0,096	0,980	0,957	0,796

Tabela 3.7. – Índices de ajustes dos 6 modelos testados pelo Mplus

A escolha do modelo final não foi considerada tomando em conta estes novos modelos, por uma série de motivos. Os dois primeiros modelos (M1 e M2) tiveram erros padrões negativos para as estimativas do novo parâmetro incluído (por isso os índices de ajuste não foram apresentados). O RMSEA dos modelos 4, 5 e 6 mostram baixo PCLOSE o que significa que o RMSEA pode não estar abaixo do ponto de corte de 0,06 (veja também as estimativas do intervalo de confiança). O modelo 3, apesar de apresentar um ajuste quase perfeito (dado o valor 1 nos índices



CFI e TLI) não será considerado como modelo final, pois a relação entre os erros de medida entre ESC5 e ESC4 não são apontados pelo pesquisador como sendo de interesse da questão em estudo.

Sendo assim, o modelo mais parcimonioso foi o modelo 3 de 3 fatores. Assim, serão apresentadas a continuação seguir a matriz de correlação policórica amostral (S), a matriz de correlação policórica estimada ( $\Sigma$ ), matriz de correlação residual, as estimativas não padronizadas e as estimativas padronizadas para os parâmetros disponíveis no Mplus.

Na matriz de correlação amostral (figura 3.8.) podemos observar que a maior parte das correlações entre as variáveis é fraca a moderada sendo que nas variáveis ESC7 – ESC6 e ESC8 – ESC7 as correlações foram 0,664 e 0,64 respectivamente. A maior correlação reportada entre as variáveis foi entre ESC8 e ESC6 (0,766).

CORRELATION MATRIX (WITH VARIANCES ON THE DIAGONAL)

	ESC1	ESC2	ESC3	ESC4	ESC5
ESC1	0.300				
ESC2	0.018	0.215			
ESC3	0.370	0.377	0.200		
ESC4	0.035	0.201	0.301	0.340	
ESC5	0.107	0.132	0.323	0.107	0.476
ESC6	0.258	0.234	0.311	0.140	0.400
ESC7	0.093	0.357	0.362	0.209	0.552
ESC8	0.109	0.194	0.214	0.159	0.252
ESC9	0.002	0.102	0.147	0.188	0.268
ESC13	0.094	0.090	0.331	0.194	0.191
ESC14	0.232	0.341	0.391	0.201	0.421
ESC15	0.057	0.113	0.013	0.183	0.217

CORRELATION MATRIX (WITH VARIANCES ON THE DIAGONAL)

	ESC6	ESC7	ESC8	ESC9	ESC13
ESC7	0.664				
ESC8	0.766	0.640			
ESC9	0.400	0.398	0.381		
ESC13	0.380	0.331	0.432	0.214	
ESC14	0.161	0.171	0.162	0.279	0.159
ESC15	0.537	0.440	0.455	0.509	0.234
ESC16	0.382	0.237	0.261	0.189	0.277

CORRELATION MATRIX (WITH VARIANCES ON THE DIAGONAL)

	ESC14	ESC15	ESC16
ESC15	0.449		
ESC16	0.081	0.094	

Figura 3.8. – Matriz de correlação amostral (S) do Mplus

A matriz de correlação estimada apresenta correlações bem próximas das correlações amostrais mencionadas acima, mas nesta nova matriz de correlação apresenta correlações um pouco menores às apresentadas nas relações de ESC7-ESC6, ESC8-ESC6 E ESC8-ESC7.

ESTIMATED MODEL AND RESIDUALS (OBSERVED - ESTIMATED)

	Model Estimated Covariances/Correlations/Residual Correlations				
	ESC1	ESC2	ESC3	ESC4	ESC5
ESC1					
ESC2	0.310				
ESC3	0.118	0.174			
ESC4	0.296	0.436	0.166		
ESC5	0.116	0.171	0.225	0.163	
ESC6	0.164	0.241	0.317	0.230	0.530
ESC7	0.142	0.209	0.275	0.199	0.460
ESC8	0.165	0.243	0.320	0.232	0.536
ESC9	0.139	0.205	0.322	0.195	0.266
ESC13	0.088	0.129	0.170	0.123	0.285
ESC14	0.098	0.145	0.228	0.138	0.188
ESC15	0.189	0.278	0.437	0.265	0.360
ESC16	0.067	0.099	0.130	0.094	0.217

	Model Estimated Covariances/Correlations/Residual Correlations				
	ESC6	ESC7	ESC8	ESC9	ESC13
ESC7	0.646				
ESC8	0.754	0.654			
ESC9	0.373	0.324	0.378		
ESC13	0.400	0.347	0.405	0.201	
ESC14	0.264	0.229	0.267	0.269	0.142
ESC15	0.507	0.440	0.513	0.515	0.272
ESC16	0.306	0.265	0.309	0.153	0.164

	Model Estimated Covariances/Correlations/Residual Correlations		
	ESC14	ESC15	ESC16
ESC15	0.365		
ESC16	0.108	0.208	

Figura 3.9. – Matriz de correlação estimada ( $\Sigma$ ) do Mplus

A partir da discrepância entre as matrizes de correlação estimada e observada, observa-se a matriz de correlação residual. Cabe mencionar que quando são analisadas variáveis categóricas (sem covariáveis no modelo) é apresentada a matriz de correlação residual e não a matriz de covariâncias. Segundo (Muthén, 2006), na análise de variáveis categóricas não é fornecida a matriz de covariância residual, apenas a matriz de correlação residual. É desejável que os resíduos padronizados sejam próximos de zero e podemos observar que na maioria dos casos as correlações residuais não superam 0,1.

Residuals for Covariances/Correlations/Residual Correlations					
	X1	X2	X3	X4	X5
X1					
X2	-0.011				
X3	-0.100	0.041			
X4	0.074	-0.059	0.035		
X5	-0.081	0.030	0.075	0.177	
X6	-0.056	-0.108	0.006	-0.123	-0.054
X7	0.116	0.025	0.037	-0.059	-0.060
X8	-0.072	0.114	0.041	-0.023	0.016
X9	-0.030	-0.011	-0.108	-0.036	-0.013
X13	-0.086	-0.027	-0.023	0.065	-0.017
X14	-0.005	-0.055	0.103	0.056	0.003
X15	0.043	0.063	-0.046	-0.064	0.060
X16	-0.010	0.014	-0.117	0.089	0.000

Residuals for Covariances/Correlations/Residual Correlations					
	X6	X7	X8	X9	X13
X7	0.018				
X8	0.012	-0.014			
X9	0.027	0.074	0.003		
X13	-0.020	-0.016	0.027	0.013	
X14	-0.103	-0.058	-0.106	0.010	0.017
X15	0.030	0.000	-0.058	-0.006	-0.038
X16	0.076	-0.028	-0.048	0.035	0.112

Residuals for Covariances/Correlations/Residual Correlations			
	X14	X15	X16
X15	0.084		
X16	-0.027	-0.114	

Figura 3.10. – Matriz de correlação residual do Mplus para o Modelo 3

## MODEL RESULTS

		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
F1	BY				
	ESC6	1.000	0.000	999.000	999.000
	ESC8	1.011	0.060	16.829	0.000
	ESC7	0.867	0.062	13.964	0.000
	ESC13	0.537	0.087	6.163	0.000
	ESC5	0.711	0.075	9.509	0.000
	ESC16	0.410	0.086	4.767	0.000
F2	BY				
	ESC15	1.000	0.000	999.000	999.000
	ESC14	0.521	0.110	4.739	0.000
	ESC3	0.625	0.111	5.648	0.000
	ESC9	0.737	0.097	7.626	0.000
F3	BY				
	ESC1	1.000	0.000	999.000	999.000
	ESC2	1.471	0.392	3.755	0.000
	ESC4	1.404	0.391	3.589	0.000
F2	WITH				
	F1	0.507	0.059	8.619	0.000
F3	WITH				
	F1	0.164	0.050	3.256	0.001
	F2	0.189	0.056	3.346	0.001
Variances					
	F1	0.745	0.060	12.479	0.000
	F2	0.700	0.101	6.901	0.000
	F3	0.211	0.083	2.555	0.011

Figura 3.11. – Estimativas não padronizadas do Mplus para o Modelo 3

## STD Standardization

		Estimate	S.E.	Est./S.E.	Two-Tailed P-Value
F1	BY				
	ESC6	0.863	0.035	24.958	0.000
	ESC8	0.873	0.035	25.109	0.000
	ESC7	0.749	0.046	16.373	0.000
	ESC13	0.463	0.074	6.273	0.000
	ESC5	0.614	0.060	10.168	0.000
	ESC16	0.354	0.074	4.784	0.000
F2	BY				
	ESC15	0.836	0.061	13.801	0.000
	ESC14	0.436	0.084	5.176	0.000
	ESC3	0.523	0.080	6.536	0.000
	ESC9	0.616	0.067	9.154	0.000
F3	BY				
	ESC1	0.459	0.090	5.110	0.000
	ESC2	0.676	0.100	6.784	0.000
	ESC4	0.645	0.103	6.256	0.000
F2	WITH				
	F1	0.702	0.065	10.793	0.000
F3	WITH				
	F1	0.412	0.091	4.549	0.000
	F2	0.491	0.103	4.795	0.000
Variances					
	F1	1.000	0.000	999.000	999.000
	F2	1.000	0.000	999.000	999.000
	F3	1.000	0.000	999.000	999.000

