



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



**MODELOS DE EQUAÇÕES ESTRUTURAIS COM
ÊNFASE EM ANÁLISE FATORIAL CONFIRMATÓRIA
NO SOFTWARE AMOS**

CRISTIANO LEMKE

ORIENTADORA: JANDYRA MARIA GUIMARÃES FACHEL

Monografia apresentada para obtenção
do grau de bacharel em estatística.

Porto Alegre, Dezembro de 2005.

*Agradeço a Deus.
Agradeço a minha namorada
Elisa pelo apoio e por ser tão amável.
Agradeço a minha orientadora Jandyra,
que me incentivou e foi sempre prestativa.
Agradeço aos colegas e demais professores,
que de alguma forma colaboraram com este trabalho.
Agradeço a minha família por toda paciência, suporte e carinho.*

SUMÁRIO

SUMÁRIO.....	5
1 INTRODUÇÃO.....	7
1.1 Objetivos.....	9
1.2 Estrutura do Trabalho	9
2 CONCEITOS BÁSICOS.....	11
2.1 Variáveis Latentes & Variáveis Observáveis	11
2.2 Variáveis Latentes Exógenas & Variáveis Latentes Endógenas	11
2.3 Modelo de Análise Fatorial	12
2.4 Modelo Completo de Variável Latente.....	12
2.5 O Processo de Modelagem Estatística.....	13
3 O MODELO GERAL DE SEM	15
3.1 O Diagrama de Trajeto	15
3.2 As Equações Estruturais	17
3.3 Composição básica de SEM	18
3.4 Formulação da Estrutura de Covariância e de Média.....	19
3.5 Identificação do Modelo	20
3.6 Estimação dos Parâmetros	23
3.7 Análise de Dados Categóricos.....	23
3.8 Representação Matemática de SEM	25
4 O SOFTWARE AMOS	28
5 METODOLOGIA E EXEMPLO DE CFA DE PRIMEIRA ORDEM	34
5.1 Hipótese 1 – AC Estruturado com Quatro Fatores	35
5.2 Especificação dos Dados	38
5.3 Cálculo das Estimativas.....	39
5.4 Avaliação do Modelo.....	42
5.5 Análise “Post Hoc”	56
5.6 Hipótese 2: AC Estruturado com Dois Fatores.....	57

6	METODOLOGIA E EXEMPLO DE CFA DE SEGUNDA ORDEM	61
6.1	O Modelo Hipotético	61
6.2	Avaliação do Modelo.....	69
6.3	Análise Post Hoc.....	72
7	ANÁLISE FATORIAL CONFIRMATÓRIA DO INSTRUMENTO DE MEDIDA: <i>PROSPECTIVE AND RETROSPECTIVE MEMORY QUESTIONNAIRE</i> (PRMQ).....	78
7.1	Introdução ao Prospective and Retrospective Memory Questionnaire.....	78
7.2	CFA do PRMQ	81
8	CONCLUSÃO.....	86
9	REFERÊNCIAS BIBLIOGRÁFICAS	87
	APÊNDICES	90
	APÊNDICE A: Notações.....	90
	APÊNDICE B: Funções de Discrepância para Estimação no AMOS:.....	92
	APÊNDICE C: Medidas de Ajuste.....	94

1 INTRODUÇÃO

Modelos de equações estruturais, do inglês SEM – Structural Equation Modeling - formam um conjunto de técnicas estatísticas que avaliam relações simultâneas entre uma ou mais variáveis independentes e uma ou mais variáveis dependentes. O termo Structural Equation Modeling conduz a dois importantes aspectos de procedimento: (a) que o processo causal em estudo está representado por uma série de equações estruturais, e (b) estas relações estruturais podem ser modeladas de forma a deixar clara a conceitualização da teoria em estudo. O modelo hipotético pode ser testado estatisticamente através de uma análise simultânea de todo o sistema de variáveis para ver se ele está consistente com os dados. Se o modelo está adequado (*goodness of fit*), então as relações postuladas entre as variáveis são plausíveis; se não está adequado, a sustentabilidade destas relações é rejeitada.

Utiliza-se o SEM para procedimentos multivariados não encontrados em outros softwares estatísticos tradicionais. Por exemplo, é possível utilizar estes modelos para realizar uma análise fatorial confirmatória que diferentemente da análise fatorial exploratória exige do pesquisador uma idéia *a priori* da estrutura da matriz fatorial. É também muito mais provável um pesquisador utilizar o SEM para verificar se um determinado modelo é válido do que para “encontrar” um modelo apropriado, embora as análises de SEM envolvam freqüentemente um determinado elemento exploratório. Outro aspecto é o fato do modelo de relações interváveis possuir uma estrutura *a priori* especificada o que permite que a análise de dados em SEM possa ser realizada com objetivos de inferência, principalmente no sentido de testes de ajustamento. A maioria das outras técnicas multivariadas são essencialmente descritivas por natureza (como a análise fatorial exploratória), onde testes de hipóteses sobre o modelo como um todo são difíceis, se não impossíveis, de serem realizados. Outra vantagem do SEM é que ele possibilita uma estimativa dos erros dos parâmetros, enquanto alguns métodos alternativos (como os modelos lineares generalizados) não fornecem os erros das variáveis explanatórias.

Um modelo de equações estruturais utiliza uma estrutura de matriz de covariância das medidas (um nome alternativo conhecido para SEM é "Análise das Estruturas de Covariância"). Uma vez que os parâmetros do modelo foram estimados, o modelo resultante dado pela matriz de covariância pode então ser comparado a uma

matriz de covariância empírica ou baseada em dados. Se as duas matrizes forem consistentes uma com a outra, então o modelo de equação estrutural pode ser considerado plausível para relações entre as medidas.

O uso de SEM é muito geral, abrangendo técnicas estatísticas como regressão linear e múltipla, regressão multivariada, análise fatorial confirmatória, análise fatorial exploratória, path analysis, ANCOVA.

Outra característica da modelagem de equações estruturais é possuir uma nomenclatura bem própria:

Variáveis Exógenas – são variáveis independentes, supostamente medidas sem erro. São causadas ou influenciadas por fatores externos ao modelo.

Variáveis Endógenas – são variáveis dependentes. São parcialmente explicadas pelo modelo.

As **variáveis observadas** são medidas diretamente pelo pesquisador. Enquanto as **variáveis latentes** ou não observadas não são medidas diretamente, mas podem ser inferidas pela relação ou pelas correlações entre variáveis mensuráveis.

Em SEM, as variáveis de interesse são geralmente conceitos abstratos (variáveis latentes), tais como a inteligência, ou a atitude. Podemos observar o comportamento das variáveis latentes somente de forma indireta e imprecisa, através dos seus efeitos nas variáveis manifestas.

SEM pode ser aplicado em diversos campos da ciência, como por exemplo:

- **Psicologia** – Exemplo: Desenvolver modelos para entender como as drogas, as medicações e a terapia afetam o humor do paciente;
- **Medicina** - Exemplo: confirmar qual das três variáveis melhor prediz uma sustentação para o médico prescrever medicamentos genéricos: confiança, o preço ou o desempenho nos testes;
- **Ciências Sociais** – Exemplo: Descobrir como o status sócio-econômico, organização social e outras variáveis afetam a participação política do indivíduo;
- **Pesquisa Educacional** – Exemplo: Avaliar os resultados de um programa de treinamento para determinar o impacto da sua possível eficácia no aprendizado

- **Pesquisa de Mercado** – Exemplo: Modelar como o comportamento do cliente impacta nas vendas de um produto novo.

1.1 Objetivos

O objetivo é construir um trabalho sobre modelos de equações estruturais, com enfoque na análise fatorial confirmatória. Um trabalho de cunho prático com fundamentação estatística. Existem muitas bibliografias que tratam sobre esse assunto, mas geralmente ou são totalmente teóricas, ou são um mero tutorial do programa, e praticamente todas em inglês. A idéia neste trabalho é juntar as duas coisas, formando um material bastante usual para resolver situações de pesquisa especialmente com a análise fatorial confirmatória via SEM e o software AMOS, com a facilidade adicional de estar no nosso idioma.

1.2 Estrutura do Trabalho

- Capítulo 1 – Introdução, apresentação, objetivos e estrutura do trabalho.
- Capítulo 2 – Conceitos Básicos; variáveis latentes e variáveis observadas, variáveis endógenas e variáveis exógenas, modelo de análise fatorial, modelo completo de variável latente e o processo de modelagem estatística.
- Capítulo 3 – Modelo geral de SEM; o diagrama de trajeto, as equações estruturais, modelo de medida e modelo estrutural, identificação do modelo, suposições do SEM, representação matemática.
- Capítulo 4 – Tutorial do software AMOS *Graphics* baseado na versão 4.0.
- Capítulo 5 – Exemplo de Análise Fatorial Confirmatória de primeira ordem com análise de resíduos, índices de ajuste (*goodness-of-fit*) e índices de modificação.
- Capítulo 6 – Exemplo de Análise Fatorial Confirmatória de segunda ordem.

- Capítulo 7 – Validação de um instrumento de medida da memória prospectiva e a memória retrospectiva através da Análise Fatorial Confirmatória no AMOS, para os dados da dissertação de mestrado “Tradução para o português-brasileiro e validação do *Prospective and Retrospective Memory Questionnaire* (PRMQ)” de Daniela Benites .

Este trabalho é fortemente baseado em Byrne (2001), e citações a ele serão mencionadas quando se julgou mais importante.

2 CONCEITOS BÁSICOS

2.1 Variáveis Latentes & Variáveis Observáveis

Nas ciências comportamentais, os pesquisadores geralmente estão interessados em estudar construções teóricas que não podem ser observadas diretamente. Essas construções teóricas são chamadas de *variáveis latentes* ou *fatores*. Alguns exemplos de variáveis latentes são conceitos abstratos como inteligência, satisfação, motivação, atitude,...

Como estas variáveis não são observadas diretamente, também não podem ser medidas diretamente. Os pesquisadores definem essas variáveis latentes em termos do seu conhecimento sobre o assunto. Tais variáveis podem ser medidas indiretamente ao serem associadas a uma ou mais variáveis observáveis. Essas medidas podem ser feitas através de escores obtidos em entrevistas, respostas codificadas de questionários, etc. Estes escores são denominados *variáveis observadas* ou *manifestas*, que na metodologia de SEM servem como indicadores para representar a(s) variável(eis) latente(s) a eles correlacionados.

2.2 Variáveis Latentes Exógenas & Variáveis Latentes Endógenas

É muito importante quando se está trabalhando com Modelos de Equações Estruturais distinguir entre variáveis que são exógenas das que são endógenas. O termo variável *exógena* é um sinônimo para variável independente; elas causam flutuações em outras variáveis no modelo. Mudanças nos valores das variáveis exógenas não são explicadas pelo modelo, mas podem ser influenciadas por fatores externos ao modelo, como sexo, idade, classe social. Já o termo variável *endógena* é um sinônimo para variável dependente, porque as variáveis endógenas são influenciadas pelas variáveis exógenas no modelo, direta ou indiretamente. Flutuações nos valores das variáveis endógenas são ditas explicadas parcialmente pelo modelo.

2.3 Modelo de Análise Fatorial

O mais antigo e conhecido procedimento estatístico para a investigação de relações entre as variáveis observadas e as variáveis latentes é a *análise fatorial*. Na análise fatorial o pesquisador examina a covariância entre variáveis observadas com o objetivo de obter informações a respeito do fator latente em estudo. Há dois tipos básicos de análise fatorial: a *análise fatorial exploratória* (exploratory factor analysis – EFA) e a *análise fatorial confirmatória* (confirmatory factor analysis – CFA). Faremos uma breve descrição de ambas:

Análise fatorial exploratória (EFA) é usada quando não se tem uma conexão entre as variáveis observadas e as variáveis latentes, por falta de conhecimento ou incerteza sobre o fator em estudo. Através da EFA, o pesquisador identifica variáveis ou fatores que explicam correlações dentro de um conjunto de variáveis. É um procedimento de redução da dimensão dos dados originais que visa identificar um pequeno número de fatores que explique a maior parte da variação observada em um número muito maior de variáveis.

Análise fatorial confirmatória (CFA) é apropriada quando o pesquisador já possui alguma idéia sobre as variáveis latentes em estudo (fatores). Baseado no conhecimento teórico, resultados de pesquisas, ou até mesmo de ambos, ele postula as relações entre as variáveis medidas e os fatores definidos a priori, e então testa estatisticamente essa estrutura hipotética. Devido ao fato do modelo CFA focar somente a ligação entre os fatores e as variáveis observadas, ele é o mais utilizado em SEM.

2.4 Modelo Completo de Variável Latente

O modelo é dito completo quando contempla o modelo de medida e o modelo estrutural. O modelo de medida é aquele que descreve as ligações entre as variáveis latentes e as suas medidas observadas, como, por exemplo, o modelo CFA. O modelo estrutural descreve as ligações entre as variáveis latentes.

Um modelo completo de variável latente é dito *recursivo* quando especifica uma direção de causa e efeito para apenas uma direção; é dito *não recursivo* quando indica

efeito de causa em mais de uma direção, como efeitos recíprocos ou “feedbacks”. Neste trabalho trataremos apenas do modelo recursivo.

2.5 O Processo de Modelagem Estatística

Os modelos estatísticos são boas ferramentas para descrever uma estrutura latente, através de determinadas variáveis observadas. Esses modelos podem ser expressos graficamente através de diagramas ou matematicamente através de equações. Tais modelos explicam como as variáveis latentes e as variáveis observadas estão relacionadas umas às outras. A postulação do modelo estatístico se dá, geralmente, pelo conhecimento teórico do pesquisador sobre o assunto, pesquisa empírica, ou pela junção das duas coisas. Depois que o modelo é especificado, o pesquisador testa sua adequação, baseado nos dados amostrais obtidos através de todas as variáveis observadas no modelo. A tarefa primária neste procedimento de testar o modelo é determinar quão bom é o ajuste do modelo (*goodness-of-fit*) aos dados amostrais. Como não há um ajuste perfeito, existe uma diferença entre o modelo especificado hipoteticamente e os dados amostrais, chamada resíduo. Este processo de ajuste do modelo pode ser sintetizado como segue:

$$\text{DADOS} = \text{MODELO} + \text{RESÍDUO}$$

onde DADOS representam os dados amostrais, verificados pelas variáveis observadas; MODELO representa a estrutura hipotética de ligação das variáveis latentes e observadas; RESÍDUO representa a discrepância entre os dados e o modelo.

A idéia geral para testar modelos de equações estruturais, segundo Joreskog (1993), compreende três cenários distintos. O cenário estritamente confirmatório, onde o pesquisador cria o modelo hipotético, coleta os dados e então simplesmente aceita ou rejeita o modelo, sem modificações posteriores. Temos também o cenário de modelos alternativos, em que o pesquisador propõe um certo número de modelos, optando pelo mais plausível para os dados observados após testá-los. Por fim, existe o cenário de geração de modelos. Aqui, o pesquisador após rejeitar um modelo por falta de ajuste aos


dados amostrais, começa um procedimento exploratório para encontrar um modelo que melhor descreva os dados amostrais. A re-especificação do modelo pode vir de fontes oriundas da teoria ou mesmo de uma nova concepção sobre o assunto, que os dados amostrais propiciaram.

A situação mais comum é a do último cenário, o de geração de modelos. É o mais largamente utilizado na bibliografia, por motivos óbvios. A coleta de dados é uma tarefa dispendiosa, requer tempo e investimentos. Seria um desperdício fazer toda uma pesquisa e simplesmente parar com a rejeição do modelo especificado, no caso de uma pesquisa estritamente confirmatória.


3 O MODELO GERAL DE SEM

3.1 O Diagrama de Trajeto

Em SEM, as relações entre as variáveis observadas e as variáveis latentes são representadas graficamente através do chamado diagrama de trajeto (*path diagram*). Nestes diagramas existe uma simbologia particular de SEM, que possibilita um entendimento mais claro sobre o modelo, do que se apresentado em forma de equações.



- os círculos ou elipses representam as variáveis latentes (não observadas) e os resíduos (que são sempre não observados);



- os quadrados ou retângulos representam as variáveis observadas;



- as setas uni-direcionais representam a relação de causa entre duas variáveis;



- as setas bi-direcionais representam as correlações e as covariâncias, que indicam relações sem um sentido causal explicitamente definido.

O diagrama de trajeto fornece uma visualização gráfica equivalente à representação matemática, que é dada em forma de equações. Isso ficará claro mais adiante.

Como exemplo, consideramos o modelo a seguir.




fig. 3.1

Na fig. 3.1 temos dois fatores latentes não observados: **F1** e **F2**. Temos cinco variáveis observadas, onde três estão consideradas como medidas de F1 (VO1_F1, VO2_F1, VO3_F1) e duas estão atribuídas a F2 (VO1_F2, VO2_F2).

A cada variável observada existe um termo de erro associado (e1-e5). Ao fator F2 existe um termo residual associado (resid1). Há uma diferença importante entre erro e resíduo. *Erros* associados às variáveis observadas representam erros de medida, que refletem na adequação delas em medir os fatores em estudo (F1 e F2). Estes erros de medida são provenientes de duas fontes: o erro aleatório de medida e o erro derivado de alguma característica específica de uma particular variável indicadora. Esse último erro representa o erro não aleatório, e é conhecido como erro *único*. Já *resíduos* representam erros de predição de fatores endógenos a partir de fatores exógenos. No diagrama anterior temos como exemplo **resid1**, que representa o erro na predição do fator endógeno **F2** feita a partir do fator exógeno **F1**. Ambos os termos de erro são apresentados em círculos, pois são também não observados e consistentes com os fatores.

Além de mostrar as variáveis representadas por símbolos, o diagrama de trajeto também é capaz de mostrar processos hipotéticos envolvendo todo o sistema de variáveis. Na fig. 3.1, as setas apontando para um único sentido (*one-way*) representam coeficientes de regressão estrutural, que indicam o impacto de uma variável na outra. A seta unidirecional apontando o fator endógeno F2 indica que o fator exógeno F1 causa F2. Ou seja, existe um efeito direto de F1 em F2, cuja magnitude e direção é dada por

um coeficiente de regressão parcial. Já as três setas unidirecionais, apontando de F1 para as suas três variáveis observadas (VO1_F1-VO3_F1), e de F2 para cada indicadora (VO2_F1, VO2_F2), sugerem que seus valores são influenciados pelos seus respectivos fatores. Esses coeficientes representam a magnitude da mudança esperada nas variáveis observadas para cada mudança na variável latente relacionada.