## R-SQUARE

Observed Variable	Estimate	S.E.	Est./S.E.	Two-Tailed P-Value	Residual Variance
ESC1	0.211	0.083	2.555	0.011	0.789
ESC2	0.457	0.135	3.392	0.001	0.543
ESC3	0.273	0.084	3.268	0.001	0.727
ESC4	0.416	0.133	3.128	0.002	0.584
ESC5	0.377	0.074	5.084	0.000	0.623
ESC6	0.745	0.060	12.479	0.000	0.255
ESC7	0.561	0.068	8.186	0.000	0.439
ESC8	0.762	0.061	12.554	0.000	0.238
ESC9	0.380	0.083	4.577	0.000	0.620
ESC13	0.215	0.068	3.137	0.002	0.785
ESC14	0.190	0.073	2.588	0.010	0.810
ESC15	0.700	0.101	6.901	0.000	0.300
ESC16	0.125	0.052	2.392	0.017	0.875

Figura 3.12. – Estimativas padronizadas do Mplus para o Modelo 3

Na figura 3.11, são apresentados os resultados não padronizados das estimativas fornecidas pelo Mplus. As cargas fatoriais não padronizadas de ESC6, ESC15 e ESC1 possuem valor 1, pois essas medidas observadas foram usadas como variáveis indicadoras (marker indicator), ou seja, suas cargas fatoriais foram fixadas em 1 para assim passar a métrica de ESC6, ESC15 E ESC1 dentro das variáveis latentes F1, F2 e F3, respectivamente. Conseqüentemente, os erros padrões dessas estimativas são zero (veja que o valor de z aparece como 999 em alusão a essa situação).

Pode-se dizer neste exemplo que todos os parâmetros estimados estão relacionados positivamente com seus respectivos fatores (dado que são todos  $>0$ ). Realizando uma interpretação das cargas fatoriais não padronizadas, pode-se dizer que uma unidade de aumento na dimensão latente de F1 está associado com 1,011 unidade de aumento na variável observada ESC8. Assim mesmo, uma unidade de aumento na dimensão latente de F2 e uma unidade em F3 está associado com 0,737 unidade de aumento na variável observada ESC9 e 1,471 unidade de aumento na variável respectivamente

Nos resultados podemos observar que todos os parâmetros são estatisticamente significantes, pois  $|z| > 1,96$ . Elevando ao quadrado as cargas fatoriais padronizadas (saída R-Square pelo Mplus) obtemos a proporção de variância na variável indicadora que é explicada pelo fator latente. Desta forma, 76,2% da variância na variável ESC8 é explicada pelo fator F1, 70% da variância na variável ESC15 é explicada por F2 e 45,7% da variância na variável ESC2 é explicada por F3.

Pode-se observar que existe uma correlação fatorial importante entre o fator latente F1 e F2 (0,702) sendo que as correlações entre F1  $\leftrightarrow$  F3 e F2  $\leftrightarrow$  F3 não superam o valor 0.5 (assim como nas encontradas no software R). É interessante notar que em pesquisa aplicada, a correlação fatorial que exceda 0,8 ou 0,85 é freqüentemente usada como critério para definir uma validade discriminante deficiente. Neste caso observa-se que não existem construtos sobrepostos e, portanto, não existe necessidade de definir esses dois construtos num único fator.

## **4 TUTORIAIS DA ANÁLISE FATORIAL CONFIRMATÓRIA NOS SOFTWARES R E MPLUS**

Neste capítulo serão apresentadas duas secções apresentado tutoriais sobre como utilizar os softwares estatísticos para realizar Análise Fatorial Confirmatória, sendo que a primeira será referente ao software Mplus versão 6.1 e a segunda ao software R versão 0.9-21. Será utilizado, como exemplo, a mesma amostra utilizada nas análises deste trabalho e o Modelo 1 apresentados no capítulo 3 em ambos os softwares. Isto possibilitará ao leitor as comparações entre os softwares e as limitações de cada um deles ao realizar a análise de AFC. O modelo 1 está composto por 4 fatores latentes considerando todos os itens da escala ESC (veja figura 3.1 da página 33).

### **4.1 TUTORIAL DA ANÁLISE FATORIAL CONFIRMATÓRIA NO SOFTWARE MPLUS**

O Mplus possui uma interface limitada, sendo que toda a interação é feita através de uma sintaxe relativamente simples no editor fornecido pelo programa, assim, uma análise pode ser executada usando apenas 10 comandos, que são comuns à execução das mais variadas análises. Ao iniciar o Mplus, podemos visualizar a seguinte janela (figura 4.1.):







Figura 4.1. – Janela Inicial do software Mplus

Posteriormente cria-se um novo documento clicando no ícone . Aparecerá a seguir uma janela de entrada (editor), como observado na figura 4.2, abaixo:



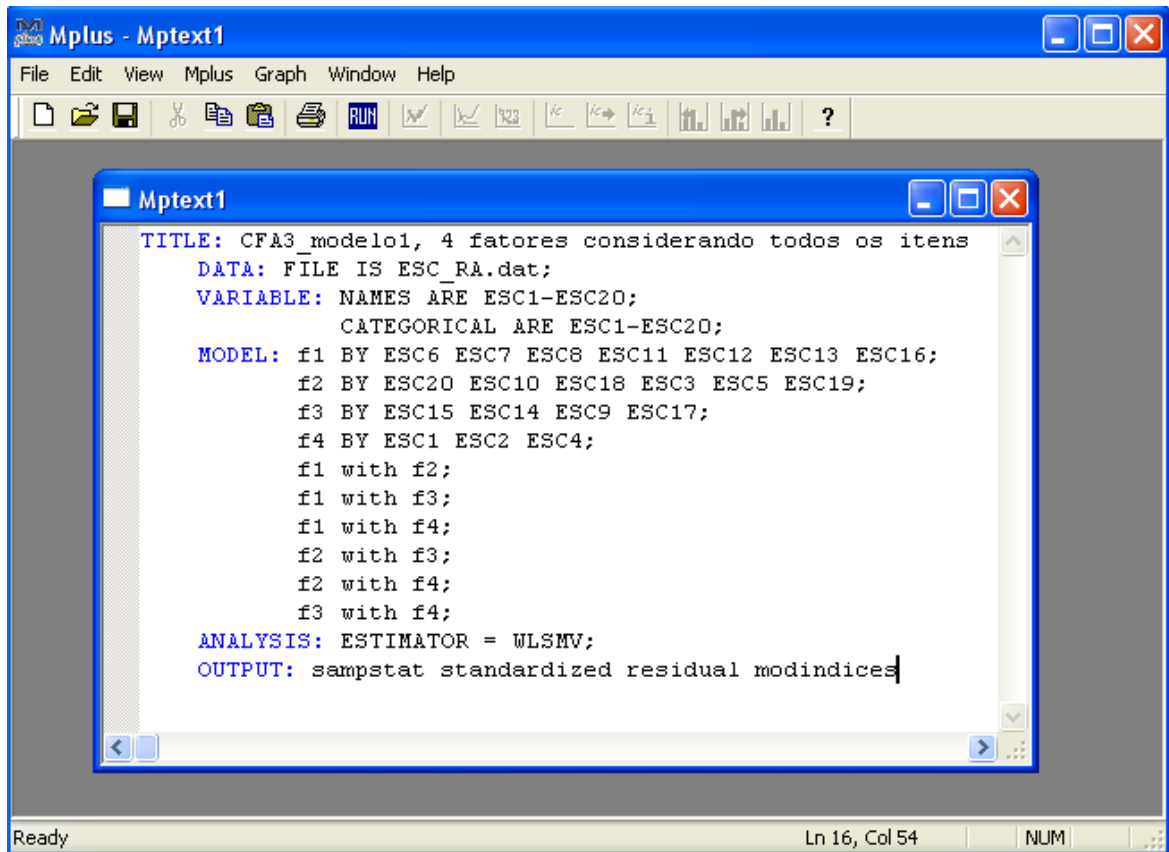


Figura 4.2. – Editor do software Mplus

Nessa janela escreve-se o programa para ler os dados a serem analisados, e especifica-se o modelo de interesse (modelo 1, neste exemplo). Uma vez escrita a sintaxe, deve-se salvar o arquivo com extensão “.inp” para depois fazer a análise clicando no botão .



The screenshot shows the Mplus software interface with a window titled 'Mptext1'. The window contains the following syntax code:

```

TITLE: CFA3_modelo1, 4 fatores considerando todos os itens
DATA: FILE IS ESC_RA.dat;
VARIABLE: NAMES ARE ESC1-ESC20;
              CATEGORICAL ARE ESC1-ESC20;
MODEL: f1 BY ESC6 ESC7 ESC8 ESC11 ESC12 ESC13 ESC16;
          f2 BY ESC20 ESC10 ESC18 ESC3 ESC5 ESC19;
          f3 BY ESC15 ESC14 ESC9 ESC17;
          f4 BY ESC1 ESC2 ESC4;
          f1 with f2;
          f1 with f3;
          f1 with f4;
          f2 with f3;
          f2 with f4;
          f3 with f4;
ANALYSIS: ESTIMATOR = WLSMV;
OUTPUT: sampstat standardized residual modindices
  
```

The status bar at the bottom of the window shows 'Ready', 'Ln 16, Col 54', and 'NUM'.

Figura 4.3. – Sintaxe do modelo 1 no editor do Mplus

Na figura 4.3., apresenta-se a sintaxe do modelo 1 na janela do editor de Mplus. Este software, como mencionado anteriormente, trabalha com 10 comandos básicos, mas possui por sua vez inúmeros sub-comandos (ou palavras chaves) sendo que aqui serão explicados apenas os utilizados para a análise fatorial confirmatória de primeira ordem. Algumas regras básicas do Mplus a serem consideradas ao escrever as sintaxes são as seguintes:

- Todos os comandos (Title, Data, Variable, etc.) devem começar numa nova linha.
- Todos os comandos devem ser seguidos de dois pontos “ : ”, por exemplo, Title : , Data : , Variable : , etc. Uma vez digitado os dois pontos, o comando torna-se azul.
- Ponto e vírgula ao final da linha separa as opções de comandos.