As setas unidirecionais vindas dos erros (e1 a e5) indicam o impacto do erro de medida (erro aleatório e único) nas variáveis observadas, e o resíduo (resid1), o impacto do erro na predição de F2.

As setas curvadas bidirecionais representam as covariâncias ou correlações entre pares de variáveis. No diagrama usado como exemplo, o erro de medida associado a VO1_F1 é correlacionado ao erro de medida associado a VO2_F1.

3.2 As Equações Estruturais

Modelos de equações estruturais podem também ser representados por equações de regressão. Isto porque as equações de regressão representam a influência de uma ou mais variáveis em outra, e, convencionalmente em SEM, essa influência é simbolizada por uma seta apontando da variável de influência para a variável de interesse. Podemos assim pensar que cada equação é um sumário do impacto de todas as variáveis relevantes no modelo (tanto observadas quanto não observadas) em uma específica variável (observadas ou não observadas). Uma aproximação relativamente simples para formular estas equações é notar que cada variável que possui pelo menos uma seta apontando para ela registra a soma de todas as influências de cada uma dessas variáveis dependentes.

Na fig. 3.1 existem seis variáveis com setas apontando para elas. Cinco são as variáveis observadas (VO1_F1, VO2_F1, VO3_F1, VO1_F2, VO2_F2), e uma representa uma variável não observada (o fator F2). O modelo exposto na fig. 3.1 pode ser resumido em termos de seis equações linearmente dependentes:

$$F2 = F1 + \text{resid1}$$

$$VO1_F1 = F1 + e1$$

$$VO2_F1 = F1 + e2$$

$$VO3_F1 = F1 + e3$$

$$VO1_F2 = F2 + e4$$

$$VO2_F2 = F2 + e4$$

3.3 Composição básica de SEM

O modelo geral de SEM pode ser decomposto em dois submodelos. Um chamado “measurement model”, que traduzirei como *modelo de medida*, e outro chamado *modelo estrutural*. No modelo de medida estão definidas as relações entre as variáveis observadas e as variáveis não observadas. Ou seja, é uma ligação entre os escores de um instrumento de medida (as variáveis indicadoras observadas) e o construto teórico em estudo que foram designadas para medir (as variáveis latentes não observadas). O modelo estrutural define as relações entre as variáveis não observadas. Ele especifica como uma particular variável latente causa (direta ou indiretamente) mudanças em outras variáveis latentes no modelo.

Para esquematizar esta decomposição em submodelos, considere a figura a seguir:

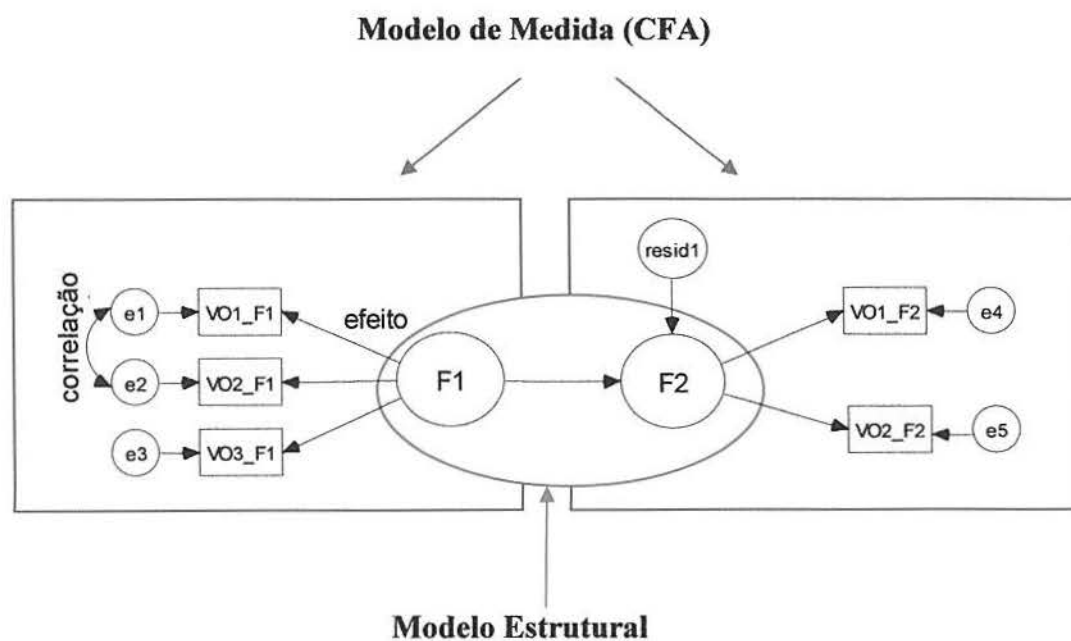


fig. 3.2

Considerados separadamente, os dois modelos em cada retângulo na fig. 3.2 representam dois modelos de análise fatorial confirmatória (CFA). Os dois fatores envolvidos pela elipse caracterizam um modelo completo de variável latente, que não é o interesse na pesquisa CFA.

O modelo CFA da esquerda representa um modelo de um fator (F1) medido pelas três variáveis observadas VO1_F1, VO2_F1 e VO3_F1. O modelo da direita representa um modelo de um fator (F2) medido por duas variáveis observadas VO1_F2, VO2_F2. Em ambos, estimar os coeficientes da regressão das variáveis observadas em cada fator, as variâncias de cada fator e os erros de medida são objetivos primários.

Os dois modelos descritos na fig. 3.2 são modelos fatoriais de primeira ordem. Modelos de ordem maior também podem ser gerenciados por SEM. Aqui abordaremos até o modelo de segunda ordem.

3.4 Formulação da Estrutura de Covariância e de Média

Em SEM, os parâmetros que geralmente são estimados na análise das estruturas de covariância são os coeficientes de regressão, as variâncias e as covariâncias das variáveis independentes. Quando se quer proceder a análise de estruturas de médias, as médias e os interceptos também se tornam parâmetros centrais no modelo. Porém, com uma amostra que só tenha escores observados, é necessário algum mecanismo interno que possibilite transpor os dados em parâmetros do modelo. Essa tarefa é realizada através de um modelo matemático que representa todo o sistema de variáveis. Essas representações sistemáticas variam em cada software para análise de SEM, e como sua explicação necessita de conhecimentos de programação além da teoria estatística, ele foge do objetivo deste trabalho.

Para uma explicação profunda sobre estruturas de covariâncias é recomendada a leitura de outros trabalhos e livros aprofundados no assunto (Bollen, 1989).

3.5 Identificação do Modelo

A identificação do modelo é um tema complexo e difícil de ser explicado. Aqui neste trabalho faremos uma síntese, em termos não matemáticos, do conceito geral da identificação do modelo. A compreensão desse conceito geral facilitará entender, como veremos mais adiante, porque alguns parâmetros têm seus valores fixados. Para explicações mais complexas, recomendamos a leitura de Bollen (1989).

O interesse na especificação do modelo está diretamente centrado na transposição da matriz de covariância das variáveis observadas em parâmetros estruturais do modelo em estudo. Se uma única solução para os valores dos parâmetros estruturais pode ser encontrada, o modelo é considerado como identificado. Como consequência, os parâmetros são estimáveis e o modelo é testável. Por outro lado, um modelo que não pode ser identificado sugere uma arbitrariedade nos parâmetros, que implica que diferentes valores dos parâmetros definem o mesmo modelo. Assim, estimativas consistentes para todos os parâmetros não são possíveis, e o modelo não pode ser avaliado empiricamente. Como exemplo imagine um processo que tente determinar valores únicos para X e Y quando a única informação que temos é que $X + Y = 15$. Generalizando este exemplo para uma análise de estrutura de covariância, o foco na identificação do modelo se estende para o único conjunto de valores que podem ser inferidos para os parâmetros desconhecidos a partir de uma matriz de covariância das variáveis analisadas que são reproduzidas pelo modelo.

Os modelos estruturais podem ter três tipos de identificação: *just-identified*, *underidentified* e *overidentified*. O modelo *just-identified* define-se na situação em que há uma correspondência um-a-um entre os dados e os parâmetros estruturais. Em outras palavras, o número de variâncias e covariâncias dos dados é igual ao número de parâmetros a serem estimados. Entretanto, apesar da capacidade do modelo em identificar uma única solução para todos os parâmetros, o modelo *just-identified* não é cientificamente interessante porque não possui graus de liberdade e jamais poderá ser rejeitado. No modelo *underidentified*, o número de parâmetros a serem estimados é maior que o número de variâncias e covariâncias (pontos dos dados). Neste caso o modelo tem pouca informação para determinar a solução na estimação dos parâmetros. Isto quer dizer que um número infinito de soluções é possível para um modelo *underidentified*. No modelo *overidentified*, o número de parâmetros a serem estimados é menor que o número de pontos dos dados (variâncias, covariâncias das variáveis

observadas). Esta situação resulta em graus de liberdade positivos, que permitem o teste do modelo. O objetivo em SEM é, então, especificar um modelo segundo este critério do modelo *overidentified*.

O modelo do diagrama da fig. 3.3 a seguir será utilizado como exemplo.

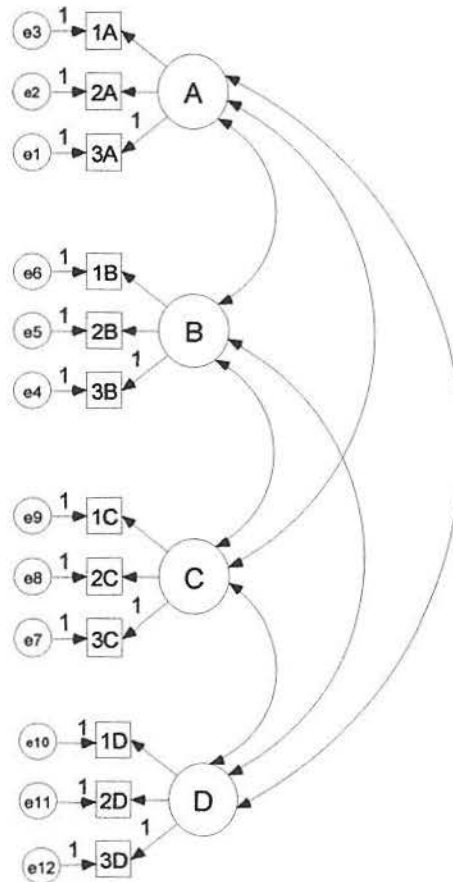


fig. 3.3

É um modelo de CAF no qual determinamos quantos pontos de dados temos para trabalhar (quanta informação temos a respeito dos nossos dados). Como mencionado antes, os pontos são constituídos de variâncias e covariâncias. Com p variáveis, existem $p(p+1)/2$ elementos. Como existem 12 variáveis observadas, nós temos $12(12+1)/2 = 78$ pontos de dados.

Em SEM é extremamente importante sempre registrar o número de parâmetros no modelo a serem estimados antes de se proceder a análise. Essa informação é crítica para sabermos se o modelo que estamos testando é ou não estatisticamente identificável. Para o exemplo da figura, contabilizaremos o número de parâmetros a serem estimados:

- Existem 12 coeficientes de regressão (cargas fatoriais);
- 16 variâncias (12 de erro e 4 dos fatores);
- 6 covariâncias dos fatores.

Temos um total de 34 parâmetros. Os valores “1” que aparecem nas cargas fatoriais no diagrama são valores fixos, portanto não serão estimados. Teremos então que descontar 4 parâmetros, totalizando 30 parâmetros a serem estimados no modelo CFA da fig.3.3.

Assim, com 78 pontos de dados e 30 parâmetros a serem estimados, temos um modelo *overidentified* com 48 graus de liberdade.

A especificação de um modelo *overidentified* é uma condição necessária, mas não suficiente para resolver o problema da identificação. A imposição de contrastes para determinados parâmetros pode, às vezes, ajudar o pesquisador a alcançar um modelo *overidentified*.

Relacionado ao assunto da identificação está a necessidade de cada variável latente ter a sua escala determinada, pois são variáveis não observadas e conseqüentemente não tem definida uma escala métrica. Esse requisito é satisfeito utilizando um contraste, um valor que não seja zero (tipicamente 1 é utilizado) em uma das cargas fatoriais que são designadas para medir o mesmo fator. Isso vale tanto para variáveis latentes dependentes como para variáveis independentes. Olhando a fig. 3.3, isso significa que cada uma das três trajetórias de regressão de cada fator (A, B, C e D) para o seu conjunto de variáveis indicadoras deve ter um valor fixo especificado. Este parâmetro fixado é chamado de variável referência. A decisão de qual parâmetro fixar é arbitrária (Byrne, 2001). A medida que tem maior confiança é recomendada, se essa informação é conhecida. O valor a ser especificado do parâmetro também é arbitrário. Na fig. 3.3, por exemplo, a escala foi estabelecida contrastando o valor 1.0 no terceiro parâmetro em cada conjunto de variáveis observadas.

3.6 Estimação dos Parâmetros

(ver Apêndice B)

No AMOS, por padrão, a estimação dos parâmetros é baseada no método da máxima verossimilhança (ML – *maximum likelihood*). Entretanto, esse método requer que algumas condições sejam satisfeitas:

- a. Amostras grandes;
- b. As variáveis observadas pertencem a uma distribuição normal multivariada;
- c. O modelo hipotético deve ser válido;
- d. As variáveis observadas têm escala quantitativa.

De todas essas condições, a última, que se refere à escala das variáveis é a que tem gerado bastante debate nos últimos anos. O foco deste debate tem sido a questão do tratamento das variáveis com escala ordinal como se fossem quantitativas. Um exemplo típico é utilizar dados computados na forma da escala *Likert* (5 categorias: concordo plenamente, concordo, neutro, não concordo e não concordo plenamente) em programas de SEM ou em tradicionais técnicas estatísticas, como ANOVA, onde existe a suposição de que as variáveis tenham escala contínua.

3.7 Análise de Dados Categóricos

Byrne (2001 pág. 71-72) escreve que uma revisão das aplicações de modelos de equações estruturais nos últimos 15 anos (principalmente na área da psicologia) revela que a maioria é baseada na escala do tipo *Likert*, utilizando como método de estimação a máxima verossimilhança (ML).

As duas primeiras aproximações para análise de dados categóricos foram desenvolvidas por Joreskog (1990) e Muthén (1984). Ambas as metodologias usam limitadas informações de estimadores baseados em um estimador assintótico de distribuição-livre (*ADF - asymptotic distribution-free*) de Wothke, 1993. Porém existem três restrições nas metodologias de variáveis categóricas que são relevantes:

- a. Necessidade de grandes amostras;
- b. Número limitado de variáveis observadas (<25);
- c. A forte suposição de que para cada variável categórica observada exista uma variável latente não observada que seja de escala contínua e que estas variáveis latentes contínuas tenham distribuição normal multivariada (Bentler & Wu, 1995);

Devido ao fato desta última suposição ser extremamente forte e, em certos contextos, não apropriada, Bentler e seu associados (Chou, Bentler, & Satorra, 1991), discutiram se fazia mais sentido tratar as variáveis categóricas como se fossem quantitativas e corrigir o teste estatístico do que usar um diferente método de estimação. A escala estatística criada por Satorra & Bentler (1988), chamada escala estatística Satorra-Bentler pode ser utilizada para fazer tal correção. As três suposições fizeram com que a estimação por distribuição-livre fosse pouco praticável para a maioria dos pesquisadores, em análises de dados reais (não simulados).

Tendo em vista essas impraticabilidades, é conveniente conhecer os riscos que envolvem tratar as variáveis categóricas como se fossem quantitativas. Uma revisão de estudos de *Monte Carlo* sobre esse assunto (Babakus, Ferguson, & Joreskog, 1987), mostra importantes resultados. Em primeiro lugar, os coeficientes de correlação de Pearson são maiores quando computados entre duas variáveis quantitativas do que quando computados pelas mesmas variáveis reestruturadas em escala categórica ordinal. Entretanto, a maior atenuação ocorre quando as variáveis têm menos que cinco categorias e elas exibem um alto grau de assimetria. Isso fica pior quando as variáveis estão assimétricas em direções opostas (uma variável é positivamente assimétrica, a outra negativamente assimétrica). Segundo, quando variáveis categóricas são aproximadas a uma distribuição normal:

- a. O número de categorias tem um pequeno efeito no valor do χ^2 da verossimilhança no teste de ajuste do modelo.
- b. Cargas fatoriais e correlações fatoriais são apenas modestamente subestimados. Entretanto, a subestimação se torna mais crítica quando existe menos do que três categorias, a assimetria é maior que 1.0 e assimetrias em direções opostas ocorrem entre as variáveis.
- c. Estimativas dos erros das variâncias, mais do que de outros parâmetros, parecem ser mais sensíveis à categorização e assimetria mostradas em b;

- d. As estimativas dos erros padrões para todos os parâmetros tendem a ser baixas, principalmente quando as distribuições são muito e diferentemente assimétricas.

Neste trabalho, todas as aplicações serão baseadas na estimação por máxima verossimilhança, com os dados sendo tratados como variáveis quantitativas. Existem dois pontos que dão suporte a essa estratégia. Primeiramente, o método da máxima verossimilhança é menos problemático quando é analisada uma matriz de covariância do que uma matriz de correlação, pois utilizando a correlação é possível se estimar incorretamente os erros padrões. Segundo, quando o número de categorias é grande, a falha atribuída à ordinaryidade dos dados é provavelmente desprezível (Atkinson, 1988). Bentler & Chou (1987) afirmam que métodos contínuos podem ser usados sem muita preocupação quando a variável tem quatro ou mais categorias. Resultados mais recentes dão suporte a essas afirmações e mostram que a estatística χ^2 é influenciada mais pelo formato de resposta em duas categorias e menos quando o número de categorias aumenta (Green, Akey, Fleming, Hershberger, & Marquis, 1997).

3.8 Representação Matemática de SEM

Essa representação matemática foi baseada em Hair & cols. (1998). O modelo completo de equações estruturais pode ser expresso em termos de oito matrizes, duas definindo as equações estruturais, duas definindo a correspondência dos indicadores e construtos, uma para as correlações dos construtos exógenos, uma para as correlações dos construtos endógenos, e duas dos erros de medida das variáveis endógenas e exógenas. A tab. 3.1 lista cada uma dessas matrizes e suas particulares notações.