- Os caracteres por linhas não podem ser maiores a 90 dígitos.
- Cada linha pode conter letras maiúsculas, minúsculas e tabulações.
- Somente os nomes de variáveis são sensíveis à maiúsculas ou minúsculas. Isto quer dizer que a variável ESC1 é diferente da variável esc1.

Neste exemplo temos 6 comandos que definem a análise:

**TITLE:** Este comando é opcional, mas é recomendado, pois especifica o conteúdo e características do modelo.

**DATA:** Este comando é obrigatório, e especifica o banco de dados que será trabalhado na análise. O sub-comando FILE IS sempre acompanha o comando data e permite determinar qual o caminho ou a forma do Mplus obter os dados para a análise. Existem duas formas para obter os dados no Mplus. A primeira delas é mostrada na figura 4.3, usando esta opção define-se a seguinte sintaxe:

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

Para usar a opção anterior e conseguir realizar a análise, é preciso abrir o banco de dados no mesmo programa do Mplus. Assim, ficarão abertas duas janelas: a primeira contendo a sintaxe e a segunda contendo os dados (veja a figura abaixo, fig. 4.4). Em seguida, com a janela de sintaxes ativa pode-se fazer a análise clicando o botão RUN.

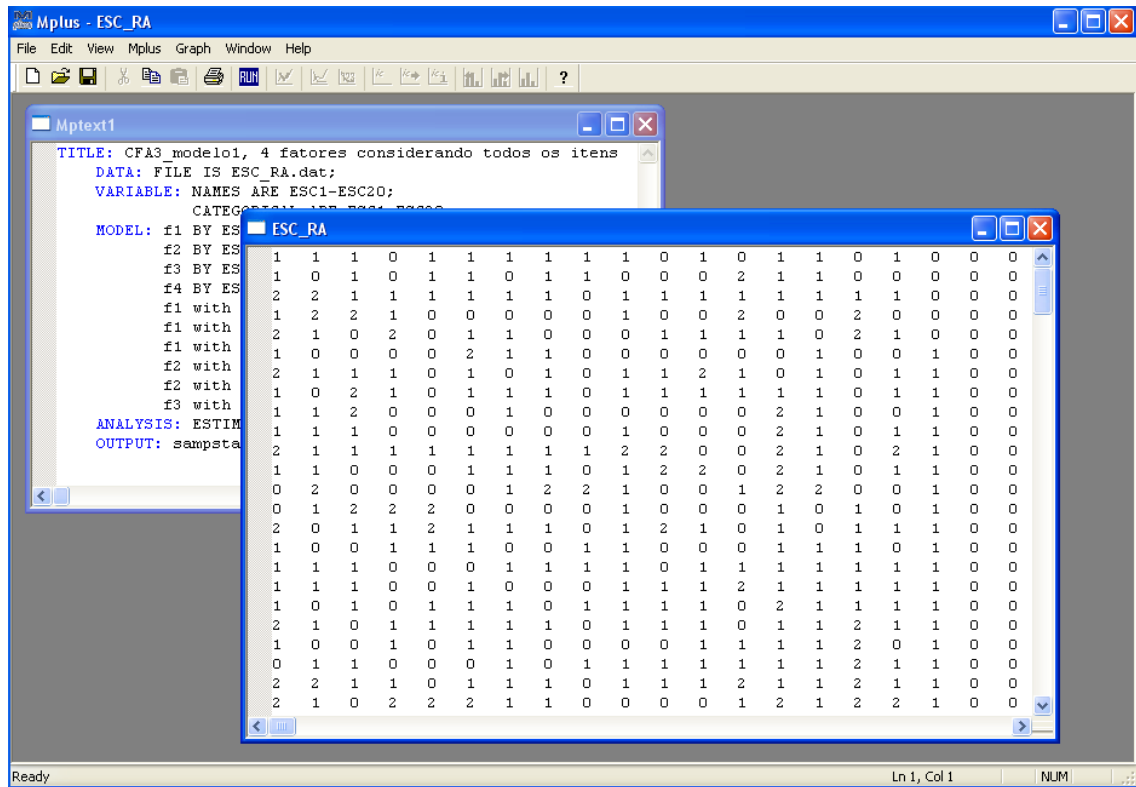


Figura 4.4. – Primeiro método de obtenção de dados pelo Mplus

Um segundo método mais simples é colocar o caminho do arquivo:

```
DATA: FILE IS "c:\mplus_exemplos\ESC_RA.dat";
```

Cabe destacar que a extensão do arquivo utilizado é .dat mas se você estiver usando algum software como SPSS, Stata, SAS ou Excel precisará converter para esta extensão. Neste exemplo, os dados estavam no SPSS e utilizou-se a seguinte sintaxe do SPSS para converter o arquivo (figura, 4.5):

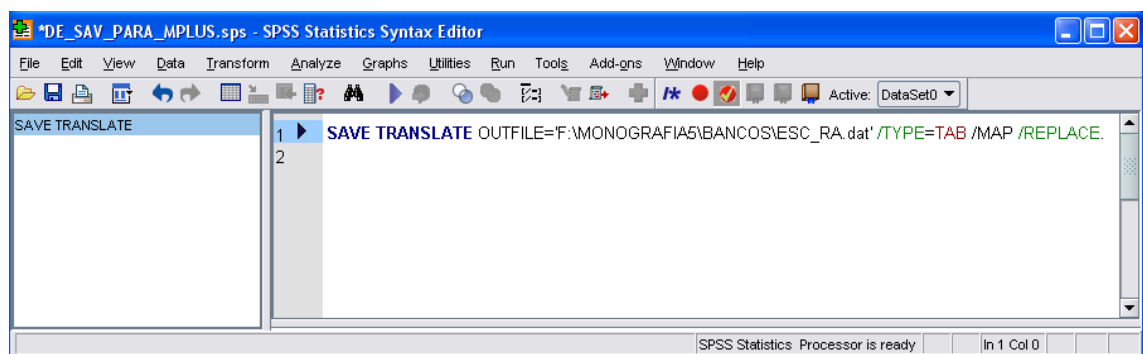


Figura 4.5. – Sintaxe para conversão do banco em SPSS para Mplus

**VARIABLE:** Este comando é obrigatório, e é usado para especificar as variáveis que serão utilizadas. A opção NAMES é usada para assinalar os nomes das variáveis no conjunto de dados. A ordem das variáveis escritas neste comando deve ser a mesma que a ordem do arquivo .dat. Cabe mencionar que o nome de variável não pode conter mais do que 8 caracteres. Neste exemplo as variáveis utilizadas (ESC1, ESC1, ESC3, etc.) podem ser separadas por hífen (NAMES ARE ESC1-ESC20;).

A opção CATEGORICAL é usada para especificar quais variáveis são tratadas como ordinais (ou binárias) no modelo. Neste exemplo, foram definidas todas as variáveis como categóricas (ordinais). O Mplus identifica automaticamente, o número de categorias das variáveis.

**MODEL:** Este comando é usado para descrever as relações estabelecidas no modelo a priori. Este comando é muito importante, pois é aqui que “modelamos” e especificamos os parâmetros do modelo.

Neste exemplo temos que o modelo é definido por:

```
MODEL: f1 BY x6 x7 x8 x11 x12 x13 x16;
f2 BY x20 x10 x18 x3 x5 x19;
f3 BY x15 x14 x9 x17;
f4 BY x1 x2 x4;
f1 with f2;
f1 with f3;
f1 with f4;
f2 with f3;
f2 with f4;
f3 with f4;
```

As três declarações “BY” são usadas para especificar as variáveis latentes, o que significa: o fator f1 é medido por ESC6, ESC7, ESC8, ESC11, ESC12, ESC13 e ESC16, o fator f2 é medido por ESC20, ESC10, ESC18, ESC3, ESC5 e ESC19, o fator f3 é medido por ESC15, ESC14, ESC9 e ESC17 e finalmente que o fator f4 é medido por ESC1, ESC2 e ESC4. A declaração “with” (que pode ser declarada em maiúscula) correlaciona os fatores latentes. Não precisamos estabelecer estas

declarações já que é o default do Mplus, mas foram adicionadas para entender a lógica do AFC.