As matrizes são usadas na forma de equações básicas para ambos os modelos de medida e estrutural. A equação para o modelo de medida é:

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

As equações para o modelo de medida são como segue:

Construto Exógeno

$$X = \Lambda_x \xi + \delta$$

Construto Exógeno

$$Y = \Lambda_y \eta + \varepsilon$$

Modelo	Notação		Descrição
	Matriz	Elemento	
Modelo Estrutural	B	β_{nm}	Relacionamentos de construto endógeno para endógeno
	Γ	γ_{nm}	Relacionamentos de construto exógeno para exógeno
	Φ	ϕ_{mm}	Correlação entre construtos exógenos
	Ψ	ψ_{nn}	Correlação entre construtos endógenos
Modelo de Medida	Λ_x	λ^x_{pm}	Carga dos indicadores exógenos
	Λ_y	λ^y_{qn}	Carga dos indicadores endógenos
	Θ_δ	θ^δ_{pp}	Matriz correlacional da predição dos erros para os indicadores dos construtos exógenos
	Θ_ε	θ^ε_{qq}	Matriz correlacional da predição dos erros para os indicadores dos construtos endógenos
Construtos e Indicadores		ξ	Construto exógeno
		η	Construto endógeno
		X	Indicador exógeno
		Y	Indicador endógeno
Modelo de Equações Estrutural e de Medida			
	Modelo Estrutural	$\eta = \Gamma \xi + \beta \eta + \zeta$	Relacionamentos entre construtos exógenos e endógenos
Modelo de Medida	Exógeno	$X = \Lambda_x \xi + \delta$	Especificação de indicadores para construtos exógenos
	Endógeno	$Y = \Lambda_y \eta + \varepsilon$	Especificação de indicadores para construtos endógenos
Tamanho das Matrizes		m	Número de construtos exógenos
		n	Número de construtos endógenos
		p	Número de indicadores de construtos exógenos
		q	Número de indicadores de construtos endógenos

tab. 3.1

Com o objetivo de ilustração, suponha dois construtos endógenos ($n=2$) e três construtos exógenos ($m=3$), com quatro indicadores de ambos os construtos endógenos e exógenos ($p=4$, $q=4$). Nenhuma relação causal está expressa. A relação completa das equações é mostrada na tab. 3.2.

<u>Equações do Modelo Estrutural</u>					
<i>Construto Endógeno</i>		<i>Construto Exógeno</i>		<i>Construto Endógeno</i>	<i>Erro</i>
η_1	=	$\gamma_{11}\xi_1 + \gamma_{12}\xi_2 + \gamma_{13}\xi_3$	+	$\beta_{11}\eta_1 + \beta_{12}\eta_2$	+ ζ_1
η_2	=	$\gamma_{21}\xi_1 + \gamma_{22}\xi_2 + \gamma_{23}\xi_3$	+	$\beta_{21}\eta_1 + \beta_{22}\eta_2$	+ ζ_2

<u>Equações do Modelo de Medida</u>			
<i>Indicador Exógeno</i>		<i>Construto Exógeno</i>	<i>Erro</i>
X_1	=	$\lambda_{11}^x \xi_1 + \lambda_{12}^x \xi_2 + \lambda_{13}^x \xi_3$	+ δ_1
X_2	=	$\lambda_{21}^x \xi_1 + \lambda_{22}^x \xi_2 + \lambda_{23}^x \xi_3$	+ δ_2
X_3	=	$\lambda_{31}^x \xi_1 + \lambda_{32}^x \xi_2 + \lambda_{33}^x \xi_3$	+ δ_3
X_4	=	$\lambda_{41}^x \xi_1 + \lambda_{42}^x \xi_2 + \lambda_{43}^x \xi_3$	+ δ_4

<i>Indicador Endógeno</i>		<i>Construto Endógeno</i>	<i>Erro</i>
Y_1	=	$\lambda_{11}^y \eta_1 + \lambda_{12}^y \eta_2$	+ ε_1
Y_2	=	$\lambda_{21}^y \eta_1 + \lambda_{22}^y \eta_2$	+ ε_2
Y_3	=	$\lambda_{31}^y \eta_1 + \lambda_{32}^y \eta_2$	+ ε_3
Y_4	=	$\lambda_{41}^y \eta_1 + \lambda_{42}^y \eta_2$	+ ε_4

<u>Correlações das Equações Estruturais Entre Construtos</u>						
<i>Entre Construtos Exógenos (ϕ)</i>				<i>Entre Construtos Endógenos (ψ)</i>		
	ξ_1	ξ_2	ξ_3		η_1	η_2
ξ_1	-			η_1	-	
ξ_2	ϕ_{21}	-		η_2	ψ_{21}	-
ξ_3	ϕ_{31}	ϕ_{32}	-			

<u>Correlações Entre Modelos de Medida (Indicadores)</u>									
<i>Entre Indicadores Exógenos (θ_δ)</i>				<i>Entre Indicadores Endógenos (ϕ_ε)</i>					
	X_1	X_2	X_3	X_4		Y_1	Y_2	Y_3	Y_4
X_1	-				Y_1	-			
X_2	$\phi_{\delta_{21}}$	-			Y_2	$\phi_{\varepsilon_{21}}$	-		
X_3	$\phi_{\delta_{31}}$	$\phi_{\delta_{32}}$	-		Y_3	$\phi_{\varepsilon_{31}}$	$\phi_{\varepsilon_{32}}$	-	
X_4	$\phi_{\delta_{41}}$	$\phi_{\delta_{42}}$	$\phi_{\delta_{43}}$	-	Y_4	$\phi_{\varepsilon_{41}}$	$\phi_{\varepsilon_{42}}$	$\phi_{\varepsilon_{43}}$	-

tab. 3.2

4 O SOFTWARE AMOS

O software AMOS (*Analysis of MOment Structures*) é um programa da empresa SPSS. Ele tem uma interface bastante amigável para a modelagem de equações estruturais. Possui dois métodos de programação: um com linhas de comando (AMOS *basic*) e outro com a interface gráfica (AMOS *Graphics*). Somente esta segunda opção fornece as estimativas graficamente em um diagrama de trajeto, e será o que utilizarei nesta monografia, na versão 4.0. Na fig. 4.1 temos a interface do programa.

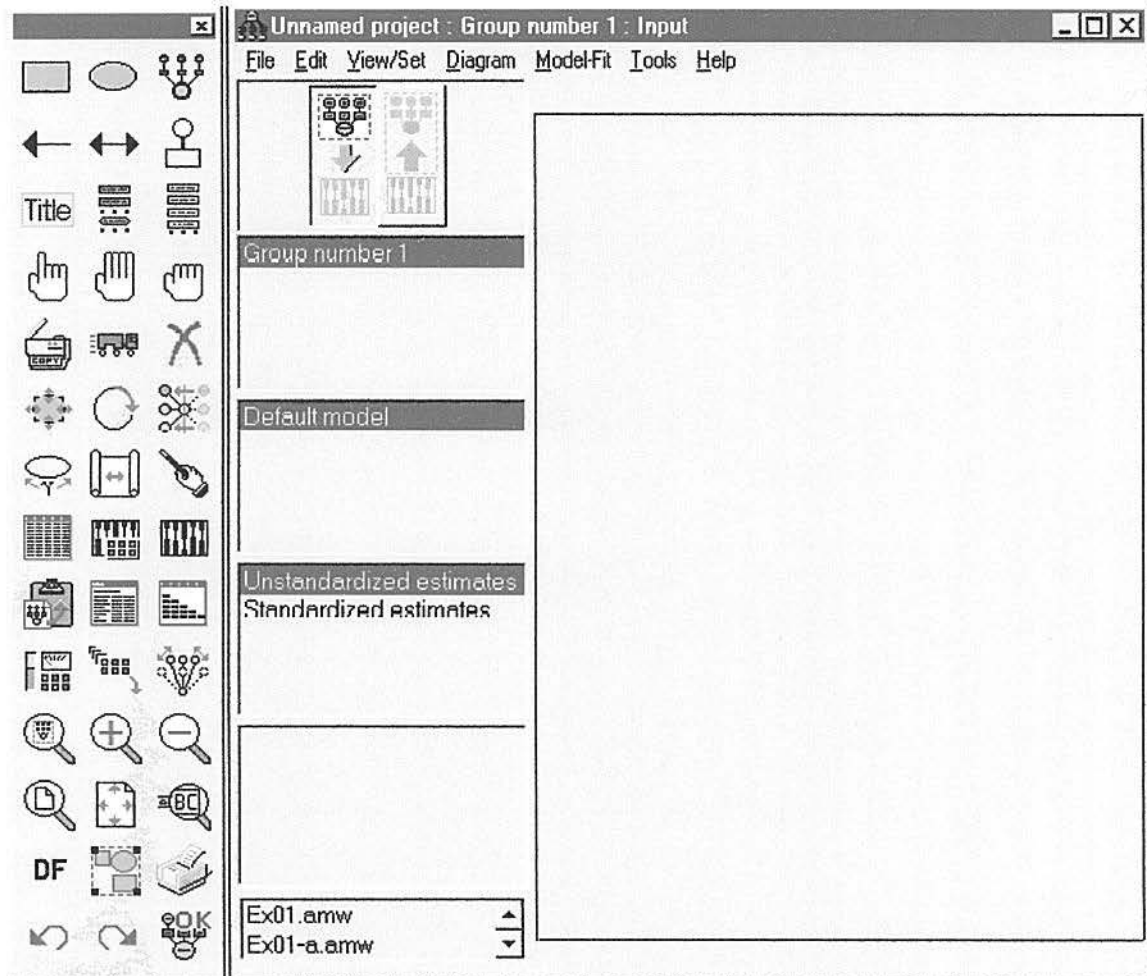



fig. 4.1

Criar os diagramas de trajeto no AMOS é uma tarefa simples. Para colocar as figuras basta clicar nos ícones correspondentes na fig. 4.1 (na parte as esquerda onde estão as ferramentas de desenho) e clicar no espaço vazio, segurando o ponteiro esquerdo do mouse e arrastando até atingir tamanho e forma desejada.

O ícone  fornece pronto o conjunto mostrado na fig. 4.2. A cada novo clique com o mouse, quando este ícone está selecionado, aparece um novo conjunto no fator.








fig. 4.2

Todos os ícones do programa são facilmente identificados; é só passar com o ponteiro do mouse por cima que aparece a função do mesmo. É possível duplicar objetos, mover, selecionar um-a-um ou a todos, manter a simetria, mudar as curvas das correlações,... Basta dedicar um pouco de tempo explorando as ferramentas de desenho. Alguns ícones importantes:

 → Selecionar um objeto.

 → Tirar a seleção de todos os objetos que estão selecionados.

 → Ao clicar em um fator latente ele que os objetos a ele ligados giram 90 graus. Como na fig. 4.3

 → Refletir indicadores para o lado oposto.



→ Reajustar o diagrama ao tamanho da página.



→ Aumentar o tamanho dos objetos selecionados.




fig. 4.3

Para ler os dados no AMOS, basta escolher *data files* no menu *file*. Aparecerá uma tabela como mostra a fig. 4.4., onde vemos que é possível também abrir o banco de dados para examina-lo.

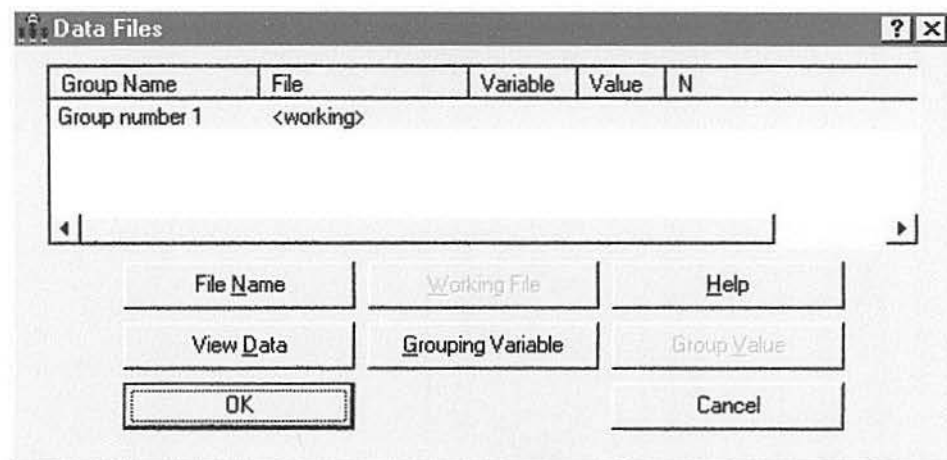


fig. 4.4

A fig. 4.5 mostra os tipos de arquivos compatíveis com o AMOS:

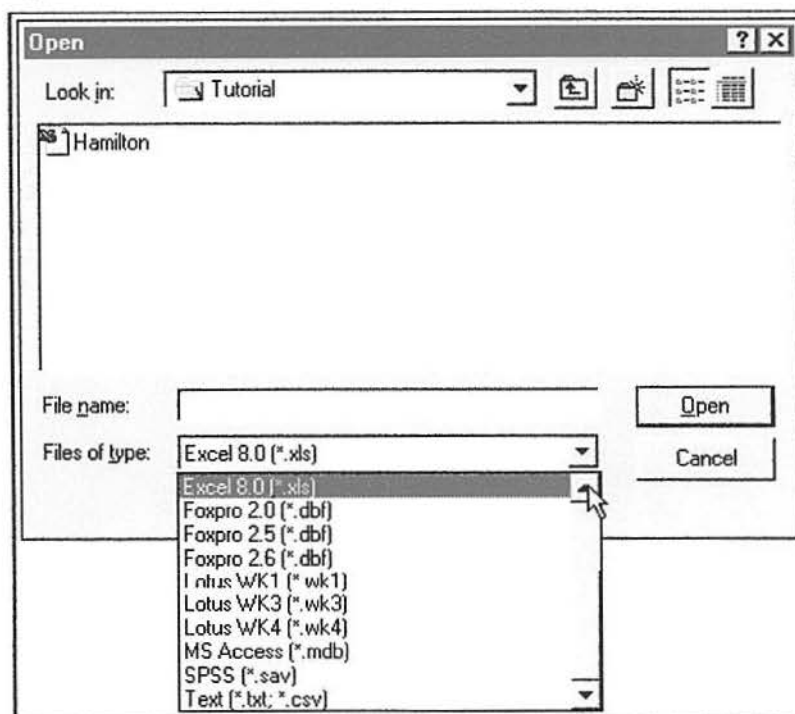


fig. 4.5

Uma vez que o banco de dados foi definido no AMOS, é hora de atribuir as variáveis aos seus respectivos triângulos e círculos. Para fazer isso, clique no menu *view/set*, na opção *Variables in Dataset*. Irá aparecer uma janela como mostra a fig. 4.6.




fig. 4.6

Agora é só clicar na variável e literalmente arrastá-la até a figura correspondente no diagrama de trajeto.

Antes de rodar o programa, é interessante escolher as opções necessárias no menu *View/Set*, na opção *Analysis Properties* (fig. 4.7).

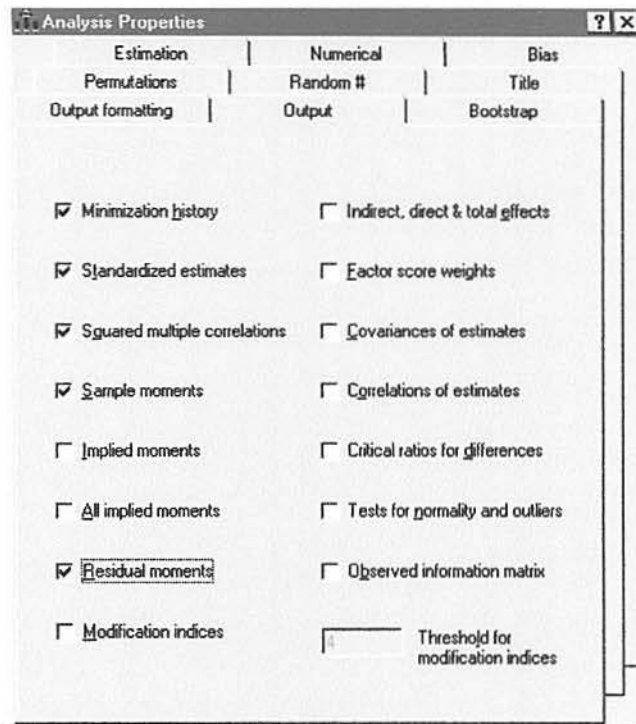



fig. 4.7

Feito isso, podemos executar as análises clicando no ícone .

Para colocar as estimativas no diagrama de trajeto deve-se clicar no botão com a seta vermelha para cima, que aparece na fig.4.8.

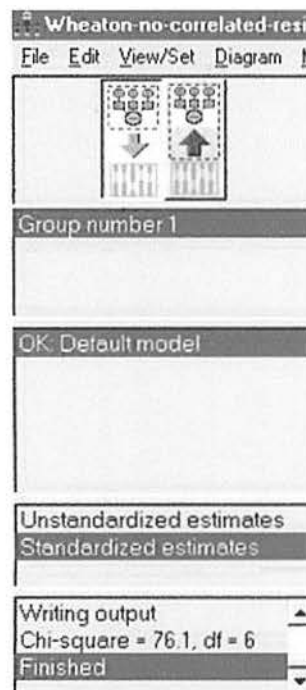


fig. 4.8

Para obter as estimativas dos parâmetros, análise dos resíduos, índices de ajuste e demais opções solicitadas na forma de tabelas, basta clicar no ícone:



Essas tabelas serão apresentadas no decorrer deste trabalho.

5 METODOLOGIA E EXEMPLO DE CFA DE PRIMEIRA ORDEM

Neste capítulo será exposto um teste para a validação fatorial de um construto teórico multidimensional. Esta aplicação testa a hipótese de que o auto-conceito (AC), para pré-adolescentes, é um construto composto por quatro fatores: AC geral (ACG), AC acadêmico (ACA), AC verbal (ACV) e AC matemático (ACM). Esse exemplo foi rodado no AMOS é baseado no livro da Byrne (2001), e é derivado de um modelo hierárquico de AC, proposto por Shavelson, Hubner e Stanton (1976).

O Modelo Hipotético

Primeiramente, é interessante pensar a respeito da plausibilidade dessa estrutura multidimensional de AC para pré-adolescentes. Byrne (2001) diz que há numerosos estudos que dão sustentabilidade a essa hipótese de quatro fatores. Mas, por outro lado, alguns estudos apontam que a questão do AC para crianças e pré-adolescentes é pouco diferenciada, indicando assim que o modelo poderia ser formado por apenas dois fatores, o AC Geral e o AC acadêmico. Há, ainda, alguns estudos que apontam um único fator de AC, o AC geral.

A tarefa aqui então será testar a hipótese original de que AC tem uma estrutura de quatro fatores, compreendendo um componente geral (ACG), um componente acadêmico (ACA), e dois componentes específicos (ACV e ACM) contra as duas hipóteses alternativas: (a) o AC é uma estrutura de dois fatores (ACG e ACA), e (b) o AC é uma estrutura de um único fator, sem a distinção de AC geral e acadêmico.

5.1 Hipótese 1 – AC Estruturado com Quatro Fatores

A priori, o modelo postulado na hipótese 1 especifica que o auto-conceito em pré-adolescentes é uma estrutura formada por quatro fatores: AC geral (ACG), AC acadêmico (ACA), AC verbal (ACV) e AC de matemática (ACM), conforme apresentado esquematicamente na fig. 5.1.

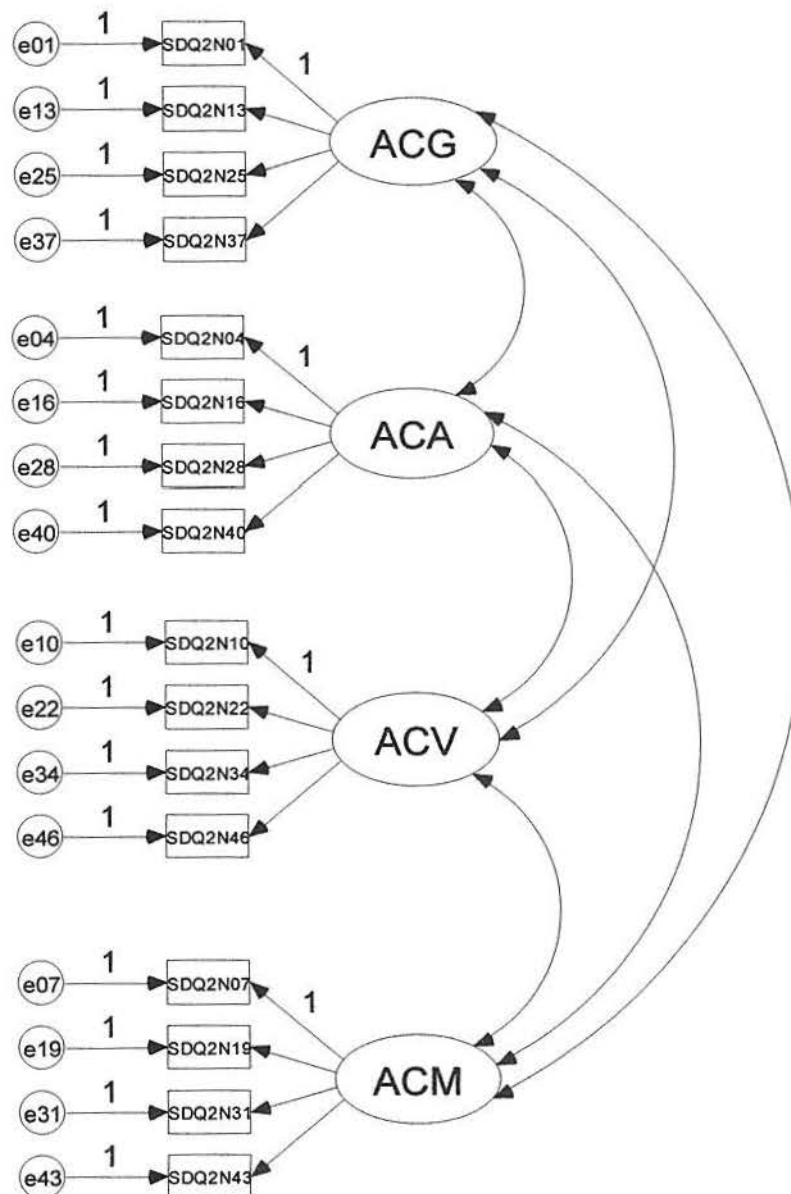


fig. 5.1

Um passo muito importante em SEM, quando se está modelando ou testando uma estrutura, é fazer uma leitura detalhada do diagrama. Saber entender através dos diagramas todas as informações que os símbolos e as variáveis estão oferecendo.

Ao examinar a fig. 5.1, podemos listar as seguintes características:

- 1- Existem 4 fatores latentes, indicados pelas elipses maiores. São: ACG, ACA, ACV e ACM.
- 2- Os quatro fatores são intercorrelacionados, indicados pelas setas bidirecionais;
- 3- Existem 16 variáveis observadas, indicados pelos 16 retângulos (SDQ2N01-SDQ2N43), que são sub-escalas de AC geral, acadêmico, verbal e matemático de um questionário sobre auto imagem.
- 4- As variáveis observadas se ligam aos fatores no seguinte padrão: SDQ2N01- SDQ2N37 ao fator 1; SDQ2N04- SDQ2N40 ao fator 2; SDQ2N10 ao SDQ2N46 ao fator 3 e SDQ2N07- SDQ2N43 ao fator 4.
- 5- Cada variável observada carrega um e apenas um fator.
- 6- Os erros de medida associado a cada variável observada (e01-e43) são não correlacionados.

Condensando as informações acima, pode-se apresentar uma descrição mais formal do modelo hipotético. O modelo especificado a priori nos indica que:

- 1- As respostas de AC podem ser explicadas por quatro fatores: ACG, ACA, ACV e ACM.
- 2- Cada item de medida tem carga não zero no fator de AC que é designada para medir (chamada carga alvo), e carga zero nos demais fatores.
- 3- Os quatro fatores AC, consistentes com a teoria, são correlacionados.
- 4- Erros associados a cada medida são não correlacionados.

O modelo hipotético da fig. 5.1 pode também ser apresentado na forma de matriz. A representação em forma de matriz pode ser bem usual, porque é a forma com a qual os resultados das análises a partir de SEM são geralmente apresentados nos arquivos de *output* dos programas. Na visualização gráfica do AMOS aparecem apenas os parâmetros estimados e seus erros padrões. Já a representação em tabelas traz diversas informações, como a matriz de cargas

fatoriais, a matriz fatorial de variância/covariância e a matriz de variância/covariância dos erros. Com o propósito da identificação do modelo e escala da variável latente, a primeira de cada variável observada em cada jogo congênico de medidas associadas a cada fator de AC tem com carga fatorial definida o valor 1,0. As demais variáveis são livremente estimadas ou fixadas com o valor zero. A tab. 5.1 demonstra isso. Explicando o termo congênico anteriormente citado, um jogo de medidas é dito congênico se cada medida acessa o mesmo construto. Por exemplo, na fig. 5.1 as variáveis observadas SDQ2N01, SDQ2N13, SDQ2N25 e SDQ2N37 são todas as medidas do auto-conceito geral; elas representam um jogo congênico de variáveis indicadoras. Na matriz de covariância/variância todos os parâmetros são livremente estimados. Na matriz dos erros, somente os erros das variâncias são estimados; todos os erros das covariâncias são presumidos como sendo zero.

Medidas Observadas	ACG F1	ACA F2	ACV F3	ACM F4
matriz carga fatorial				
SDQ2N01	1	0	0	0
SDQ2N13	a	0	0	0
SDQ2N25	a	0	0	0
SDQ2N37	a	0	0	0
SDQ2N04	0	1	0	0
SDQ2N16	0	a	0	0
SDQ2N28	0	a	0	0
SDQ2N40	0	a	0	0
SDQ2N10	0	0	1	0
SDQ2N22	0	0	a	0
SDQ2N34	0	0	a	0
SDQ2N46	0	0	a	0
SDQ2N07	0	0	0	1
SDQ2N19	0	0	0	a
SDQ2N31	0	0	0	a
SDQ2N43	0	0	0	a
Matriz fatorial var/cov				
ACG	a			
ACA	a	a		
ACV	a	a	a	
ACM	a	a	a	a

tab. 5.1

a. parâmetro a ser estimado

continuação da tabela 5.1

	Matriz erro variância/Covariância															
	01	13	25	37	04	16	28	40	10	22	34	46	07	19	31	43
SDQ2N01	a															
SDQ2N13	0	a														
SDQ2N25	0	0	a													
SDQ2N37	0	0	0	a												
SDQ2N04	0	0	0	0	a											
SDQ2N16	0	0	0	0	0	a										
SDQ2N28	0	0	0	0	0	0	a									
SDQ2N40	0	0	0	0	0	0	0	a								
SDQ2N10	0	0	0	0	0	0	0	0	a							
SDQ2N22	0	0	0	0	0	0	0	0	0	a						
SDQ2N34	0	0	0	0	0	0	0	0	0	0	a					
SDQ2N46	0	0	0	0	0	0	0	0	0	0	0	a				
SDQ2N07	0	0	0	0	0	0	0	0	0	0	0	0	a			
SDQ2N19	0	0	0	0	0	0	0	0	0	0	0	0	0	a		
SDQ2N31	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a	
SDQ2N43	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	a

a. parâmetro a ser estimado

5.2 Especificação dos Dados

Para esta primeira aplicação, foi utilizada como entrada de dados a matriz de covariância mostrada na tab. 5.2. É proveniente do estudo informado no início do capítulo.

tipo	SDQ2N	07	19	31	43	10	22	34	46	04	16	28	40	01	13	25	37
	n	265	265	265	265	265	265	265	265	265	265	265	265	265	265	265	265
cov	SDQ2N																
cov	07	3,161															
cov	19	1,996	2,859														
cov	31	2,238	1,757	2,457													
cov	43	1,430	1,439	1,428	1,954												
cov	10	0,246	0,348	0,339	0,225	1,322											
cov	22	0,245	0,365	0,370	0,186	0,584	1,186										
cov	34	-0,327	-0,080	-0,123	-0,067	0,510	0,347	2,890									
cov	46	0,212	0,160	0,330	0,346	0,543	0,525	0,452	1,675								
cov	04	0,882	0,725	0,879	0,491	0,593	0,370	0,231	0,347	1,955							
cov	16	1,018	0,998	1,071	0,743	0,581	0,578	0,188	0,471	0,749	1,533						
cov	28	0,975	1,059	1,119	0,744	0,517	0,505	0,079	0,449	0,689	0,944	1,768					
cov	40	0,887	1,035	1,013	0,833	0,637	0,575	0,326	0,602	0,514	0,875	0,925	1,841				
cov	01	0,560	0,496	0,574	0,273	0,350	0,265	0,362	0,378	0,418	0,464	0,375	0,451	1,811			
cov	13	0,512	0,564	0,650	0,472	0,409	0,342	0,461	0,373	0,662	0,552	0,477	0,540	0,681	1,838		
cov	25	0,542	0,347	0,576	0,331	0,252	0,257	0,282	0,174	0,300	0,393	0,347	0,432	0,749	0,502	1,500	
cov	37	0,580	0,475	0,713	0,343	0,323	0,299	0,313	0,224	0,468	0,577	0,539	0,660	0,475	0,653	0,428	1,306

tab. 5.2

5.3 Cálculo das Estimativas

Depois de especificado o modelo e o banco de dados, é possível se proceder as análises. AMOS oferece as saídas em forma gráfica, tabular e textual. A fig. 5.2 mostra, na forma gráfica, os resultados da análise.

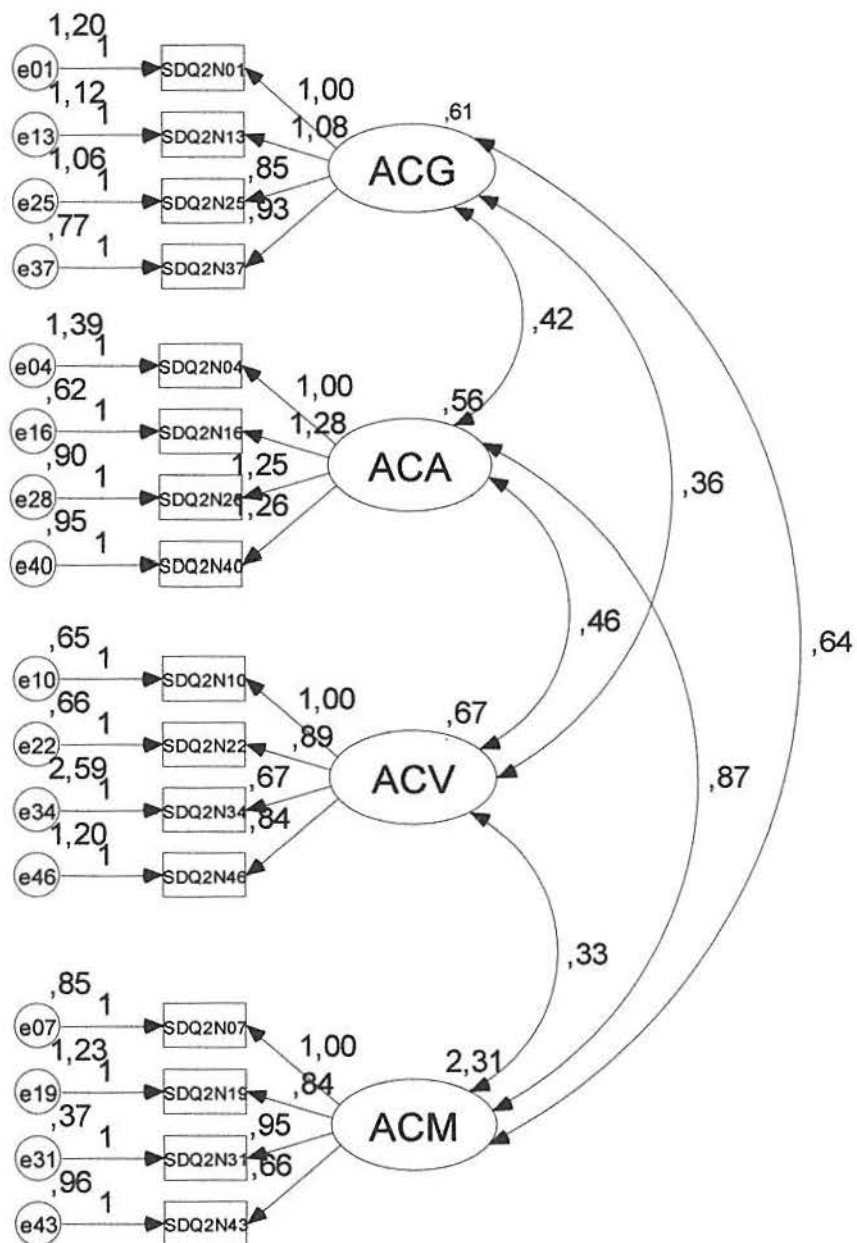


Fig. 5.2

Sumário do Modelo

Your model contains the following variables:

SDQ2N37	observed	endogenous
SDQ2N25	observed	endogenous
SDQ2N13	observed	endogenous
SDQ2N01	observed	endogenous
SDQ2N40	observed	endogenous
SDQ2N28	observed	endogenous
SDQ2N16	observed	endogenous
SDQ2N04	observed	endogenous
SDQ2N46	observed	endogenous
SDQ2N34	observed	endogenous
SDQ2N22	observed	endogenous
SDQ2N10	observed	endogenous
SDQ2N43	observed	endogenous
SDQ2N31	observed	endogenous
SDQ2N19	observed	endogenous
SDQ2N07	observed	endogenous

ACG	unobserved	exogenous
e37	unobserved	exogenous
e25	unobserved	exogenous
e13	unobserved	exogenous
e01	unobserved	exogenous
ACA	unobserved	exogenous
e40	unobserved	exogenous
e28	unobserved	exogenous
e16	unobserved	exogenous
e04	unobserved	exogenous
ACV	unobserved	exogenous
e46	unobserved	exogenous
e34	unobserved	exogenous
e22	unobserved	exogenous
e10	unobserved	exogenous
ACM	unobserved	exogenous
e43	unobserved	exogenous
e31	unobserved	exogenous
e19	unobserved	exogenous
e07	unobserved	exogenous

tab. 5.3

Number of variables in your model:	36
Number of observed variables:	16
Number of unobserved variables:	20
Number of exogenous variables:	20
Number of endogenous variables:	16

continuação da tab. 5.3

A tabela 5.3 é gerada pelo *output* do AMOS. Contém as primeiras informações sobre o modelo.

Consistentes com o diagrama de trajeto mostrado na fig. 5.1, todas as variáveis observadas (isto é, os dados de entrada) operam como variáveis dependentes no modelo. Todos os fatores e termos de erro funcionam como variáveis não observadas e operam como variáveis independentes no modelo. O sumário dos parâmetros mostra, da esquerda para a direita, que temos 32 pesos de regressão, 20 que foram fixados e 12 livres para serem estimados. Os 20 fixados compreendem o peso de regressão de cada fator (o primeiro) mais os 16 termos de erro. Temos 6 covariâncias e 20 variâncias, todas estimadas. No total existem 58 parâmetros, dos quais 38 foram estimados. Dado esse resumo, fica fácil determinar o número de graus de liberdade e conseqüentemente, se o modelo é ou não identificado.

The model is recursive.

Sample size = 265

Computation of degrees of freedom

Number of distinct sample moments = 136

Number of distinct parameters to be estimated = 38

Degrees of freedom = $136 - 38 = 98$

Minimum was achieved

Chi-square = 158,454

Degrees of freedom = 98

Probability level = 0,000

tab. 5.4

A tab. 5.4 mostra um resumo geral do modelo que foi testado. O modelo hipotético é do tipo recursivo, e o tamanho da amostra é de 265. Tem 136 momentos distintos da amostra com os quais são computadas as estimativas do modelo e 38 parâmetros para serem estimados, deixando o modelo com 98 graus de liberdade. Em SEM, os únicos dados com os quais trabalhamos são as variáveis observadas, e neste caso temos 16. Baseado na fórmula $[p(p+1)/2]$, o número 136, referente aos momentos amostrais, é obtido pelo cálculo $[16(17)/2]$. A partir desta informação podemos concluir que temos um modelo *overidentified* com 98 graus de liberdade. A mensagem “*minimum was achieved*” nas últimas linhas desse output inicial assegura que o processo de estimação gerou uma solução admissível. Finalizando, a tab. 5.4 fornece uma rápida visão geral sobre o ajuste do modelo com a estatística qui-quadrado (χ^2). Neste caso o valor foi 158,511, acompanhado de um valor de probabilidade associado de 0,000.