**ANALYSIS:** Este comando pode ser usado para selecionar o estimador da análise. Neste caso foi definido o estimador próprio para variáveis categóricas WLSMV. Assim, a sintaxe fica:

```
ANALYSIS: ESTIMATOR = WLSMV;
```

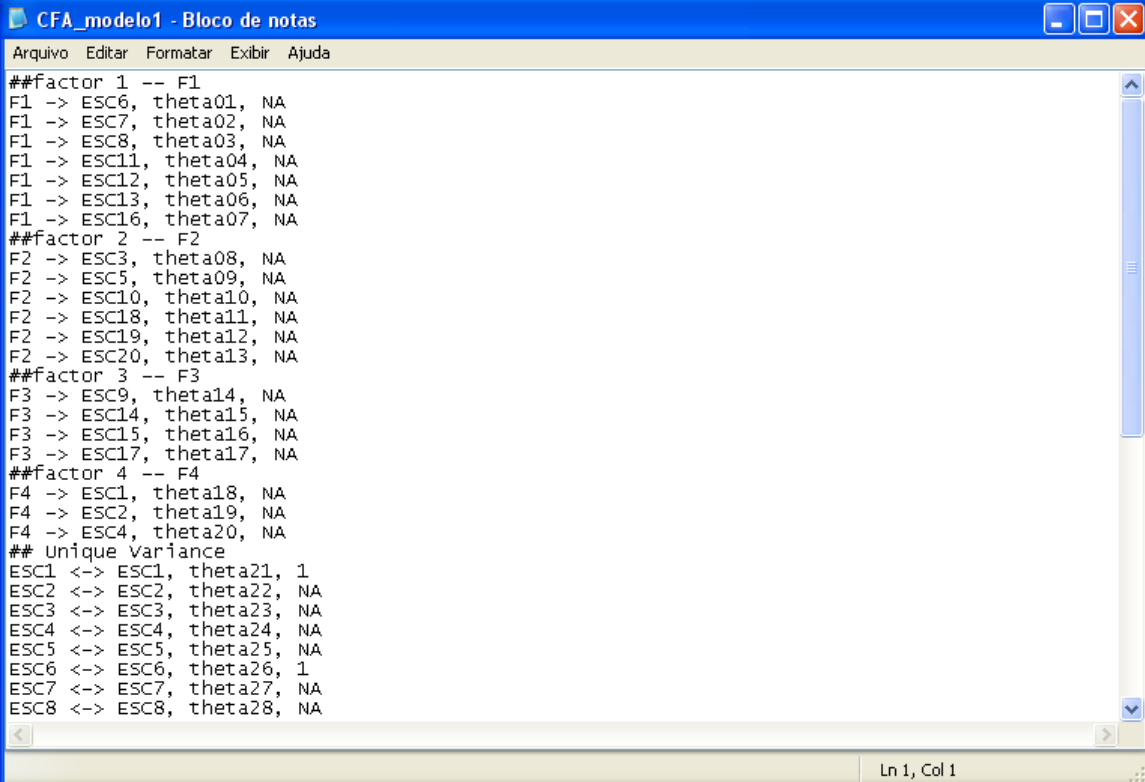
**OUTPUT:** Esta sintaxe permite escolher diversas opções de resultados. Neste exemplo temos escolhido as opções: sampstat (fornece as estatísticas amostrais e a matriz de correlação policórica, estimativas não padronizadas para os parâmetros e os índices de ajuste), standardized (fornece os parâmetros e seus erros padrões padronizados), residual (fornece a matriz de correlação estimada e a matriz de correlação residual) e modindices (fornece os índices de modificação para a re-especificação do modelo.

O manual do Mplus na versão 6 é uma ótima referência para este tipo de análise, mas outros documentos (veja seção das referências) são também interessantes como o tutorial de Acock (2009).

## 4.2 TUTORIAL DA ANÁLISE FATORIAL CONFIRMATÓRIA NO PACOTE SEM DO SOFTWARE R

A fim de realizar a análise no software R, utilizou-se o editor Tinn-R versão 2.3.5.2 como complemento ao R para escrever a sintaxe do programa.

O primeiro passo, para realizar a análise, é criar um arquivo texto que contenha todas as relações e especificações do modelo. Assim, foi criado o arquivo AFC\_modelo1.txt (figura 4.6).



```

CFA_modelo1 - Bloco de notas
Arquivo Editar Formatar Exibir Ajuda
##factor 1 -- F1
F1 -> ESC6, theta01, NA
F1 -> ESC7, theta02, NA
F1 -> ESC8, theta03, NA
F1 -> ESC11, theta04, NA
F1 -> ESC12, theta05, NA
F1 -> ESC13, theta06, NA
F1 -> ESC16, theta07, NA
##factor 2 -- F2
F2 -> ESC3, theta08, NA
F2 -> ESC5, theta09, NA
F2 -> ESC10, theta10, NA
F2 -> ESC18, theta11, NA
F2 -> ESC19, theta12, NA
F2 -> ESC20, theta13, NA
##factor 3 -- F3
F3 -> ESC9, theta14, NA
F3 -> ESC14, theta15, NA
F3 -> ESC15, theta16, NA
F3 -> ESC17, theta17, NA
##factor 4 -- F4
F4 -> ESC1, theta18, NA
F4 -> ESC2, theta19, NA
F4 -> ESC4, theta20, NA
## Unique Variance
ESC1 <-> ESC1, theta21, 1
ESC2 <-> ESC2, theta22, NA
ESC3 <-> ESC3, theta23, NA
ESC4 <-> ESC4, theta24, NA
ESC5 <-> ESC5, theta25, NA
ESC6 <-> ESC6, theta26, 1
ESC7 <-> ESC7, theta27, NA
ESC8 <-> ESC8, theta28, NA
Ln 1, Col 1

```

Figura 4.6. – Especificação do modelo 1

O conteúdo completo da figura 4.6. será descrito a seguir para melhor entendimento da sintaxe.

```

##factor 1 -- F1
F1 -> ESC6, theta01, NA
F1 -> ESC7, theta02, NA
F1 -> ESC8, theta03, NA
F1 -> ESC11, theta04, NA
F1 -> ESC12, theta05, NA
F1 -> ESC13, theta06, NA
F1 -> ESC16, theta07, NA
##factor 2 -- F2
F2 -> ESC3, theta08, NA
F2 -> ESC5, theta09, NA
F2 -> ESC10, theta10, NA
F2 -> ESC18, theta11, NA
F2 -> ESC19, theta12, NA
F2 -> ESC20, theta13, NA
##factor 3 -- F3
F3 -> ESC9, theta14, NA
F3 -> ESC14, theta15, NA
F3 -> ESC15, theta16, NA

```

```

F3 -> ESC17, theta17, NA
##factor 4 -- F4
F4 -> ESC1, theta18, NA
F4 -> ESC2, theta19, NA
F4 -> ESC4, theta20, NA
## Unique Variance
ESC1 <-> ESC1, theta21, 1
ESC2 <-> ESC2, theta22, NA
ESC3 <-> ESC3, theta23, NA
ESC4 <-> ESC4, theta24, NA
ESC5 <-> ESC5, theta25, NA
ESC6 <-> ESC6, theta26, 1
ESC7 <-> ESC7, theta27, NA
ESC8 <-> ESC8, theta28, NA
ESC9 <-> ESC9, theta29, NA
ESC10 <-> ESC10, theta30, NA
ESC11 <-> ESC11, theta31, NA
ESC12 <-> ESC12, theta32, NA
ESC13 <-> ESC13, theta33, NA
ESC14 <-> ESC14, theta34, NA
ESC15 <-> ESC15, theta35, 1
ESC16 <-> ESC16, theta36, NA
ESC17 <-> ESC17, theta37, NA
ESC18 <-> ESC18, theta38, NA
ESC19 <-> ESC19, theta39, NA
ESC20 <-> ESC20, theta40, 1
## Factor Variances fixed at 1
F1 <-> F1, NA, 1
F2 <-> F2, NA, 1
F3 <-> F3, NA, 1
F4 <-> F4, NA, 1
##Factor Correlations
F1 <-> F2, theta41, NA
F1 <-> F3, theta42, NA
F1 <-> F4, theta43, NA
F2 <-> F3, theta44, NA
F2 <-> F4, theta45, NA
F3 <-> F4, theta46, NA



```

Sob cada etiqueta `##factor 1--F1`, `##factor 2--F2`, `##factor 3--F3` e `##factor 4--F4` estão definidas as variáveis indicadoras (observadas) que fazem parte do fator latente. Mencionamos que essas etiquetas são antecidas pelo símbolo #, pois são títulos que o R não lê (somente usado para a identificação). É definido, por exemplo, o



parâmetro  $\theta_{01}$  para a variável ESC6, pois esse será o parâmetro livremente estimado. Livremente, pois é acompanhado da sigla NA.

Sob a etiqueta `## Unique Variance` são definidos os erros de medida para cada variável indicadora ( $\delta$ ). Esses erros são definidos pelo parâmetro  $\theta$ , e a sigla NA significa que serão livremente estimados. Sob a etiqueta `## Factor Variances fixed at 1` estão definidas a variância do fator latente definidas com valor 1 (que é o segundo método alternativo ao método de “marker indicator”). Finalmente, a etiqueta `##Factor Correlations` contém as correlações fatoriais que serão livremente estimadas ( $\theta_{NA}$ ) pelo parâmetro  $\theta$ .

Depois de gravado o arquivo texto, abre-se o programa Tinn\_R (conforme figura 4.7.), e cria-se um novo documento clicando no ícone  e também o ícone  que se encontra no canto superior direito do menu. Clicando este último ícone permitirá a abertura do programa R. Assim, o leitor trabalhará com duas janelas: uma do editor Tinn-R para a escrita da sintaxe e a outra, do R, para a visualização dos resultados.