5.4 Avaliação do Modelo

O objetivo primário, modelando equações estruturais, é construir um modelo que descreva adequadamente os dados amostrais. Caso encontrarmos alguns indícios de falta de ajuste, o próximo passo seria detectar a fonte dela. A avaliação o modelo é baseada em critérios severos, e pode vir de diversas perspectivas. Aqui focaremos em particular duas: (a) a adequação dos parâmetros estimados e (b) a adequação do modelo como um todo.

(a) Parâmetros Estimados:

Dentro da questão do ajuste individual dos parâmetros estimados, temos três tópicos importantes:

1. **A plausibilidade:** esse é o passo inicial na avaliação do modelo. Os parâmetros estimados devem apresentar sinal e tamanho corretos, e ser consistentes com a teoria em estudo. Qualquer estimativa que saia da amplitude admissível é um claro indicador de que o modelo está errado, ou a matriz de dados de entrada não traz informação suficiente. Exemplos disso são correlações >1 , variâncias negativas, e matrizes de covariâncias e ou correlações que não são positivas definidas.

2. Erros Padrões Apropriados: Um indicador de ajuste pobre do modelo é a presença de erros padrões que são excessivamente grandes ou pequenos. Por exemplo, se um erro padrão é próximo de zero, a estatística de teste para este parâmetro não pode ser definida (Bentler, 1995 apud Byrne, 2001). Por outro lado, erros padrões muito grandes indicam parâmetros que não podem ser determinados. Como os erros padrões são influenciados pelas unidades de medida de uma variável observada ou medida, assim como a magnitude do parâmetro estimado, nenhum critério definitivo de “pequeno” ou “grande” foi estabelecido.

3. Significância Estatística das Estimativas dos Parâmetros: O teste estatístico aqui usado é do da razão crítica, que é representado pela estimativa do parâmetro dividida pelo seu erro padrão. Ele opera como a estatística z testando se a estimativa é estatisticamente diferente de zero. Baseado no nível de significância 0,05, o teste estatístico precisa ser $|z| > 1.96$ para que a hipótese (de que a estimativa seja igual a zero) possa ser rejeitada. Parâmetros que não foram significantes, com exceção das variâncias, podem ser considerados não importantes ao modelo. Há que se ter um cuidado, pois parâmetros não significativos podem ser um indício de que o tamanho da amostra é muito pequeno Byrne (2001).

A tab. 5.5 mostra as estimativas do AMOS na forma não padronizada. Podemos notar que os resultados são apresentados separadamente, nesta ordem: as cargas fatoriais (listados como pesos de regressão), as covariâncias (neste caso, para fatores apenas) e as variâncias. Na primeira coluna temos os nomes das variáveis observadas e os fatores correspondentes. A segunda coluna mostra o valor estimado do parâmetro, a terceira coluna mostra o erro padrão (S.E.) e a quarta coluna mostra o valor da razão crítica (C.R.). A tab. 5.5 dos valores não padronizados informa que todas as estimativas são razoáveis e estatisticamente significativas; todos os erros padrões não aparentam problemas.

Regression Weights		Estimate	S.E.	C.R.	P	Label
SDQ2N37 <--	ACG	0,933	0,131	7,117	0,000	par-1
SDQ2N25 <--	ACG	0,851	0,132	6,445	0,000	par-2
SDQ2N13 <--	ACG	1,082	0,154	7,031	0,000	par-3
SDQ2N01 <--	ACG	1,000				
SDQ2N40 <--	ACA	1,259	0,157	8,036	0,000	par-4
SDQ2N28 <--	ACA	1,247	0,154	8,084	0,000	par-5
SDQ2N16 <--	ACA	1,279	0,150	8,507	0,000	par-6
SDQ2N04 <--	ACA	1,000				
SDQ2N46 <--	ACV	0,842	0,117	7,213	0,000	par-7
SDQ2N34 <--	ACV	0,670	0,148	4,532	0,000	par-8
SDQ2N22 <--	ACV	0,889	0,103	8,643	0,000	par-9
SDQ2N10 <--	ACV	1,000				
SDQ2N43 <--	ACM	0,655	0,049	13,275	0,000	par-10
SDQ2N31 <--	ACM	0,952	0,049	19,475	0,000	par-11
SDQ2N19 <--	ACM	0,841	0,058	14,476	0,000	par-12
SDQ2N07 <--	ACM	1,000				
Covariances		Estimate	S.E.	C.R.	P	Label
ACA <-->	ACV	0,464	0,079	5,911	0,000	par-13
ACV <-->	ACM	0,331	0,100	3,302	0,001	par-14
ACG <-->	ACV	0,355	0,072	4,938	0,000	par-15
ACG <-->	ACM	0,635	0,118	5,376	0,000	par-16
ACG <-->	ACA	0,415	0,079	5,284	0,000	par-17
ACA <-->	ACM	0,873	0,134	6,508	0,000	par-18
Variances		Estimate	S.E.	C.R.	P	Label
	ACG	0,614	0,138	4,458	0,000	par-19
	ACA	0,561	0,126	4,446	0,000	par-20
	ACV	0,669	0,116	5,741	0,000	par-21
	ACM	2,307	0,273	8,444	0,000	par-22
	e37	0,772	0,088	8,807	0,000	par-23
	e25	1,056	0,107	9,877	0,000	par-24
	e13	1,119	0,124	9,004	0,000	par-25
	e01	1,197	0,126	9,516	0,000	par-26
	e40	0,952	0,095	10,010	0,000	par-27
	e28	0,896	0,090	9,943	0,000	par-28
	e16	0,615	0,068	9,003	0,000	par-29
	e04	1,394	0,128	10,879	0,000	par-30
	e46	1,201	0,118	10,165	0,000	par-31
	e34	2,590	0,233	11,107	0,000	par-32
	e22	0,658	0,075	8,721	0,000	par-33
	e10	0,653	0,082	7,923	0,000	par-34
	e43	0,963	0,092	10,453	0,000	par-35
	e31	0,366	0,065	5,646	0,000	par-36
	e19	1,226	0,121	10,130	0,000	par-37
	e07	0,854	0,100	8,534	0,000	par-38

tab. 5.5

(b) O Modelo:

A tabela anterior (tab. 5.4) mostra um valor geral χ^2 , juntamente com os graus de liberdade e um valor de probabilidade. Entretanto, essa informação tem apenas a intenção de fornecer uma idéia geral sobre o ajuste do modelo. O programa AMOS gera muitas outras estatísticas de ajuste que devem ser examinadas. A seguir, quatro importantes aspectos sobre ajustes de modelos hipotéticos:

1. O Processo de Ajuste do Modelo

Como citado anteriormente, nos primeiros capítulos, o objetivo primário do pesquisador é confirmar um bom ajuste entre o modelo criado e os dados amostrais. Em outras palavras, o pesquisador especifica um modelo e então usa os dados amostrais para testá-lo.

Dando uma idéia mais formal sobre esse processo de ajuste: Suponha que S representa a matriz amostral de covariância (dos escores das variáveis observadas), Σ a matriz populacional de covariância e θ um vetor que compreende os parâmetros do modelo. Então $\Sigma(\theta)$ representa a matriz de covariância restringida pelo modelo (isto é, a estrutura especificada pelo modelo hipotético). Em SEM, a hipótese nula (H_0) a ser testada é que o modelo postulado condiz com a população (isto é, $\Sigma = \Sigma(\theta)$). O pesquisador espera não rejeitar H_0 .

2. Processo de Estimação

(ver Apêndice B)

Em SEM, o primeiro foco no processo de estimação é o rendimento nos valores dos parâmetros com relação à discrepância (resíduos) entre a matriz de covariância amostral S e a matriz de covariância populacional, implicando que o modelo $[\Sigma(\theta)]$ é mínimo. Esse objetivo é alcançado pela minimização da função discrepância, $F[S, \Sigma(\theta)]$, tal que o mínimo valor (F_{\min}) reflete o ponto no processo de estimação onde a discrepância entre S e $\Sigma(\theta)$ é menor [$S - \Sigma(\theta) = \text{mínimo}$]. F_{\min} serve como uma medida da extensão de quanto S difere de $\Sigma(\theta)$.

3. Estatísticas de Ajuste do Modelo (“Goodness-of-Fit”)

(ver Apêndice C)

Retornando a aplicação 1, a tab. 5.6 foi tirada diretamente do *output* do AMOS. Essa tabela mostra estatísticas de ajuste do modelo. Podemos notar que as informações são dadas para três modelos, que aparecem um em cada linha. A primeira linha enfoca o modelo hipotético que está sendo testado (*default model*), a segunda o modelo saturado e a terceira o modelo de independência.

Byrne (2001) explica esses últimos dois modelos fazendo um comparativo, sugerindo supor que os três modelos representam pontos contínuos, com o modelo de independência em uma extremidade, o modelo saturado em outra extremidade, e o modelo hipotético em algum lugar entre eles. No modelo de independência existe a completa independência para todas as variáveis no modelo (onde todas as correlações entre as variáveis são zero) e é o mais restritivo. Já no modelo saturado, por outro lado, o número de parâmetros estimados é igual ao número de pontos de dados (i.e. variâncias e covariâncias das variáveis observadas, como no caso do modelo just-identified), e é o menos restritivo.

Agora explicarei as estatísticas de ajuste para o modelo hipotético apenas, contidas na tab. 5.6 conforme Byrne (2001), as fórmulas para cada estatística de ajuste podem ser obtidas em Arbuckle & Wothke (1999) e no Apêndice C.

Observando a tab. 5.6, as primeiras informações do modelo hipotético são dadas pelas colunas NPAR (número de parâmetros), CMIN (discrepância mínima), DF (graus de liberdade), P (valor de probabilidade), e CMIN/DF. O valor de 158,454, em CMIN, representa a discrepância entre a matriz irrestrita de covariância amostral S e a matriz restringida de covariância $\Sigma(\theta)$, e, na essência, representa o teste estatístico razão de verossimilhança, geralmente expressada como a estatística qui-quadrado (χ^2). Essa estatística é igual a $(N-1) F_{\min}$, onde N é o tamanho da amostra. Em grandes amostras, é distribuída como χ^2 central com graus de liberdade igual a $[(1/2)p(p+1) - t]$, onde p é o número de variáveis observadas, e t é o número de parâmetros a serem estimados. Em geral, $H_0: \Sigma = \Sigma(\theta)$ é equivalente a testar a hipótese de que $\Sigma - \Sigma(\theta) = 0$; o teste χ^2 então testa, simultaneamente, a extensão com que todos os resíduos em $\Sigma - \Sigma(\theta)$ são zero. Formulada ligeiramente diferente, a hipótese nula (H_0) postula que a especificação das cargas fatoriais, variâncias e covariâncias fatoriais, e as variâncias dos erros do modelo

Summary of models

Model	NPAR	CMIN	DF	P	CMIN/DF
Default model	38	158,454	98	0,000	1,617
Saturated model	136	0,000	0		
Independence model	16	1696,861	120	0,000	14,141

Model	RMR	GFI	AGFI	PGFI
Default model	0,103	0,933	0,906	0,672
Saturated model	0,000	1,000		
Independence model	0,628	0,379	0,296	0,334

Model	DELTA1 NFI	RHO1 RFI	DELTA2 IFI	RHO2 TLI	CFI
Default model	0,907	0,886	0,962	0,953	0,962
Saturated model	1,000		1,000		1,000
Independence model	0,000	0,000	0,000	0,000	0,000

Model	PRATIO	PNFI	PCFI
Default model	0,817	0,740	0,785
Saturated model	0,000	0,000	0,000
Independence model	1,000	0,000	0,000

Model	NCP	LO 90	HI 90
Default model	60,454	29,934	98,886
Saturated model	0,000	0,000	0,000
Independence model	1576,861	1447,420	1713,699

Model	FMIN	F0	LO 90	HI 90
Default model	0,600	0,229	0,113	0,375
Saturated model	0,000	0,000	0,000	0,000
Independence model	6,428	5,973	5,483	6,491

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	0,048	0,034	0,062	0,563
Independence model	0,223	0,214	0,233	0,000

Model	AIC	BCC	BIC	CAIC
Default model	234,454	239,685	475,842	408,483
Saturated model	272,000	290,721	1135,915	894,843
Independence model	1728,861	1731,064	1830,499	1802,137

Model	ECVI	LO 90	HI 90	MECVI
Default model	0,888	0,772	1,034	0,908
Saturated model	1,030	1,030	1,030	1,101
Independence model	6,549	6,058	7,067	6,557

Model	HOELTER .05	HOELTER .01
Default model	204	223
Independence model	23	25

tab 5.6

em estudo são válidos; o χ^2 simultaneamente testa a extensão com que essas especificações são verdadeiras. O valor de probabilidade associado com o χ^2 representa a verossimilhança de se obter um valor χ^2 que exceda o valor χ^2 quando H_0 é verdadeira. Assim, quanto maior o valor de probabilidade associado com o χ^2 melhor é o ajuste entre o modelo hipotético (sob H_0) e os dados (Bollen, 1989 apud Byrne, 2001).

O teste da aplicação 1, onde H_0 : o AC é uma estrutura de quatro fatores; gerou um $\chi^2 = 158,454$ com 98 graus de liberdade e probabilidade $p < 0,001$ que sugere que o ajuste dos dados com o modelo hipotético não está inteiramente adequado. Interpretado literalmente, o teste indica que, com os presentes dados, a hipótese referente às relações de AC, como sumarizadas no modelo, representa um evento improvável (ocorrendo menos de uma vez em mil, sob a hipótese nula) e deveria ser rejeitada.

Entretanto, a sensibilidade do teste da razão de verossimilhança ao tamanho da amostra e sua base na distribuição central χ^2 , a qual assume que o modelo se ajusta perfeitamente a população (i.e., H_0 é verdadeira) conduzem a problemas de ajuste que serão descritos agora. Como a estatística χ^2 é igual a $(N-1)F_{\min}$, este valor tende a ser substancial quando o modelo não é sustentado e a amostra é grande. A análise de estruturas de covariâncias é baseada em teorias com grandes amostras, as quais são críticas de se obter estimativas precisas dos parâmetros. Assim, conseguir modelos hipotéticos bem ajustados onde os valores do χ^2 são próximos aos graus de liberdade é muito raro em SEM na maioria das pesquisas empíricas. É mais comum encontrar um valor de χ^2 grande relativo aos graus de liberdade, indicando a necessidade de uma modificação no modelo para se alcançar um ajuste melhor. Por isso o resultado ruim do χ^2 gerado pelo modelo que está sendo testado não é uma surpresa.

Para contornar as limitações do teste χ^2 os pesquisadores desenvolveram os índices de *goodness-of-fit* para avaliar o modelo, que serão apresentados a seguir, conforme constam na tab. 5.6 (Ver Apêndice C).

- CMIN: é o valor mínimo de discrepância.
- CMIN/DF: é a razão χ^2 /graus de liberdade, que deve ser ≤ 5 .
- RMR: *root mean square residual*; representa o valor residual médio derivado do ajuste da matriz de variância-covariância do modelo hipotético $\Sigma(\theta)$ para matriz de matriz de variância-covariância dos dados amostrais S . Devido ao fato destes resíduos serem relativos aos tamanhos das variâncias e covariâncias observadas eles são difíceis de interpretar. O RMR padronizado representa o valor médio de

todos os resíduos padronizados, e tem amplitude de zero a 1. Para um modelo bem ajustado, o valor deve ser pequeno, 0,05 ou menos. O valor 0,103 apresentado na tabela referente ao RMR é não padronizado. O valor padronizado não mostrado na tabela é 0,0479 e representa a discrepância média entre as matrizes de correlação observada e a hipotética.

- GFI: *goodness-of-fit index*; é a medida da quantidade relativa de variância e covariância em S que é conjuntamente explicada por Σ . O índice tem amplitude de zero a 1, sendo que valores perto de 1 são indicativos de bom ajuste. Na tab. 5.6 referente ao exemplo deu 0,933; sinal de bom ajuste.
- AGFI: esse índice difere do GFI apenas pelo fato de ser ajustado pelo número de graus de liberdade do modelo especificado. Ele “penaliza” a inclusão adicional de um parâmetro. No caso 0,906; também indício de bom ajuste.
- PGFI: *parsimony goodness-of-fit index*; esse índice leva em conta a complexidade (isto é, o número de parâmetros estimados) do modelo hipotético na avaliação geral do modelo. Geralmente apresenta valor baixo. O encontrado no nosso modelo é 0,672, que parece consistente com os índices anteriores.

Os próximos índices de ajuste podem ser classificados como incrementais ou comparativos. Assim como em GFI e AGFI, os índices incrementais de ajuste são baseados na comparação de modelos hipotéticos contra algum padrão.

- NFI: *normed fit index*; varia de zero a 1, e é derivado da comparação entre o modelo hipotético e o modelo de independência. Valor acima $> 0,90$ indica bom ajuste do modelo. No exemplo da tab. 5.6, o valor é 0,907.
- CFI: *comparative fit index*; como NFI apresentou uma certa tendência de subestimar o ajuste em amostras pequenas, ele foi corrigido e criado o índice CFI para levar em conta o tamanho da amostra. A interpretação é a mesma do NFI. No exemplo da tab. 5.6, o valor é 0,962. Os dois índices indicam bom ajuste do modelo hipotético aos dados.
- RFI: *relative fit index*; também variação de zero a 1, com valores perto de 0,95 indicando um bom ajuste
- IFI: *incremental fit index*; é uma derivação do NFI, com a computação basicamente a mesma, com a diferença do número de graus de liberdade utilizados.

No caso encontramos o valor 0,962, o mesmo encontrado no CFI, refletindo que o modelo está bem ajustado.

- TLI: *Tucker-Lewis index*; também com valores entre zero e um, e valores próximos a 0,95 (para amostras grandes) indicando bom ajuste (na tab. 5.6 é 0,953).

Os índices a seguir referem-se ao assunto da parcimônia (*parsimony*). Uma medida de ajuste parcimônia pode ser entendida como uma medida geral de *goodness-of-fit* representando o grau de ajuste do modelo por coeficiente estimado. O objetivo não é minimizar o número de coeficientes ou maximizar o ajuste geral, mas sim maximizar a quantidade de ajuste por coeficiente estimado e evitar o “super-ajustamento” com coeficientes adicionais que trazem poucos ganhos no ajuste do modelo (Hair, 1998).