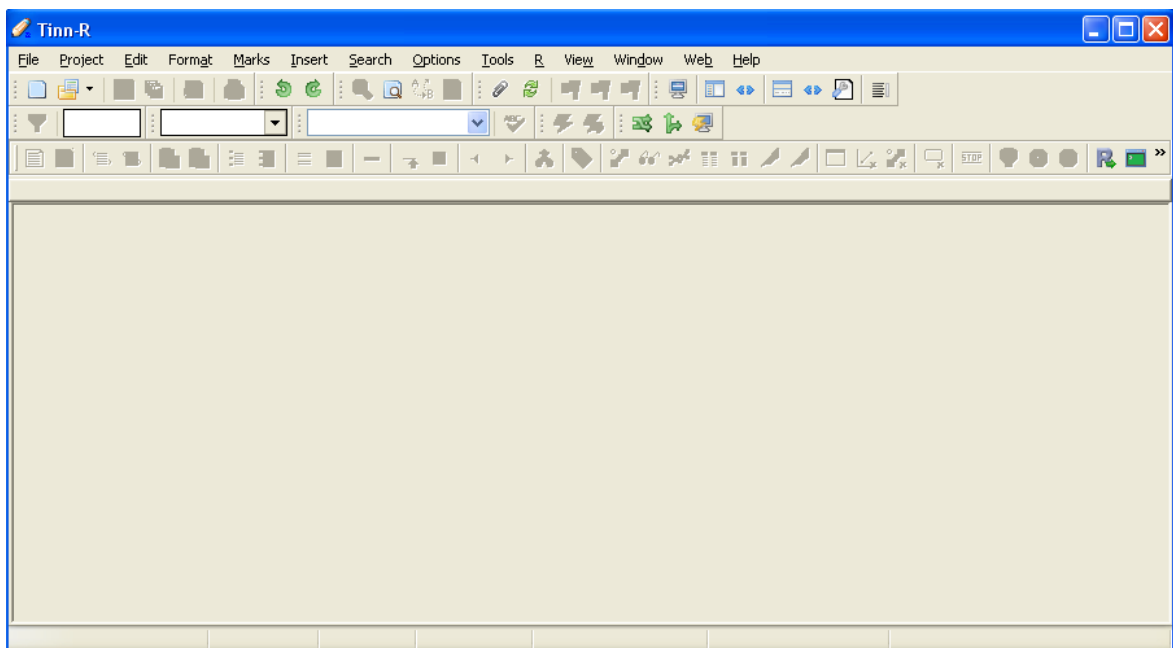
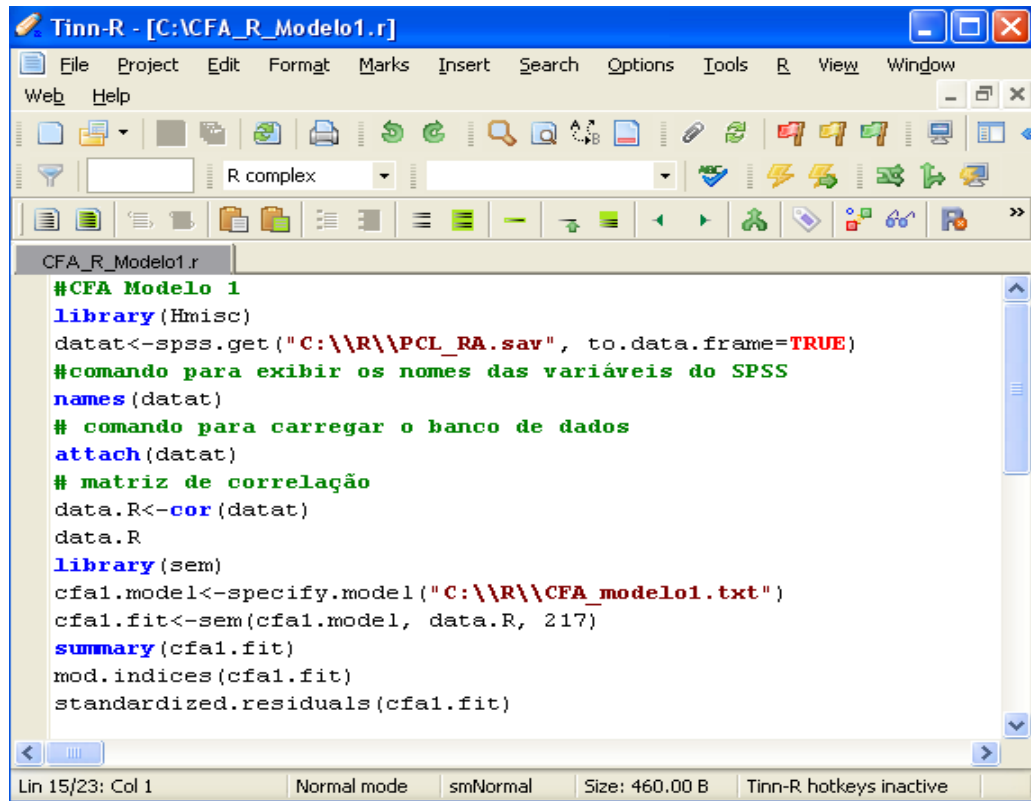


Figura 4.7. – Especificação do modelo 1

Na janela do Tinn-R será escrita a seguinte sintaxe que será utilizada para a análise fatorial confirmatória do modelo 1 (figura 4.8.).



```

Tinn-R - [C:\CFA_R_Modelo1.r]
File Project Edit Format Marks Insert Search Options Tools R View Window
Web Help
R complex
CFA_R_Modelo1.r
#CFA Modelo 1
library(Hmisc)
datat<-spss.get("C:\\R\\PCL_RA.sav", to.data.frame=TRUE)
#comando para exibir os nomes das variáveis do SPSS
names(datat)
# comando para carregar o banco de dados
attach(datat)
# matriz de correlação
data.R<-cor(datat)
data.R
library(sem)
cfa1.model<-specify.model("C:\\R\\CFA_modelo1.txt")
cfa1.fit<-sem(cfa1.model, data.R, 217)
summary(cfa1.fit)
mod.indices(cfa1.fit)
standardized.residuals(cfa1.fit)
Lin 15/23: Col 1 Normal mode smNormal Size: 460.00 B Tinn-R hotkeys inactive

```

Figura 4.8. – Sintaxe do modelo 1 no software R, editor Tinn-R.

Antes de explicar a sintaxe é importante mencionar que os títulos e linhas comentadas são precedidos pelo símbolo #. Assim, no Tinn-R, esses comentários ficam identificados pela cor verde.

O primeiro passo nesta análise é carregar o pacote `library(Hmisc)`. Este pacote permite ler o arquivo do SPSS e transformá-lo dentro de um data frame que é uma estrutura de dados do R, através da função `spss.get` e armazená-lo na variável `datat`. Como apresentado na figura 4.8, o comando `names(datat)` permite exibir os nomes das variáveis do banco de dados e é interessante visualizá-las como uma forma de conferencia das variáveis que se quer trabalhar. O seguinte comando `attach(datat)` permite obter o banco de dados.

A matriz de entrada de dados para realizar a análise será a matriz de correlação de Pearson e será armazenada na variável `data.R`. É importante mencionar que o *default* da função `cor` é a matriz de Pearson. A seguir, o pacote SEM deve ser carregado, o que é realizada pelo comando `library(sem)`. Assim, o arquivo de texto `AFC_modelo1.txt` poderá ser lido pelo R através da função:

```
cfa1.model<-specify.model("C:\\R\\CFA_modelo1.txt")
```

O próximo comando permitirá ajustar o modelo e salvar os resultados:

```
cfa1.fit<-sem(cfa1.model, data.R, 217)
```

Podemos ver que `cfa1.modelo` é a variável que contém a especificação do modelo hipotetizado, o comando `data.R` é a matriz de correlação de entrada e 217 é o número de casos do banco de dados. O comando `summary(cfa1.fit)` solicita os índices de ajustes e os parâmetros estimados pelo modelo. Já o comando `mod.indices(cfa1.fit)` proporciona os 5 índices de modificação mais importantes para uma possível re-especificação do modelo e a sintaxe `standardized.residuals(cfa1.fit)` permite obter os resíduos padronizados do modelo.





## **5 COMPARAÇÃO DAS ANÁLISES E RESULTADOS ENTRE R E MPLUS FATORES**

Antes de comparar os resultados dos softwares R e Mplus é importante situar alguns aspectos sobre as análises realizadas. De um modo geral, o software R (pacote SEM) usa a matriz de correlação de Pearson como entrada de dados que é própria para tratar variáveis contínuas e também o método de estimação de máxima verossimilhança para este mesmo tipo de variáveis. O software Mplus utiliza uma matriz de correlação policórica e um método de estimação de mínimos quadrados ponderados robustos ajustados (WLSMV) para o tratamento de variáveis categóricas (politômicas). Embora neste trabalho tenha-se utilizado variáveis politômicas, estes dois métodos foram empregados para assim, além de obter a validação dos construtos teóricos por meio do Mplus, apresentar e estudar indícios de similaridades, diferenças e limitações de cada software.





Com respeito aos índices de ajuste os resultados do R e Mplus conseguem performance similar, especialmente no índice de parcimônia (RMSEA). Cabe destacar que para os índices de RMSEA e SRMR quanto menor o índice melhor o ajuste do modelo, assim temos que o Mplus consegue obter estimativas inferiores que as obtidas pelo software R. Ao contrário, nos índices de CFI e TLI um ajuste melhor do modelo é dado por índices maiores, próximos a 1. Assim, o Mplus consegue identificar valores maiores em comparação do software R.

Na validação de construtos em um instrumento de medida é indispensável pesquisar o grau de correlação das cargas fatoriais com seus respectivos fatores latentes a fim de determinar a relevância de cada uma delas no construto e especialmente averiguar a ordenação na importância das variáveis na construção dos fatores. A seguir, são apresentados graficamente os resultados dos perfis das cargas fatoriais pelos dois softwares, para cada modelo e para cada fator latente (F1, F2, F3 e F4).

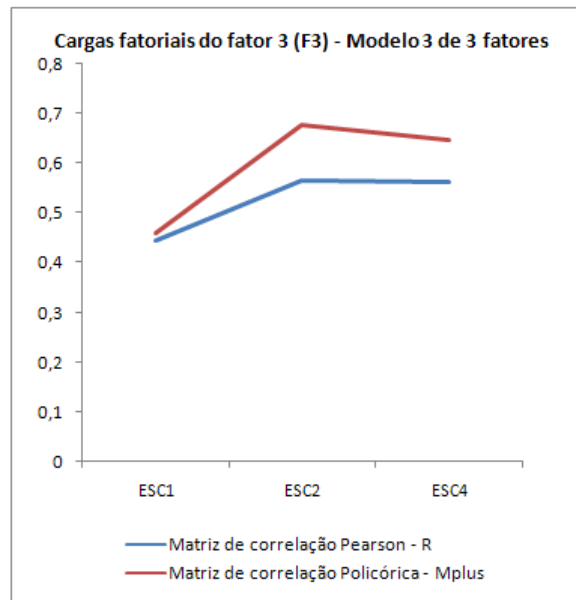


## Modelo 1 – 4 fatores







## Modelo 2 – 4 fatores



### Modelo 3 – 3 fatores






## Modelo 4 – 4 fatores






## Modelo 5 – 3 fatores



### **Modelo 6 – 4 fatores**



Verificando os gráficos anteriores, podemos concluir que para cada fator do modelo estudado, existe similaridade nos resultados das matrizes fatoriais dando a mesma ordenação na importância das variáveis na construção dos fatores. Porém, por causa do método de estimação, as cargas fatoriais estimadas são um pouco maiores pelo o Mplus. Esse comportamento deve-se ao fato de que os valores da correlação policórica são maiores do que os da correlação de Pearson. O cálculo da correlação policórica é baseada na premissa que valores discretos observados são devidos a uma distribuição contínua subjacente não observada. Criticamente importante no cálculo dessa correlação é o pressuposto de normalidade bivariada (para duas variáveis aleatórias normais, correlacionadas) entre o par de variáveis da resposta latente.

Os fatos considerados acima são conhecidos na literatura e são mencionados como conseqüências potenciais de tratar variáveis categóricas como contínuas (ver Brown 2006, p. 387). Porém, as diferenças nas estimativas neste exemplo (embora estejam presentes por causa do método de estimação utilizado) não são tão divergentes e conservam a ordenação de importância das variáveis dentro dos construtos para modelos de AFC de primeira ordem. Isto é interessante para o

pesquisador, pois poderia apresentar indícios de quais as variáveis indicadoras tem o maior peso dentro do construto e obter resultados confirmatórios para os parâmetros estimados.

Através de simulação, Flora e Curran (2004) confirmaram que os resultados mostrados pelo estimador de mínimos quadrados ponderados robustos (WLSMV) produziram acurados testes estatísticos, estimativas de parâmetros e erros padrões para modelos de AFC sob uma variedade de condições, como por exemplo, tamanhos amostrais que variavam desde 100 a 1000 casos, vários graus de não normalidade e complexidade do modelo. Assim, o estimador WLSMS é robusto para desvios não tão grandes de normalidade nos dados.

Com respeito às correlações fatoriais temos que as estimativas para as relações entre os fatores latentes foram semelhantes no Mplus e no R para os três primeiros modelos. As correlações fatoriais não apresentam um comportamento concordante em ambos os softwares nos três últimos modelos (4, 5 e 6). O resultado anterior coincide com que estes modelos não apresentam índices dentro das amplitudes aceitáveis de ajuste.

Comparações desta natureza existem como parte de estudos de AFC e também foram observadas por Fachel (1986) num trabalho sobre Análise Fatorial para Dados Categóricos supondo uma distribuição subjacente contínua.

## 6 CONCLUSÕES

Este trabalho aplicou a análise fatorial confirmatória nos softwares R e Mplus que utilizam metodologias diferentes no que diz respeito à entrada de dados e o método de estimação. O modelo final foi escolhido por meio da técnica de análise fatorial confirmatória dentre de um conjunto de seis modelos hipotetizados pelo pesquisador ou baseados na literatura relativa à Escala sendo validada.

Com relação aos resultados encontrados pela técnica, tanto pelo software R quanto pelo Mplus pode-se afirmar que a amostra brasileira ajustou-se melhor a um modelo proposto pelo pesquisador que aos modelos teóricos existentes, porém a diferença está em duas das 13 variáveis indicadoras existentes nestes modelos uma vez que duas das variáveis foram contempladas dentro de fatores latentes diferentes. Ambos os softwares, apesar de não contar com uma ferramenta de visualização própria para esse tipo de técnica (os chamados diagramas de caminhos), são fontes conhecidas e aprovadas, dada a grande quantidade de artigos e textos que os utilizam.

Na comparação da *performance* entre os dois softwares para os 6 modelos considerados podemos apontar três aspectos interessantes:

No contexto de lidar com variáveis categóricas, o Mplus é o software mais adequado, no entanto, verificou-se que no R (apesar de subestimar as cargas fatoriais) a ordenação de importância das variáveis indicadoras dentro de cada fator latente são similares.

Os índices de ajuste pelos dois softwares foram similares nos seis modelos estudados. Os resultados mostraram que a escolha do modelo tanto utilizando os índices de um software como de outro teria resultado num modelo final idêntico.

Aparentemente as correlações fatoriais, comparadas no capítulo 5, são bem discriminadas por ambos os softwares uma vez que os 3 primeiros modelos apresentam índices de ajustes dentro dos intervalos de pontos de corte aceitáveis,

ou seja, são modelos bem especificados. Contrariamente, as correlações fatoriais não apresentam um comportamento concordante em ambos os softwares nos três últimos modelos (4, 5 e 6). O resultado anterior coincide com que estes modelos não apresentam índices dentro dos intervalos aceitáveis de ajuste.

É lógico que os resultados das comparações anteriores são indícios e não certezas, ainda porque a aplicação desta metodologia foi realizada somente para um modelo fatorial confirmatório de primeira ordem sendo que a abrangência da AFC é realizada para estruturas de ordem maior e para situações de AFC com co variáveis (modelos MIMIC), por exemplo. Conforme os resultados encontrados, sugere-se realizar uma análise fatorial confirmatória usando o software livre R para todos os itens e com a entrada dos dados através da matriz de correlação nos casos em que todos os itens são avaliados com a mesma escala.

O presente trabalho também possibilitou uma série contribuições, tais como: a validação da escala de um instrumento de medida, o desenvolvimento de dois tutoriais específicos para a análise fatorial confirmatória e a possibilidade de um trabalho em conjunto com um pesquisador de uma área não relacionada à estatística o que foi uma experiência enriquecedora para mim como formanda em estatística.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Acock A. C., Mplus for Windows: An Introduction and Overview. Disponível em:  
<http://www.caldar.org/presentations/summer%20institute/2008/Day2%20Aug%2014-2008/Track%201/Mplus%20for%20Windows.pdf>. Data de acesso em: 26 de abril de 2011.
- Albright J. J. and Park M. H., Confirmatory Factor Analysis using Amos, LISREL, Mplus, SAS/STAT CALLIS, 2009. Disponível em  
<http://www.indiana.edu/~statmath/stat/all/cfa/cfa.pdf> . Data de acesso em: 4 de maio de 2011.
- Bentler P. M., EQS 6 Structural Equations Program Manual. Encino, California: Multivariate Software, Inc. 1995.
- BATISTA-FOGUET, J. M., COENDERS, G., ALONSO J., Análisis Fatorial Confirmatória. Su utilidad em la validación de Cuestionarios relacionados a la salud. *MedClin(Barc)*, v. 122, p. 21-27, 2004.
- Brown, Anne; Croudace Tim. Introduction to Mplus: Latent variables, traits and Classes. Disponível em:  
<http://www.psychometrics.ppsis.cam.ac.uk/uploads/documents/Introduction%20to%20Mplus%20Day1%20FINAL.pdf>. Acessado em: 24 de maio de 2011.
- BROWN, T. A.; Confirmatory Factor Analysis for Applied Research, 1st Edition, New York: The Guilford Press, 2006.
- DeCoster J., 1998. Overview of Factor Analysis - University of Alabama Disponível em: [www.stat-help.com/notes.html](http://www.stat-help.com/notes.html). Data de acesso em: citado em 13 de abril de 2011.
- Fachel, J.M.G. (1986) – The C-Type Distribution as an underlying model for categorical data and its use in factor analysis. PhD Thesis. University of London.

FLORA D. B., CURRAN, P. J. An Empirical Evaluation of Alternative Methods of Estimation for Confirmatory Factor Analysis with Ordinal Data. *Psychological Methods*, v. 9, p. 654-657, 2004.

HAIR, J. F.; ANDERSON, R. E.; TATHAM, R.L.; & BLACK, W. C.; *Multivariate Data Analysis*. 5 ed., New Jersey: Prentice-Hall, 1998.

HARRINGTON, D.; *Confirmatory Factor Analysis*, 1<sup>st</sup> Edition, New York: Oxford University Press, 2009.

HEVEY, D. et al. Consideration of future consequences scale: Confirmatory Factor Analysis. *Personality and Individual Differences*; v. 48, p. 654-657, 2009.

Hu, L., & Bentler, P. M. Cutoff criterion for fit indexes in covariance structure analysis: conventional criteria versus new alternatives. *Structural Equation Modeling*, v.6, p.1-55, 1999.

KLINE, R. B.; *Principles and Practice of Structural Equation Modeling*, 3<sup>rd</sup> Edition, New York: The Guilford Press, 2006.

Lemke, C., 2005. Modelos de Equações Estruturais com ênfase em Análise Fatorial Confirmatória no Software AMOS. Monografia, Departamento em Estatística – UFRGS.