- PRATIO: *parsimony ratio*; índice da razão de parcimônia inicial.
- PNFI: índice computado de forma relativa ao índice NFI. Na tab. 5.6 PNFI=0,740. Novamente cai dentro do intervalo de valores esperados.
- PCFI: índice computado de forma relativa ao índice CFI. . Na tab. 5.6 PCFI=0,785.

Os índices abaixo fornecem uma estimação de parâmetro com não-centralidade (NCP- *noncentrality parameter*). Na discussão inicial sobre a estatística χ^2 o foco foi a extensão com que o modelo era sustentável e não podia ser rejeitado. Agora vamos analisar o que acontece quando o modelo hipotético está incorreto [i.e. $\Sigma \neq \Sigma(\theta)$]. Nessas circunstâncias, o χ^2 tem uma distribuição não central, com um parâmetro de não centralidade λ , que é fixado com graus de liberdade associados, e pode ser denotado como $\chi^2_{(gl,\lambda)}$. Ele funciona como uma medida da discrepância entre Σ e $\Sigma(\theta)$ e pode ser considerado como o “*badness-of-fit*” da população. Assim, quanto mais alta a discrepância entre Σ e $\Sigma(\theta)$ maior o valor de λ . Assim fica fácil de ver que a estatística central χ^2 é um caso especial da distribuição χ^2 não central, onde $\lambda=0$. Com o objetivo de estabelecer a precisão da estimativa do parâmetro de não centralidade, é utilizado intervalo de confiança. Voltando a tab.5.6.

- NCP: nosso modelo tem um parâmetro de não centralidade de 60,454. Esse valor representa o χ^2 menos seus graus de liberdade (158,454 – 98). O

intervalo de confiança indica que com 90% de confiança o intervalo (29,934 ; 98,886) contém verdadeiro valor (populacional) do parâmetro de não centralidade (λ).

- FMIN: Função de discrepância Mínima;
- FO: Discrepância populacional, e LO90 e HI90 fornecem os limites inferior e superior, respectivamente, de um intervalo de 90% de confiança em torno de FO.
- RMSEA: reconhecido como um dos critérios mais informativos com relação à modelagem em estruturas de covariâncias. O RMSEA leva em conta o erro de aproximação na população e faz a questão “quão bem o modelo poderia, com desconhecidos mas otimizados valores de parâmetros escolhidos, se ajustar a matriz de covariância populacional, se ela estivesse disponível?”. Essa discrepância medida por RMSEA, é expressa por graus de liberdade, sendo sensível ao número de parâmetros estimados no modelo (i.e., a complexidade do modelo); valores menores que 0,05 indicam bom ajuste, e valores maiores que 0,08 representam erros razoáveis na aproximação com a população. Valores entre 0,08 e 0,10 indicam um ajuste medíocre, e maiores que 0,10, um ajuste pobre. RMSEA de 0,06 pode ser um indicativo de bom ajuste entre o modelo hipotético e os dados observados, já que o RMSEA e o TLI tendem a rejeitar modelos verdadeiros em função de a amostra ser pequena. Todavia são critérios baseados no julgamento subjetivo e não podem ser considerados infalíveis. O AMOS mostra também um intervalo de 90% de confiança para o valor de RMSEA=0,048 (bom indicativo de ajuste); IC_{90%}(0,034; 0,062). Os intervalos de confiança (I.C.) são muito mais informativos que as estimativas pontuais apresentadas sem seu I.C., que não refletem a imprecisão da estimativa.
- PCLOSE: em adição ao I.C. de RMSEA, o índice PCLOSE testa a proximidade do ajuste, ou seja, testa se o valor RMSEA é “bom” (mais especificamente, se é $< 0,05$). Já que ele testa a $H_0: RMSEA \leq 0,05$, deve ser maior que 0,05 para rejeitar esta hipótese. Ideal que seja $> 0,50$. Na tab. 5.6 o PCLOSE é 0,563. Mais uma demonstração que o modelo hipotético é bom.

- AIC: *Akaike's Information Criteria*; critério que utiliza o assunto da parcimônia na avaliação do modelo, levando em conta o número de parâmetros estimados. É usado quando estamos comparando dois ou mais modelos, e o que possuir menor AIC é que apresenta melhor ajuste do modelo hipotético.
- CAIC: Descobertas recentes tem mostrado que o AIC apresenta estimativas assintoticamente inconsistentes, por levar em conta apenas os graus de liberdade, e não o tamanho da amostra. Por isso, Bozdagan (1987) propôs o índice CAIC, que leva em conta o tamanho da amostra e produz estimativas mais consistentes. Ele opera da mesma maneira que o AIC.
- BCC: *Browne-Cudeck Criterion*; funciona da mesma maneira que o AIC e CAIC com diferença que impõem grandes penalidades para a complexidade do modelo.
- BIV: *Bayes Information Criterion*; opera como BCC, AIC e CAIC. Olhando a tab. 5.6, observamos que esses quatro índices são substancialmente menores do que o dos modelos saturado e de independência.
- ECVI: *Expected Cross-Validation Index*; esse índice fornece uma medida da discrepância entre a matriz de covariância ajustada na amostra analisada, e a matriz de covariância esperada que poderia ser obtida em outra amostra de mesmo tamanho. No nosso exemplo, do modelo hipotético de quatro fatores, o valor ECVI é 0,888. Comparando com o do modelo saturado (1,030) e o do modelo de independência (6,549), podemos concluir que o modelo hipotético apresenta o melhor ajuste aos dados, por ter o menor ECVI. Constatação reforçada pelo intervalo de confiança (0,772; 1,034), que fica praticamente fora do menor valor de ECVI entre os dois modelos comparados (saturado e de independência).
- CN: *Critical N*; chamado índices de Hoelter 0,05 e 0,01. Neste critério, o foco é a adequação do tamanho da amostra, e não o ajustado modelo. A proposta deste índice é uma estimativa do tamanho da amostra que seja suficientemente adequado ao ajuste o modelo para o teste χ^2 . Um valor que exceda 200 é indicativo que o modelo representa adequadamente os dados amostrais. Na tab. 5.6, ambos os índices 0,05 e 0,01 são maiores que 200 para

o modelo hipotético (204 e 223, respectivamente). Como a amostra do exemplo o N=265, o modelo é satisfatório de acordo com esses índices.

Neste último tópico foram abordados todos os índices de ajuste fornecidos pelo AMOS. Mas certamente não precisam ser todos reportados na análise de um modelo. Eles servem para dar uma idéia de quão bem o modelo hipotético se ajusta com os dados amostrais. Agora qual índice escolher para reportar não é uma tarefa simples. Esses índices operam diferentemente de acordo com o tamanho da amostra, método de estimação, complexidade do modelo, e/ou violações das suposições de normalidade multivariada e independência variável.

Byrne (2001) conclui essa parte de avaliação do modelo com um importante lembrete: os índices de ajuste global, sozinhos, não possibilitam saber tudo o que precisamos conhecer sobre o modelo para podermos julgar sua adequação. Mesmo com a natureza problemática da estatística χ^2 , utilizar exclusivamente os índices de ajuste é inaceitável. Na verdade, esses índices não dão garantia de que o modelo é usual, porque é possível um modelo apresentar bom ajuste e ainda assim estar especificado de forma incorreta. Os índices de ajuste fornecem informações unicamente sobre a falta de ajuste do modelo (*lack of fit*). Mais importante, eles podem não refletir a extensão da plausibilidade do modelo. Esse julgamento é de responsabilidade do pesquisador. Assim, podemos concluir que a avaliação da adequação do modelo deve ser baseada em múltiplos critérios, que envolvem considerações teóricas, estatísticas e práticas.

4. Falta de Especificação do Modelo

Com os dados obtidos na avaliação do modelo, podemos concluir que o nosso modelo hipotético com quatro fatores se ajusta bem aos dados. O próximo passo é determinar qualquer área que possa ter falta de ajuste. Existem dois campos que podem ser explorados no AMOS com o objetivo de identificar a chamada falta de especificação (*misspecification*) – (a) os resíduos padronizados e (b) os índices de modificação. Eles podem ser solicitados pelo ícone “*Analysis Properties*”, na janela *output*. Existem outras opções, mas nos deteremos nessas.

(a) Resíduos: Relembrando que a essência em SEM é determinar o ajuste entre a matriz de covariância restrita $[\Sigma(\theta)]$, implícita pelo modelo criado, e a matriz de covariância amostral (*S*). Qualquer discrepância entre as duas é capturada pela matriz residual de covariância. Cada elemento nesta matriz residual representa a discrepância entre as

covariâncias em $\Sigma(\theta)$ e aquelas em S (i.e., $\Sigma(\theta) - S$). Isso é como dizer que há um resíduo para cada par de variáveis observadas. No exemplo, a matriz residual contém $[(16 \times 17)/2]=136$ elementos. AMOS pode apresentar os resíduos na forma padronizada ou não. Mas como eles são dependentes da unidade de medida das variáveis aleatórias podem ser difíceis de ser interpretados, na forma não padronizada. Por isso os resíduos padronizados são tipicamente examinados. Os resíduos padronizados 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 (i.e., $\Sigma(\theta) - S = 0$). Valores maiores que 2,58 são considerados grandes. Examinando a tab. 5.7, dos resíduos padronizados, observamos que apenas um excede o valor 2,58. Esse valor residual -2,941 representa a covariância entre as variáveis observadas SDQ2N07 e SDQ2N34. A partir desta informação podemos concluir que a única discrepância estatisticamente significativa é a covariância entre essas duas variáveis.

Standardized Residual Covariances							
	SDQ2N07	SDQ2N19	SDQ2N31	SDQ2N43	SDQ2N10	SDQ2N22	SDQ2N34
SDQ2N07	0,000						
SDQ2N19	0,250	0,000					
SDQ2N31	0,189	-0,457	0,000				
SDQ2N43	-0,458	1,012	-0,072	0,000			
SDQ2N10	-0,664	0,578	0,215	0,083	-0,000		
SDQ2N22	-0,406	1,030	0,847	-0,070	-0,122	0,000	
SDQ2N34	-2,941	-1,503	-2,030	-1,448	0,502	-0,440	0,000
SDQ2N46	-0,466	-0,548	0,515	1,461	-0,207	0,265	0,543
SDQ2N04	0,056	-0,061	0,332	-0,647	1,251	-0,438	-0,542
SDQ2N16	-0,647	0,418	0,060	0,099	-0,131	0,567	-1,590
SDQ2N28	-0,707	0,961	0,578	0,252	-0,612	-0,098	-2,187
SDQ2N40	-1,298	0,727	-0,228	0,904	0,515	0,578	-0,454
SDQ2N01	-0,495	-0,268	-0,229	-1,209	-0,054	-0,550	0,876
SDQ2N13	-1,138	-0,099	-0,034	0,178	0,249	0,003	1,425
SDQ2N25	0,011	-0,825	0,502	-0,216	-0,566	-0,138	0,618
SDQ2N37	-0,098	-0,193	1,286	-0,449	-0,101	0,056	0,756
	SDQ2N46	SDQ2N04	SDQ2N16	SDQ2N28	SDQ2N40	SDQ2N01	SDQ2N13
SDQ2N46	0,000						
SDQ2N04	-0,385	0,000					
SDQ2N16	-0,279	0,272	0,000				
SDQ2N28	-0,348	-0,087	0,428	0,000			
SDQ2N40	0,980	-1,545	-0,241	0,359	0,000		
SDQ2N01	0,725	0,025	-0,620	-1,242	-0,611	-0,000	
SDQ2N13	0,448	1,775	-0,205	-0,714	-0,214	0,140	0,000
SDQ2N25	-0,815	-0,493	-0,601	-0,897	-0,118	2,132	-0,584
SDQ2N37	-0,595	0,798	0,887	0,574	1,725	-0,966	0,325
	SDQ2N25	SDQ2N37					
SDQ2N25	0,000						
SDQ2N37	-0,648	0,000					

tab.5.7

(b) Índices de Modificação: Refletem a extensão com que o modelo hipotético está adequadamente descrito. A evidência de falta de ajuste é capturada pelos índices de modificação (MI), que podem ser vistos como a estatística χ^2 com um grau de liberdade. Para cada parâmetro especificado, fixo, o AMOS fornece um MI, valor que representa a queda esperada no valor do χ^2 geral se o parâmetro não fosse mais fixo, e sim livremente estimável, numa próxima vez em que o programa fosse executado. Todos os parâmetros livremente estimados automaticamente têm valores MI iguais a zero. Associado com cada MI existe uma estatística EPC (*expected parameter change*), que aparece na tabela chamada “PAR Change”. EPC representa a mudança predita do parâmetro estimado, nas direções positiva ou negativa, para cada parâmetro fixo no modelo e uma informação importante referente à sensibilidade na avaliação do ajuste para qualquer reparametrização do modelo. Mas como os EPCs são sensíveis a maneira como as variáveis ou fatores estão escalados ou identificados, seu valores absolutos são difíceis de interpretar. Os MIs e os EPCs para nosso exemplo são mostrados na tab. 5.8.

Os valores MIs e os EPCs são primeiramente apresentados para possíveis covariâncias, depois para os pesos de regressão. Lembrando que os únicos parâmetros do modelo para os quais os MIs são aplicáveis são esses que foram fixados com valor zero. Assim, não aparecem valores na tab. 5.8 para a coluna “*variances*”, já que todos os parâmetros representando as variâncias (fatores e erros de medida) são livremente estimados.

Os parâmetros da tab. 5.8, na parte das covariâncias, os únicos que fazem algum sentido substancial são aqueles que estão representando erros de covariância. Apenas o parâmetro representando a covariância entre o e25 e o e01 é relevante. Apesar disso, o valor de MI é aproximadamente 13,499 com EPC de 0,285, especialmente por estarem relacionados a um erro de covariância, eles podem ser considerados pouco preocupantes. Na parte “*Regression Weights*”, Byrne (2001) considerou que apenas dois fazem algum sentido importante: SDQN207←ACV e SDQN234←ACM. Ambos os parâmetros representam cargas cruzadas, conforme pode ser notado na fig. 5.1. Entretanto, os MIs e seus EPCs não são relevantes para serem inclusos num próximo modelo reespecificado.

Modification Indices

Covariances:	M.I.	Par Change
e31 <-----> e19	8,948	-0,167
e43 <-----> e19	7,491	0,201
e34 <-----> ACG	8,194	0,225
e46 <-----> e43	4,862	0,159
e04 <-----> e10	5,671	0,162
e40 <-----> e43	5,646	0,154
e40 <-----> e04	8,591	-0,224
e13 <-----> e04	6,394	0,217
e25 <-----> e01	13,499	0,285
e37 <-----> ACA	6,924	0,079
e37 <-----> e31	4,044	0,097
e37 <-----> e40	5,314	0,141

Variations:	M.I.	Par Change
Regression Weights:		
SDQ2N07 <----- ACV	7,395	-0,241
SDQ2N07 <---- SDQ2N34	4,884	-0,083
SDQ2N07 <---- SDQ2N28	5,408	-0,112
SDQ2N07 <---- SDQ2N40	6,294	-0,118
SDQ2N31 <---- SDQ2N37	5,949	0,107
SDQ2N10 <---- SDQ2N04	4,034	0,081
SDQ2N34 <----- ACM	6,324	-0,173
SDQ2N34 <---- SDQ2N07	7,692	-0,157
SDQ2N34 <---- SDQ2N31	5,317	-0,148
SDQ2N34 <---- SDQ2N28	4,897	-0,167
SDQ2N04 <---- SDQ2N13	5,011	0,123
SDQ2N40 <---- SDQ2N04	5,878	-0,110
SDQ2N01 <---- SDQ2N25	8,659	0,173
SDQ2N13 <---- SDQ2N04	4,224	0,104
SDQ2N25 <---- SDQ2N01	7,927	0,140
SDQ2N37 <---- SDQ2N40	5,499	0,103

tab. 5.8

5.5 Análise “Post Hoc”

Agora é o momento de o pesquisador escolher se reespecifica e estima um novo modelo, ou não. Caso parta em busca de um novo modelo, é importante que realize a análise em modo exploratório, e não confirmatório. Em outras palavras, uma vez que o modelo CFA hipotético foi rejeitado, por exemplo, isso termina com o caráter confirmatório da análise. Entretanto, os procedimentos CFA serão utilizados novamente a cada reespecificação e reestimação do modelo. A análise *post hoc* pode ser entendida como a procura da melhor especificação.

A decisão entre proceder ou não a procura pela especificação é dupla. Primeiramente o pesquisador precisa determinar se a estimação dos parâmetros focados é substancialmente significativa. Caso seja, não fará sentido deixar livre o parâmetro que tem o maior valor de MI, podendo então desconsiderá-lo. Segundo coisa a se considerar é a possibilidade de que o modelo reespecificado torne o modelo super-ajustado. Isso está ligado ao assunto do conhecimento de quando parar de ajustar o modelo. De saber quanto ajuste é o bastante, sem ser ajuste demais... Em geral, um modelo super-ajustado envolve a especificação de parâmetros adicionais no modelo depois de ter sido determinado um critério que reflete minimamente um ajuste adequado. Por exemplo, um modelo super-ajustado pode resultar, a partir da inclusão de parâmetros adicionais, em (a) uma frágil sensibilidade em representar efeitos fracos, que provavelmente não são replicáveis, (b) conduzir a uma significativa inflação dos erros padrões, e (c) influenciar parâmetros primários no modelo.

Após todo esse processo de avaliação do modelo, podemos concluir que o modelo hipotético de quatro fatores representa adequadamente o auto-conceito de pré-adolescentes, devido:

- À plausibilidade e significância estatística de todos os parâmetros estimados;
- Ao bom ajuste observado, com destaque aos valores de CFI (0,962), e RMSEA (0,048);
- À ausência de qualquer evidência de falta de ajuste do modelo, indicando que a inclusão adicional de qualquer parâmetro poderia resultar em um modelo super-ajustado.

5.6 Hipótese 2: AC Estruturado com Dois Fatores

O modelo a ser testado aqui postula a priori que o AC é uma estrutura de dois fatores, contendo um fator geral (ACG) e outro acadêmico (ACA). As mesmas quatro variáveis observadas na estrutura com quatro fatores estão associadas ao ACG, porém aqui as demais variáveis observadas pertencem ao fator ACA. Isso faz sentido, pois os demais fatores, tirando o geral, eram acadêmicos, mas específicos. Esse postulado aqui é um fator acadêmico geral. A fig. 5.3 esquematiza esta estrutura.