MUTHÉN, L.K. and MUTHÉN B. O., 2004. Mplus: The Comprehensive Modeling Program for Applied Research, 3<sup>rd</sup> Edition, Los Angeles: Muthén&Muthén

Muthén B. O., du Toit S. H. C., and Spisic D.(1997). Robust inference using weighted least squares and quadratic estimating equations in latent variable modeling with categorical and continuous outcomes. Manuscrito não publicado, University of California, Los Angeles.

RAYKOV, T. Estimation of composite reliability for congeneric measures. *Applies Psychological Measurement*, v. 21 p. 173-184, 1997.

Steiger James H., Confirmatory Factor Analysis with R. Disponível em: <http://www.statpower.net/Content/312/Handout/Confirmatory%20Factor%20Analysis%20with%20R.pdf>. Data de acesso: 6 de abril de 2011.

Steiger, H. H., & Lind, J. M. Statistically based tests for the number of common factors. In: Annual meeting of the Psychometric society, 1980, Iowa City.

Tanaka, J.S. (1993). Multifaceted conceptions of fit in structural equation models. In K.A. Bollen, & J.S. Long (eds.), *Testing structural equation models*. Newbury Park, California, Sage Publications, 1993, p.10.

UNIVERSITY OF CAMBRIDGE. Jumpstart Mplus: Exploratory and Confirmatory Factor Analysis. Disponível em: [http://www.psychometrics.ppsis.cam.ac.uk/uploads/documents/JumpStartFeb10/efac\\_fajumpstart.pdf](http://www.psychometrics.ppsis.cam.ac.uk/uploads/documents/JumpStartFeb10/efac_fajumpstart.pdf). Data de acesso em: 24 de maio de 2011.

ULLMAN, Jodie B. Structural Equation Modeling: Reviewing the Basics and Moving Forward. *Journal of Personality Assessment*, v. 87, n. 1, p. 35-50, 2006.

YU, C.Y., Evaluating cutoff criteria of model fit indices for latent variable models with binary and continuous outcomes, 2002. 183 F. Tese (Doutorado em Educação) – University of California, California. 2002.



## ANEXOS

Sintaxe de programação dos diagramas de caminhos para as Modelos utilizando a sintaxe do programa Grapviz – Graph Visualization Software

Modelo 1 - Path Diagram do modelo Baseado na AFE usando Principal Factor Axis e rotação Promax na escala que dos 20 itens, todos os itens considerados.

```

digraph "CFA3G_A4FF BANCO RA" {
rankdir=LR;
ranksep="2.0 equally"
size="20,20";
node [fontname="times" fontsize=14 shape=box];
edge [fontname="times" fontsize=13];
center=10;
"F1" [shape=ellipse]
"F2" [shape=ellipse]
"F3" [shape=ellipse]
"F4" [shape=ellipse]
"F1" -> "ESC6" [label="#955;61"];
"F1" -> "ESC7" [label="#955;71"];
"F1" -> "ESC8" [label="#955;81"];
"F1" -> "ESC11" [label="#955;111"];
"F1" -> "ESC12" [label="#955;121"];
"F1" -> "ESC13" [label="#955;131"];
"F1" -> "ESC16" [label="#955;161"];
"F2" -> "ESC3" [label="#955;32"];
"F2" -> "ESC5" [label="#955;52"];
"F2" -> "ESC10" [label="#955;102"];
"F2" -> "ESC18" [label="#955;182"];
"F2" -> "ESC19" [label="#955;192"];
"F2" -> "ESC20" [label="#955;202"];
"F3" -> "ESC1" [label="#955;13"];
"F3" -> "ESC2" [label="#955;23"];
"F3" -> "ESC4" [label="#955;43"];
"F4" -> "ESC9" [label="#955;94"];
"F4" -> "ESC14" [label="#955;144"];
"F4" -> "ESC15" [label="#955;154"];
"F4" -> "ESC17" [label="#955;174"];
"F1"->"F2"[label="#966;21",dir=both];
"F2"->"F3"[label="#966;32",dir=both];
"F3"->"F4"[label="#966;43",dir=both];
"F1"->"F4"[label="#966;41",dir=both];
"F1"->"F3"[label="#966;31",dir=both];

```

```
"F2"->"F4"[label="#966;42",dir=both];
{rank = same; F1;F2;F3;F4; }
ESC6 -> d1 [dir=back];
d1 [shape=circle,label="#948;1"];
ESC7 -> d2 [dir=back];
d2 [shape=circle,label="#948;2"];
ESC8 -> d3 [dir=back];
d3 [shape=circle,label="#948;3"];
ESC11 -> d4 [dir=back];
d4 [shape=circle,label="#948;4"];
ESC12 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC13 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC16 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];
ESC3 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
ESC5 -> d9 [dir=back];
d9 [shape=circle,label="#948;9"];
ESC10 -> d10 [dir=back];
d10 [shape=circle,label="#948;10"];
ESC18 -> d11 [dir=back];
d11 [shape=circle,label="#948;11"];
ESC19 -> d12 [dir=back];
d12 [shape=circle,label="#948;12"];
ESC20 -> d13 [dir=back];
d13 [shape=circle,label="#948;13"];
ESC1 -> d14 [dir=back];
d14 [shape=circle,label="#948;14"];
ESC2 -> d15 [dir=back];
d15 [shape=circle,label="#948;15"];
ESC4 -> d16 [dir=back];
d16 [shape=circle,label="#948;16"];
ESC9 -> d17 [dir=back];
d17 [shape=circle,label="#948;17"];
ESC14 -> d18 [dir=back];
d18 [shape=circle,label="#948;18"];
ESC15 -> d19 [dir=back];
d19 [shape=circle,label="#948;19"];
ESC17 -> d20 [dir=back];
d20 [shape=circle,label="#948;20"];
}
```

Modelo 2 - Path Diagram do modelo Baseado na AFE usando Principal Factor Axis e rotação Promax na escala que dos 20 itens considera somente 18 (sem itens 11 e 17).

```

digraph "CFA3G_B4FF BANCO RB" {
  rankdir=LR;
  ranksep="2.0 equally"
  size="20,20";
  node [fontname="times" fontsize=14 shape=box];
  edge [fontname="times" fontsize=13];
  center=10;
  "F1" [shape=ellipse]
  "F2" [shape=ellipse]
  "F3" [shape=ellipse]
  "F4" [shape=ellipse]
  "F1" -> "ESC5" [label="#955;51"];
  "F1" -> "ESC6" [label="#955;61=1"];
  "F1" -> "ESC7" [label="#955;71"];
  "F1" -> "ESC8" [label="#955;81"];
  "F1" -> "ESC12" [label="#955;121"];
  "F1" -> "ESC13" [label="#955;131"];
  "F1" -> "ESC16" [label="#955;161"];
  "F2" -> "ESC3" [label="#955;32"];
  "F2" -> "ESC10" [label="#955;102"];
  "F2" -> "ESC18" [label="#955;182"];
  "F2" -> "ESC19" [label="#955;192"];
  "F2" -> "ESC20" [label="#955;202=1"];
  "F3" -> "ESC1" [label="#955;13=1"];
  "F3" -> "ESC2" [label="#955;23"];
  "F3" -> "ESC4" [label="#955;43"];
  "F4" -> "ESC9" [label="#955;94"];
  "F4" -> "ESC14" [label="#955;144"];
  "F4" -> "ESC15" [label="#955;154=1"];
  "F1"->"F2"[label="#966;21",dir=both];
  "F2"->"F3"[label="#966;32",dir=both];
  "F3"->"F4"[label="#966;43",dir=both];
  "F1"->"F4"[label="#966;41",dir=both];
  "F1"->"F3"[label="#966;31",dir=both];
  "F2"->"F4"[label="#966;42",dir=both];
  {rank = same; F1;F2;F3;F4; }
  ESC5 -> d1 [dir=back];
  d1 [shape=circle,label="#948;1"];
  ESC6 -> d2 [dir=back];
  d2 [shape=circle,label="#948;2"];
  ESC7 -> d3 [dir=back];
  d3 [shape=circle,label="#948;3"];
  ESC8 -> d4 [dir=back];

```

```

d4 [shape=circle,label="#948;4"];
ESC12 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC13 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC16 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];
ESC3 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
ESC10 -> d9 [dir=back];
d9 [shape=circle,label="#948;9"];
ESC18 -> d10 [dir=back];
d10 [shape=circle,label="#948;10"];
ESC19 -> d11 [dir=back];
d11 [shape=circle,label="#948;11"];
ESC20 -> d12 [dir=back];
d12 [shape=circle,label="#948;12"];
ESC1 -> d13 [dir=back];
d13 [shape=circle,label="#948;13"];
ESC2 -> d14 [dir=back];
d14 [shape=circle,label="#948;14"];
ESC4 -> d15 [dir=back];
d15 [shape=circle,label="#948;15"];
ESC9 -> d16 [dir=back];
d16 [shape=circle,label="#948;16"];
ESC14 -> d17 [dir=back];
d17 [shape=circle,label="#948;17"];
ESC15 -> d18 [dir=back];
d18 [shape=circle,label="#948;18"];
}

```

**Modelo 3 - Path Diagram do modelo baseado na AFE usando Principal Factor Axis e rotação Promax na escala que dos 20 itens considera somente 13 (sem itens 10, 12, 11, 17, 18, 19 e 20).**

```

digraph "CFA_3G_C" {
rankdir=LR;
ranksep="2.0 equally"
size="20,20";
node [fontname="times" fontsize=14 shape=box];
edge [fontname="times" fontsize=13];
center=10;
"F1" [shape=ellipse]
"F2" [shape=ellipse]
"F3" [shape=ellipse]
"F1" -> "ESC5" [label="#955;51"];
"F1" -> "ESC6" [label="#955;61=1"];
"F1" -> "ESC7" [label="#955;71"];