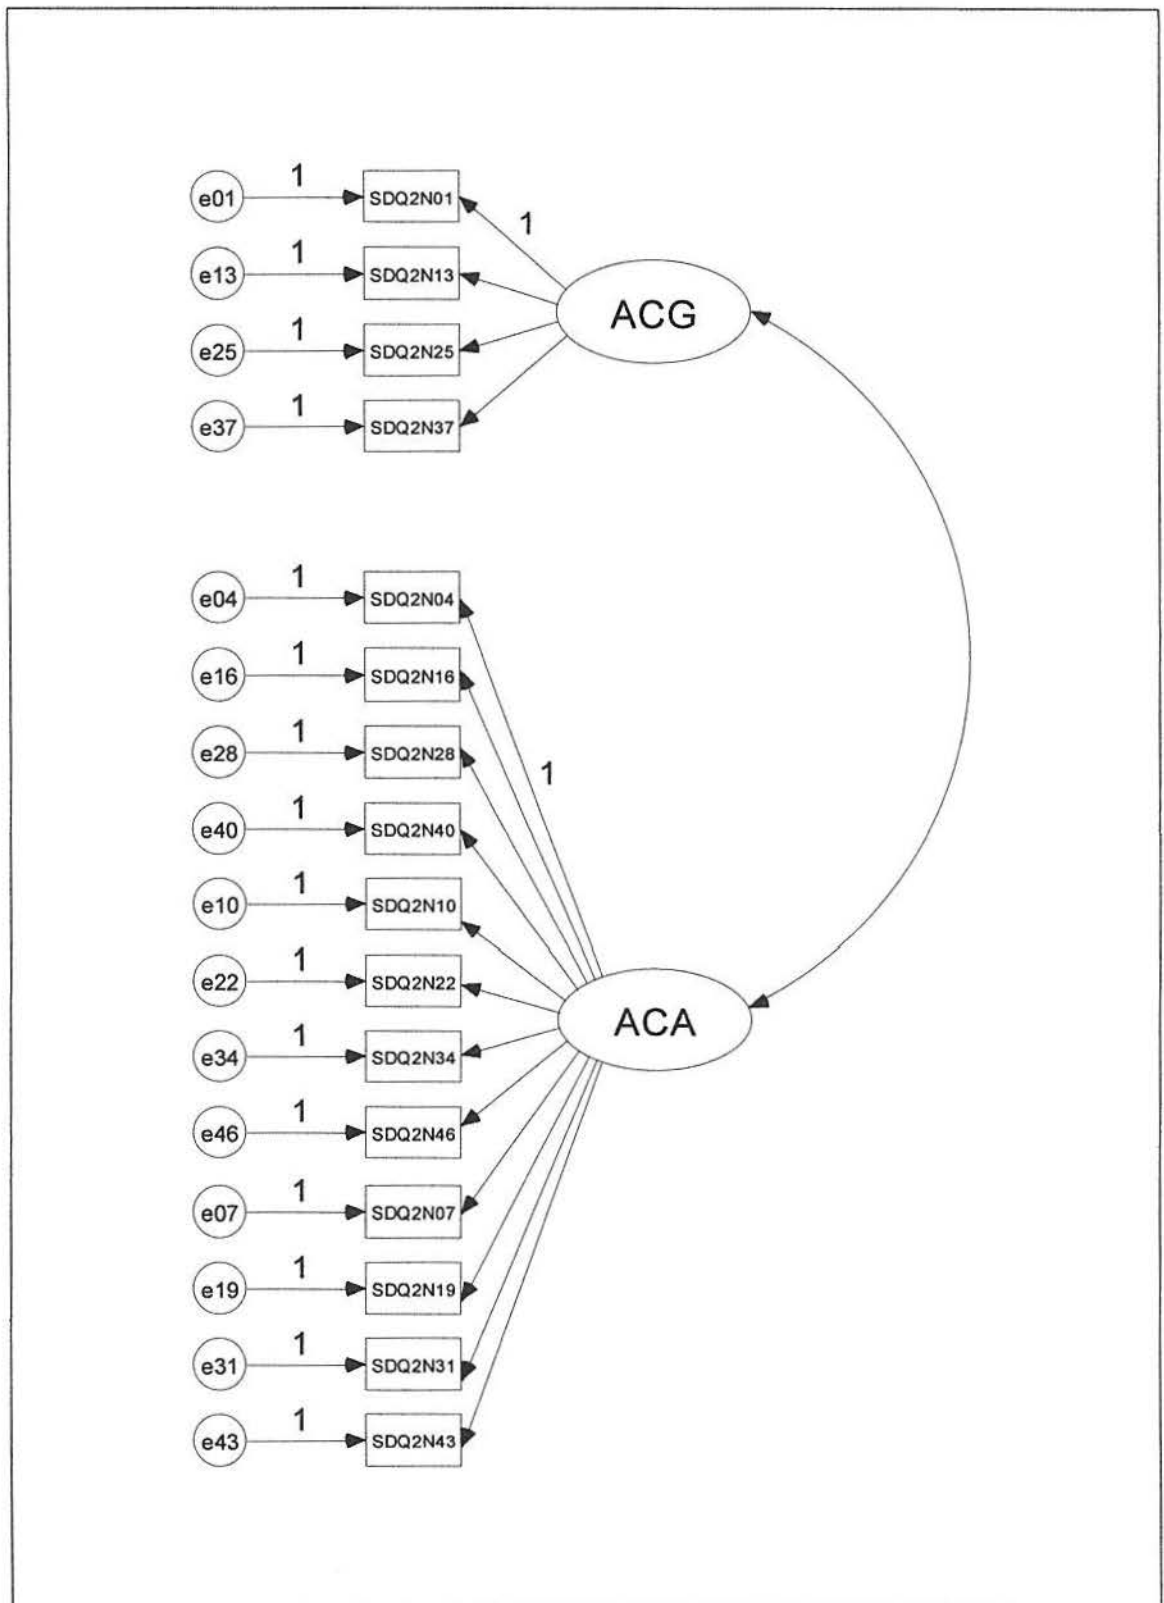


fig.5.3

Há dois aspectos interessantes na mudança do modelo. Primeiro, o padrão das cargas fatoriais permanece o mesmo para as medidas de ACG e ACA, e muda para as medidas de ACV e ACM atribuindo-as para o fator ACA. Segundo, por precisar que apenas um das doze cargas fatoriais de ACA seja fixada para o valor 1, os dois

parâmetros que antes eram contrastados (SDQ2N10 \leftarrow ACV; SDQ2N07 \leftarrow ACM) são agora livremente estimados.

Summary of models					
Model	NP	CMIN	DF	P	CMIN/DF
Default model	33	455,968	103	0,000	4,427
Saturated model	136	0,000	0		
Independence model	16	1696,861	120	0,000	14,141

Model	RMR	GFI	AGFI	PGFI
Default model	0,182	0,754	0,675	0,571
Saturated model	0,000	1,000		
Independence model	0,628	0,379	0,296	0,334

Model	DELTA1 NFI	RHO1 RFI	DELTA2 IFI	RHO2 TLI	CFI
Default model	0,731	0,687	0,779	0,739	0,776
Saturated model	1,000	1,000	1,000		
Independence model	0,000	0,000	0,000	0,000	0,000

Model	PRATIO	PNFI	PCFI
Default model	0,858	0,628	0,666
Saturated model	0,000	0,000	0,000
Independence model	1,000	0,000	0,000

Model	NCP	LO 90	HI 90
Default model	352,968	290,538	422,943
Saturated model	0,000	0,000	0,000
Independence model	1576,861	1447,420	1713,699

Model	FMIN	F0	LO 90	HI 90
Default model	1,727	1,337	1,101	1,602
Saturated model	0,000	0,000	0,000	0,000
Independence model	6,428	5,973	5,483	6,491

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	0,114	0,103	0,125	0,000
Independence model	0,223	0,214	0,233	0,000

Model	AIC	BCC	BIC	CAIC
Default model	521,968	526,510	731,594	673,099
Saturated model	272,000	290,721	1135,915	894,843
Independence model	1728,861	1731,064	1830,499	1802,137

tab. 5.9

A tab. 5.9 mostra os índices de ajuste do modelo com dois fatores. O valor $\chi^2_{(103)}=455.968$ indica um ajuste pobre aos dados e um decréscimo substancial na estatística de ajuste geral observada na estrutura com quatro fatores de $\chi^2_{(5)}=297,514$. O ganho de cinco graus de liberdade pode ser explicado pela estimação de menos duas variâncias fatoriais e menos cinco covariâncias fatoriais (SDQ2N10 \leftarrow ACV; SDQ2N07 \leftarrow ACM). Como esperado, todos os demais índices de ajuste mostram que o AC não é bem representado pela estrutura com dois fatores. Em particular, o valor de CFI=0,776 e o RMSEA= 0,114 são fortes indicativos de um ajuste inferior do modelo hipotético com os dados amostrais.

A essa altura fica lógico que o modelo de auto-conceito é melhor representado por um modelo multidimensional. Como o modelo da hipótese 3, estruturado com apenas um fator, é uma versão ainda mais restrita do que a representada com dois fatores, não apresentará melhores índices de ajuste. Por isso, não serão mostrados os resultados desse modelo hipotético.

Podemos concluir então que o AC é um construto multidimensional, abrangendo quatro fatores: auto-conceito em nível geral, acadêmico, verbal e matemático.

6 METODOLOGIA E EXEMPLO DE CFA DE SEGUNDA ORDEM

A aplicação que será apresentada agora é uma análise fatorial confirmatória de segunda ordem, onde será testada a hipótese relacionada com o Inventário de Depressão Beck (BDI – *Beck Depression Inventory*, de Beck, Ward, Mendelson, Mock, & Erbaugh, 1961) para a população não-clínica de adolescentes. É um exemplo que reproduzimos no AMOS, e é baseado no livro de Byrne (2001). Representa uma série de estudos que foram testados para validar a estrutura fatorial de segunda ordem do BDI, para adolescentes do ensino médio, no Canadá (Byrne & Baron, 1993, 1994). O foco aqui será a validação de como o BDI se relaciona com a calibração da amostra feminina.

Esse inventário (BDI) é composto por uma escala de 21 itens, que medem sintomas cognitivos, comportamentais, afetivos e componentes somáticos relacionados à depressão. Originalmente foi designado para uso por entrevistadores treinados, mas agora é mais utilizado para medir auto-relatos. Este inventário funciona assim: para cada item, os respondentes tem quatro opções, classificáveis de 0 a 3, em termos de intensidade e devem optar por uma que melhor descreve seus sentimentos; maiores escores representam maior nível de depressão. Nesta aplicação o que estamos testando é a validade dos escores a partir de um instrumento de medida (BDI). O estudo citado anteriormente mostrou evidências de que os escores do BDI são melhores representados por uma estrutura fatorial hierárquica. Ou seja, os fatores de primeira ordem são explicados por algum de uma estrutura de maior ordem, que no caso do BDI, é um modelo de segunda ordem único, cujo fator de segunda ordem é depressão geral.

6.1 O Modelo Hipotético

O modelo CFA, conforme a fig. 6.1, postula a priori que:

1. As respostas para o BDI podem ser explicadas por três fatores de primeira ordem: atitude negativa, dificuldade de performance e elementos somáticos), e um fator de segunda ordem (depressão geral).

2. Cada item tem uma carga diferente de zero no fator de primeira ordem, que é designado a medir, e cargas zero nos outros dois fatores de primeira ordem.
3. Termos de erros associados a cada item são não correlacionados.
4. Covariâncias entre os três fatores de primeira ordem são explicadas inteiramente pelas regressões deles com o fator de segunda ordem.

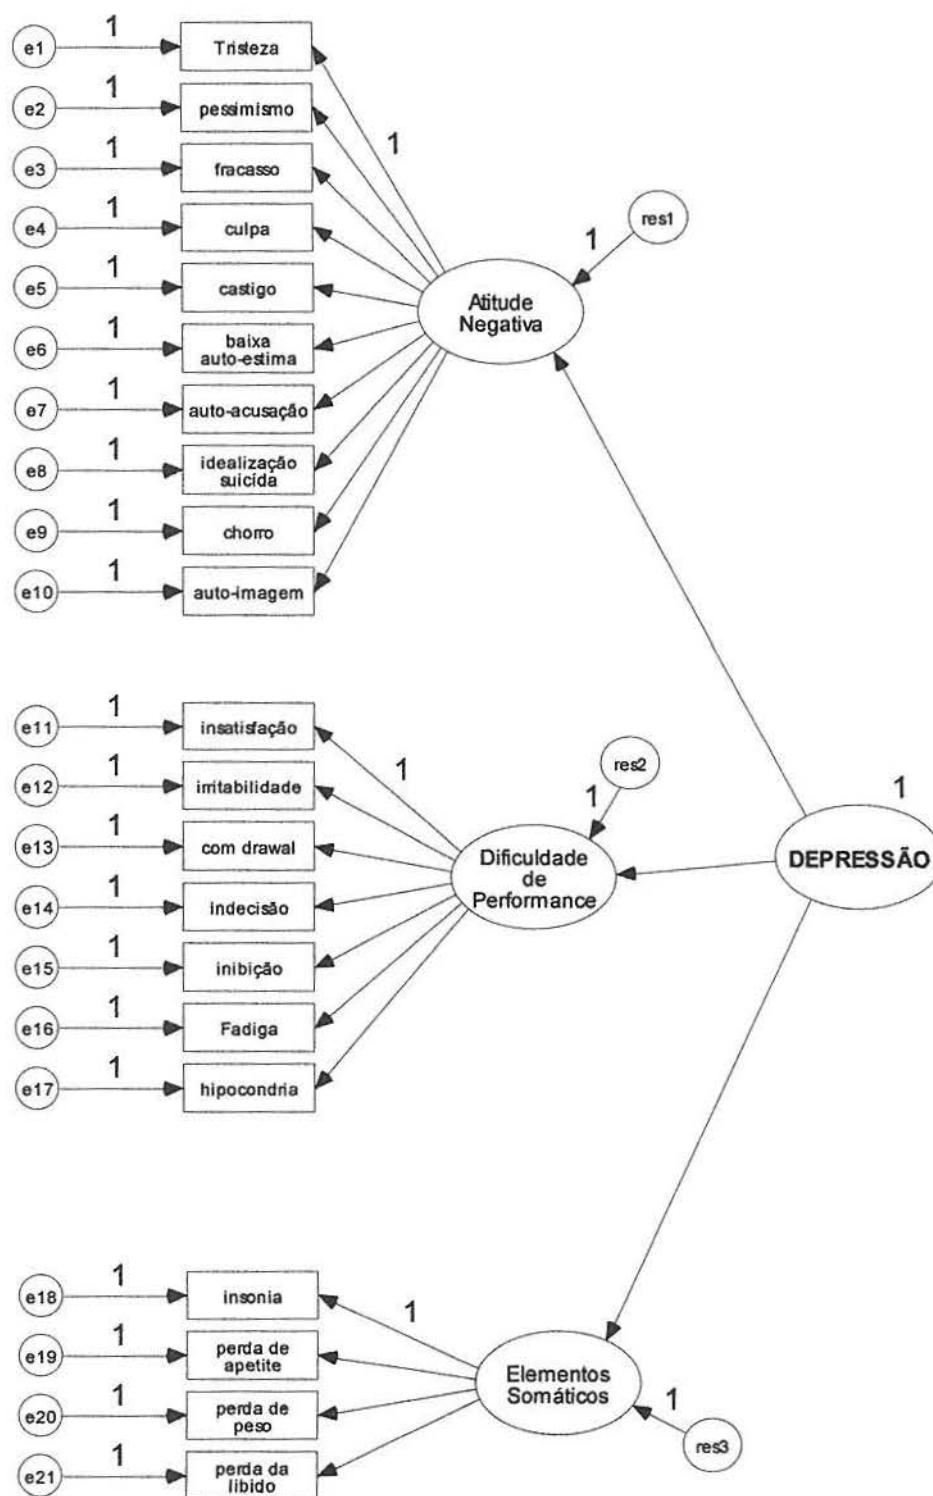


fig 6.1

Para uma testagem inicial do modelo, é interessante determinar quantos graus de liberdade ele tem associado. O AMOS fornece um sumário, clicando no ícone **DF**. Temos 231 momentos amostrais e 45 parâmetros livres para serem estimados, nos deixando com 186 graus de liberdade. Isso dá a sensação de que o modelo especificado seja *overidentified*. Porém em modelos hierárquicos é crítico também checar o status da identificação da parte de ordem maior. No presente caso, dando a especificação de apenas os três fatores de primeira ordem, a estrutura de maior ordem será *just-identified* ao menos que um contraste seja colocado em ao menos um parâmetro nesse nível de ordem maior. Sendo mais específico, tendo três fatores de primeira ordem, existem seis $[(4 \times 3)/2]$ momentos amostrais; o número de parâmetros estimados também é seis (três cargas fatoriais e três resíduos), o que resulta um modelo *just-identified*. Antes de prosseguir, abordaremos o assunto da identificação para um nível superior do modelo.

Um modo de resolver essa questão é colocar contrastes de igualdade em particulares parâmetros conhecidos para gerar estimativas aproximadamente iguais. O software AMOS tem uma ferramenta poderosa para separar os prováveis parâmetros candidatos dos improváveis para a imposição de contrastes de igualdade. Esse mecanismo é conhecido como o método *critical ratio difference* (CRDIFF). Ele fornece uma lista de razões críticas para as diferenças aos pares entre todos os parâmetros estimados. O CRDIFF pode ser solicitado na opção *output*, nas propriedades de análises do AMOS.

Neste primeiro momento, apenas o sumário dos dados e os CRDIFFs são de interesse, para avaliar se precisa ser feito algo afim de que o modelo possa ser então devidamente identificado, estimado e ajustado.

A tab. 6.1 apresenta o sumário dos graus de liberdade do modelo.