```

```

"F1" -> "ESC8" [label="#955;81"];
"F1" -> "ESC13" [label="#955;131"];
"F1" -> "ESC16" [label="#955;161"];
"F2" -> "ESC1" [label="#955;12=1"];
"F2" -> "ESC2" [label="#955;22"];
"F2" -> "ESC4" [label="#955;42"];
"F3" -> "ESC3" [label="#955;33"];
"F3" -> "ESC9" [label="#955;93"];
"F3" -> "ESC14" [label="#955;143"];
"F3" -> "ESC15" [label="#955;153=1"];
"F1"->"F2"[label="#966;21",dir=both];
"F2"->"F3"[label="#966;32",dir=both];
"F1"->"F3"[label="#966;31",dir=both];
{rank = same; F1;F2;F3; }
ESC5 -> d1 [dir=back];
d1 [shape=circle,label="#948;1"];
ESC6 -> d2 [dir=back];
d2 [shape=circle,label="#948;2"];
ESC7 -> d3 [dir=back];
d3 [shape=circle,label="#948;3"];
ESC8 -> d4 [dir=back];
d4 [shape=circle,label="#948;4"];
ESC13 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC16 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC1 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];
ESC2 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
ESC4 -> d9 [dir=back];
d9 [shape=circle,label="#948;9"];
ESC3 -> d10 [dir=back];
d10 [shape=circle,label="#948;10"];
ESC9 -> d11 [dir=back];
d11 [shape=circle,label="#948;11"];
ESC14 -> d12 [dir=back];
d12 [shape=circle,label="#948;12"];
ESC15 -> d13 [dir=back];
d13 [shape=circle,label="#948;13"];
}

```

**Modelo 4 - Path Diagram do modelo baseado no modelo teórico, usando a amostra brasileira, sendo que da escala dos 20 itens considera somente 18 (sem itens 11 e 17).**

```

digraph "CFA_4F_RB_T" {
rankdir=LR;

```

```

ranksep="2.0 equally"
size="20,20";
node [fontname="times" fontsize=14 shape=box];
edge [fontname="times" fontsize=13];
center=10;
"F1" [shape=ellipse]
"F2" [shape=ellipse]
"F3" [shape=ellipse]
"F4" [shape=ellipse]
"F1" -> "ESC6" [label="#955;61=1"];
"F1" -> "ESC7" [label="#955;71"];
"F1" -> "ESC8" [label="#955;81"];
"F1" -> "ESC16" [label="#955;161"];
"F2" -> "ESC10" [label="#955;102=1"];
"F1" -> "ESC12" [label="#955;122"];
"F2" -> "ESC18" [label="#955;182"];
"F2" -> "ESC19" [label="#955;192"];
"F2" -> "ESC20" [label="#955;202"];
"F3" -> "ESC1" [label="#955;13=1"];
"F3" -> "ESC2" [label="#955;23"];
"F3" -> "ESC4" [label="#955;43"];
"F3" -> "ESC5" [label="#955;53"];
"F4" -> "ESC3" [label="#955;34"];
"F4" -> "ESC9" [label="#955;94"];
"F4" -> "ESC13" [label="#955;134"];
"F4" -> "ESC14" [label="#955;144"];
"F4" -> "ESC15" [label="#955;154=1"];
"F1"->"F2"[label="#966;21",dir=both];
"F2"->"F3"[label="#966;32",dir=both];
"F3"->"F4"[label="#966;43",dir=both];
"F1"->"F4"[label="#966;41",dir=both];
"F1"->"F3"[label="#966;31",dir=both];
"F2"->"F4"[label="#966;42",dir=both];
{rank = same; F1;F2;F3;F4; }
ESC6 -> d1 [dir=back];
d1 [shape=circle,label="#948;1"];
ESC7 -> d2 [dir=back];
d2 [shape=circle,label="#948;2"];
ESC8 -> d3 [dir=back];
d3 [shape=circle,label="#948;3"];
ESC16 -> d4 [dir=back];
d4 [shape=circle,label="#948;4"];
ESC12 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC10 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC18 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];

```

```

ESC19 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
ESC20 -> d9 [dir=back];
d9 [shape=circle,label="#948;9"];
ESC1 -> d10 [dir=back];
d10 [shape=circle,label="#948;10"];
ESC2 -> d11 [dir=back];
d11 [shape=circle,label="#948;11"];
ESC4 -> d12 [dir=back];
d12 [shape=circle,label="#948;12"];
ESC5 -> d13 [dir=back];
d13 [shape=circle,label="#948;13"];
ESC3 -> d14 [dir=back];
d14 [shape=circle,label="#948;14"];
ESC9 -> d15 [dir=back];
d15 [shape=circle,label="#948;15"];
ESC13 -> d16 [dir=back];
d16 [shape=circle,label="#948;16"];
ESC14 -> d17 [dir=back];
d17 [shape=circle,label="#948;17"];
ESC15 -> d18 [dir=back];
d18 [shape=circle,label="#948;18"];
}

```

**Modelo 5 – Path Diagram do modelo baseado no modelo teórico, usando a amostra brasileira sendo que, na escala dos 20 itens considera somente 13 (sem itens 10, 11, 12, 17, 18, 19 e 20).**

```

digraph "CFA_3F_RC_T" {
rankdir=LR;
ranksep="2.0 equally"
size="20,20";
node [fontname="times" fontsize=14 shape=box];
edge [fontname="times" fontsize=13];
center=10;
"F1" [shape=ellipse]
"F2" [shape=ellipse]
"F3" [shape=ellipse]
"F1" -> "ESC6" [label="#955;61=1"];
"F1" -> "ESC7" [label="#955;71"];
"F1" -> "ESC8" [label="#955;81"];
"F1" -> "ESC16" [label="#955;161"];
"F2" -> "ESC1" [label="#955;12=1"];
"F2" -> "ESC2" [label="#955;22"];
"F2" -> "ESC4" [label="#955;42"];
"F2" -> "ESC5" [label="#955;52"];
"F3" -> "ESC3" [label="#955;33=1"];
"F3" -> "ESC9" [label="#955;93"];
}

```

```

"F3" -> "ESC13" [label="#955;133"];
"F3" -> "ESC14" [label="#955;143"];
"F3" -> "ESC15" [label="#955;153"];
"F1"->"F2"[label="#966;21",dir=both];
"F2"->"F3"[label="#966;32",dir=both];
"F1"->"F3"[label="#966;31",dir=both];
{rank = same; F1;F2;F3; }
ESC6 -> d1 [dir=back];
d1 [shape=circle,label="#948;1"];
ESC7 -> d2 [dir=back];
d2 [shape=circle,label="#948;2"];
ESC8 -> d3 [dir=back];
d3 [shape=circle,label="#948;3"];
ESC16 -> d4 [dir=back];
d4 [shape=circle,label="#948;4"];
ESC1 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC2 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC4 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];
ESC5 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
ESC3 -> d9 [dir=back];
d9 [shape=circle,label="#948;9"];
ESC9 -> d10 [dir=back];
d10 [shape=circle,label="#948;10"];
ESC13 -> d11 [dir=back];
d11 [shape=circle,label="#948;11"];
ESC14 -> d12 [dir=back];
d12 [shape=circle,label="#948;12"];
ESC15 -> d13 [dir=back];
d13 [shape=circle,label="#948;13"];
}

```

**Modelo 6 – Path Diagram do modelo baseado no modelo teórico parcelado, usando a amostra brasileira na escala modificada de 8 itens compostos parcelados.**

```

digraph "CFA_REE_4FFP_T BANCO REE" {
rankdir=LR;
ranksep="2.0 equally"
size="30,30";
node [fontname="times" fontsize=14 shape=box];
edge [fontname="times" fontsize=13];
center=10;
"F1" [shape=ellipse]
"F2" [shape=ellipse]
"F3" [shape=ellipse]

```



```

"F4" [shape=ellipse]
"F1" -> "ESC6e16" [label="#955;11=1"];
"F1" -> "ESC8e7" [label="#955;21"];
"F2" -> "ESC10e12" [label="#955;32=1"];
"F2" -> "ESC18e19e20" [label="#955;42"];
"F3" -> "ESC1e2" [label="#955;53=1"];
"F3" -> "ESC4e5" [label="#955;63"];
"F4" -> "ESC9e13" [label="#955;74=1"];
"F4" -> "ESC14e3e15" [label="#955;84"];
"F1"->"F2"[label="#966;21",dir=both];
"F2"->"F3"[label="#966;32",dir=both];
"F3"->"F4"[label="#966;43",dir=both];
"F1"->"F4"[label="#966;41",dir=both];
"F1"->"F3"[label="#966;31",dir=both];
"F2"->"F4"[label="#966;42",dir=both];
{rank = same; F1;F2;F3;F4; }
ESC6e16 -> d1 [dir=back];
d1 [shape=circle,label="#948;1"];
ESC8e7 -> d2 [dir=back];
d2 [shape=circle,label="#948;2"];
ESC10e12 -> d3 [dir=back];
d3 [shape=circle,label="#948;3"];
ESC18e19e20 -> d4 [dir=back];
d4 [shape=circle,label="#948;4"];
ESC1e2 -> d5 [dir=back];
d5 [shape=circle,label="#948;5"];
ESC4e5 -> d6 [dir=back];
d6 [shape=circle,label="#948;6"];
ESC9e13 -> d7 [dir=back];
d7 [shape=circle,label="#948;7"];
ESC14e3e15 -> d8 [dir=back];
d8 [shape=circle,label="#948;8"];
}

```