<p>Computation of degrees of freedom</p> <p>Number of distinct sample moments = 231 Number of distinct parameters to be estimated = 45 Degrees of freedom = 231 - 45 = 186</p> <p>Minimum was achieved</p> <p>Chi-square = 339,703 Degrees of freedom = 186 Probability level = 0,000</p>

tab. 6.1

A tab.6.2 é referente a matriz utilizada como entrada dos dados no programa AMOS.

rowtype	BDI	16	18	19	21	4	11	12	13	15	17	20	1	2	3	5	6	7	8	9	10	14
n	BDI	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321	321
cov	16	0,687																				
cov	18	0,230	0,816																			
cov	19	0,034	0,018	0,362																		
cov	21	0,039	0,070	0,019	0,342																	
cov	4	0,197	0,125	-0,027	0,054	0,791																
cov	11	0,087	0,152	-0,044	0,052	0,146	0,875															
cov	12	0,094	0,104	-0,018	0,032	0,127	0,011	0,266														
cov	13	0,210	0,166	-0,037	0,080	0,336	0,166	0,098	0,850													
cov	15	0,103	0,114	-0,016	0,042	0,214	0,141	0,067	0,240	0,552												
cov	17	0,144	0,128	-0,022	0,084	0,236	0,084	0,117	0,183	0,178	0,524											
cov	20	0,087	0,131	-0,032	0,145	0,082	0,096	0,063	0,164	0,082	0,125	0,542										
cov	1	0,118	0,151	-0,020	0,052	0,204	0,149	0,106	0,194	0,160	0,210	0,136	0,579									
cov	2	0,126	0,140	-0,051	0,021	0,158	-0,002	0,093	0,213	0,083	0,082	0,142	0,168	0,580								
cov	3	0,160	0,185	-0,044	0,073	0,155	0,136	0,111	0,222	0,097	0,125	0,174	0,211	0,202	0,528							
cov	5	0,095	0,138	-0,016	0,054	0,116	0,119	0,060	0,155	0,093	0,060	0,104	0,112	0,126	0,150	0,381						
cov	6	0,123	0,170	-0,019	0,054	0,235	0,112	0,099	0,253	0,092	0,144	0,260	0,265	0,247	0,238	0,204	1,044					
cov	7	0,136	0,189	-0,040	0,051	0,213	0,060	0,089	0,230	0,130	0,155	0,181	0,216	0,231	0,263	0,146	0,292	0,553				
cov	8	0,150	0,184	0,036	0,033	0,200	0,109	0,055	0,303	0,179	0,139	0,111	0,172	0,155	0,166	0,132	0,147	0,198	0,666			
cov	9	0,079	0,199	-0,018	0,016	0,162	0,064	0,082	0,159	0,117	0,105	0,074	0,183	0,141	0,121	0,068	0,214	0,206	0,141	0,381		
cov	10	0,142	0,286	-0,023	0,106	0,185	0,291	0,137	0,279	0,195	0,210	0,226	0,309	0,145	0,281	0,148	0,357	0,224	0,139	0,177	1,178	
cov	14	0,201	0,208	-0,075	0,073	0,200	0,188	0,063	0,274	0,085	0,100	0,178	0,180	0,274	0,196	0,107	0,192	0,290	0,195	0,182	0,192	1,153

tab. 6.2

Olhando a tab. 6.3, nota-se que, consistente com a fig. 6.1, temos três fatores de primeira ordem dependentes (atitude negativa, dificuldade de performance, elementos somáticos) que são variáveis não observadas endógenas e um fator independente de segunda ordem (depressão), que é uma variável não observada exógena.

Ainda de interesse primário, para resolver o problema da identificação da parte de segunda ordem, precisamos da tab. 6.4. O AMOS coloca rótulos únicos aos parâmetros do modelo, que são mostrados nessa tabela, na coluna "Label", juntamente com as estimativas de máxima verossimilhança, erros padrões e razões críticas. Dois primeiros candidatos para a imposição de contrastes de igualdade são os resíduos relacionados com os fatores atitude negativa e dificuldade de performance, com valores estimados quase idênticos. Eles estão em negrito, na tab. 6.4, na parte de variâncias. De fato, no estudo original eles foram contrastados para serem iguais. Entretanto, podemos ver que o terceiro resíduo (relacionado com o fator somático), não é significativamente diferente dos outros dois resíduos. A decisão final sobre quais parâmetros contrastar como iguais cabe aos valores das razões críticas das diferenças. Esses valores são mostrados, em parte, na tab. 6.5.

Your model contains the following variables:

BDI14	observed	endogenous
BDI10	observed	endogenous
BDI9	observed	endogenous
BDI8	observed	endogenous
BDI7	observed	endogenous
BDI6	observed	endogenous
BDI5	observed	endogenous
BDI3	observed	endogenous
BDI2	observed	endogenous
BDI1	observed	endogenous
BDI20	observed	endogenous
BDI17	observed	endogenous
BDI15	observed	endogenous
BDI13	observed	endogenous
BDI12	observed	endogenous
BDI11	observed	endogenous
BDI4	observed	endogenous
BDI21	observed	endogenous
BDI19	observed	endogenous
BDI18	observed	endogenous
BDI16	observed	endogenous
Atitude_Negativa	unobserved	endogenous
Dificuldade_de_Performance	unobserved	endogenous
Elementos_Somáticos	unobserved	endogenous
e10	unobserved	exogenous
e9	unobserved	exogenous
e8	unobserved	exogenous
e7	unobserved	exogenous
e6	unobserved	exogenous
e5	unobserved	exogenous
e4	unobserved	exogenous
e3	unobserved	exogenous
e2	unobserved	exogenous
e1	unobserved	exogenous
e17	unobserved	exogenous
e16	unobserved	exogenous
e15	unobserved	exogenous
e14	unobserved	exogenous
e13	unobserved	exogenous
e12	unobserved	exogenous
e11	unobserved	exogenous
e21	unobserved	exogenous
e20	unobserved	exogenous
e19	unobserved	exogenous
e18	unobserved	exogenous
DEPRESSÃO	unobserved	exogenous
e22	unobserved	exogenous
e23	unobserved	exogenous
e24	unobserved	exogenous

Number of variables in your model:	49
Number of observed variables:	21
Number of unobserved variables:	28
Number of exogenous variables:	25
Number of endogenous variables:	24

The model is recursive.

Sample size: 321

tab. 6.3

Regression Weights:

		Estimate	S.E.	C.R.	P	Label
Atitude_Negativa <--	DEPRESSÃO	0,420	0,044	9,631	0,000	par-19
Dificuldade_de_Performance <--	DEPRESSÃO	0,477	0,052	9,096	0,000	par-20
Elementos_Somáticos <--	DEPRESSÃO	0,349	0,049	7,112	0,000	par-21
BDI14 <--	Atitude_Negativa	1,037	0,153	6,769	0,000	par-1
BDI10 <--	Atitude_Negativa	1,177	0,158	7,457	0,000	par-2
BDI9 <--	Atitude_Negativa	0,765	0,092	8,297	0,000	par-3
BDI8 <--	Atitude_Negativa	0,857	0,118	7,258	0,000	par-4
BDI7 <--	Atitude_Negativa	1,127	0,117	9,611	0,000	par-5
BDI6 <--	Atitude_Negativa	1,193	0,151	7,917	0,000	par-6
BDI5 <--	Atitude_Negativa	0,633	0,089	7,120	0,000	par-7
BDI3 <--	Atitude_Negativa	1,004	0,112	9,005	0,000	par-8
BDI2 <--	Atitude_Negativa	0,886	0,112	7,892	0,000	par-9
BDI1 <--	Atitude_Negativa	1,000				
BDI20 <--	Dificuldade_de_Performance	0,621	0,099	6,261	0,000	par-10
BDI17 <--	Dificuldade_de_Performance	0,763	0,103	7,427	0,000	par-11
BDI15 <--	Dificuldade_de_Performance	0,710	0,103	6,901	0,000	par-12
BDI13 <--	Dificuldade_de_Performance	1,107	0,136	8,123	0,000	par-13
BDI12 <--	Dificuldade_de_Performance	0,444	0,070	6,365	0,000	par-14
BDI11 <--	Dificuldade_de_Performance	0,535	0,119	4,475	0,000	par-15
BDI4 <--	Dificuldade_de_Performance	1,000				
BDI21 <--	Elementos_Somáticos	0,380	0,105	3,609	0,000	par-16
BDI19 <--	Elementos_Somáticos	-0,065	0,099	-0,652	0,514	par-17
BDI18 <--	Elementos_Somáticos	1,199	0,204	5,879	0,000	par-18
BDI16 <--	Elementos_Somáticos	1,000				

Variances:

		Estimate	S.E.	C.R.	P	Label
	DEPRESSÃO	1,000				
	res1	0,034	0,018	1,924	0,054	par-22
	res2	0,036	0,024	1,478	0,139	par-23
	res3	0,047	0,028	1,684	0,092	par-24
	e10	0,927	0,076	12,124	0,000	par-25
	e9	0,887	0,074	11,942	0,000	par-26
	e8	0,258	0,022	11,620	0,000	par-27
	e7	0,512	0,043	12,000	0,000	par-28
	e6	0,286	0,027	10,625	0,000	par-29
	e5	0,745	0,063	11,782	0,000	par-30
	e4	0,297	0,025	12,038	0,000	par-31
	e3	0,316	0,028	11,198	0,000	par-32
	e2	0,415	0,035	11,792	0,000	par-33
	e1	0,369	0,032	11,417	0,000	par-34
	e17	0,440	0,037	11,927	0,000	par-35
	e16	0,371	0,033	11,338	0,000	par-36
	e15	0,419	0,036	11,654	0,000	par-37
	e14	0,527	0,049	10,683	0,000	par-38
	e13	0,214	0,018	11,889	0,000	par-39
	e12	0,800	0,065	12,358	0,000	par-40
	e11	0,528	0,048	11,058	0,000	par-41
	e21	0,318	0,026	12,173	0,000	par-42
	e20	0,361	0,029	12,638	0,000	par-43
	e19	0,572	0,061	9,313	0,000	par-44
	e18	0,518	0,050	10,255	0,000	par-45

tab. 6.4

Na tab. 6.5 vamos no focar apenas os resíduos rotulados como par-22, par-23 e par-24.

...	par-22	par-23	par-24	...
...
par-22	0,000	0,051	0,382	...
par-23	0,051	0,000	0,306	...
par-24	0,382	0,306	0,000	...
par-25	11,358	11,103	10,800	...
par-26	11,143	10,887	10,574	...
par-27	7,824	6,737	5,886	...
par-28	10,310	9,689	9,097	...
...

tab. 6.5

O valor 0,051 representa a diferença entre par-22 (resíduo 1) e par-23 (resíduo 2), dividido pelo erro padrão estimado dessa diferença. Essa razão crítica pode ser comparada a tabela da distribuição normal padronizada para testar se dois parâmetros são iguais na população. Como o valor 0,051 é menor de 1,96 a hipótese de que as duas variâncias residuais sejam iguais na população não pode ser rejeitada. Da mesma forma, as razões críticas das diferenças relacionadas com os demais pares em destaque não são estatisticamente significativas. Assim, é razoável usar um contraste de igualdade nessas três variâncias relacionadas com esses três resíduos e o nível de ordem maior do modelo será *overidentified* com dois graus de liberdade. Em outras palavras, a variância será estimada por um resíduo, e então esse mesmo valor será constante para as outras duas variâncias residuais. O número de graus de liberdade passará de 186 para 188.

Agora basta incluir essa informação no modelo a ser testado. Para fazer isto no AMOS, é só colocar o mesmo nome em todos os parâmetros que terão contrastes de igualdade. No caso do nosso modelo, será posto nos três resíduos dos fatores de primeira ordem. O nome escolhido para estes parâmetros é var_f.

A fig. 6.2 mostra a nova especificação do modelo, com os contrastes de igualdade.

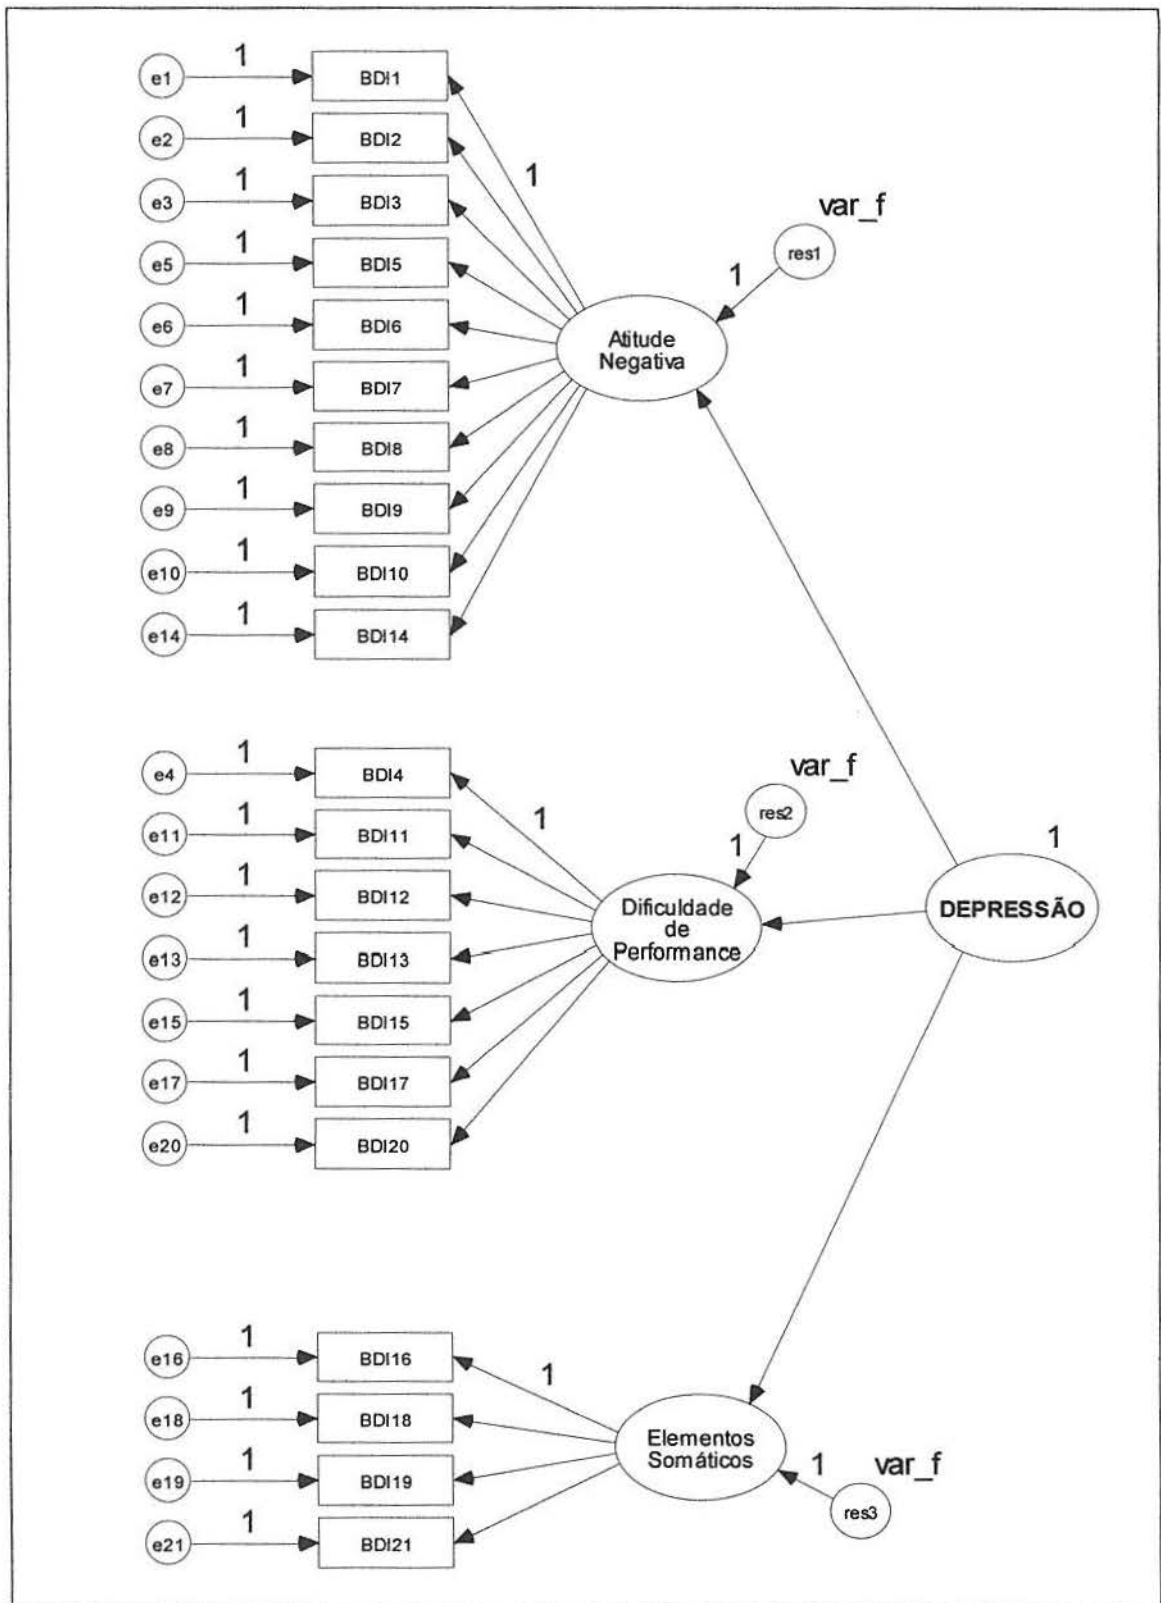


fig. 6.2

Agora podemos executar as estatísticas de ajuste e os índices de modificação. Esses valores serão apresentados nas tabelas 6.7 e 6.8, respectivamente.

6.2 Avaliação do Modelo

Estatísticas de Ajuste: Verificando a tab. 6.6, podemos observar que a inclusão dos contrastes de igualdade entre as três variâncias residuais resultou uma pequena mudança no χ^2 geral ($\chi^2_{(186)} = 339,703$ versus $\chi^2_{(188)} = 339,836$).

Computation of degrees of freedom:	
Number of distinct sample moments =	231
Number of distinct parameters to be estimated =	43
Degrees of freedom =	231 - 43 = 188
Minimum was achieved	
Chi-square =	339,836
Degrees of freedom =	188
Probability level =	0,000

tab. 6.6

Olhando a tab. 6.7, os valores de GFI = 0,908 e CFI = 0,885 indicam que existe alguma fonte de falta de ajuste do modelo hipotético. Para localizá-la, recorreremos aos índices de modificação (MI), na tab. 6.8.

Summary of models						
Model	NP	PAR	CMIN	DF	P	CMIN/DF
Default model	43		339,836	188	0,000	1,808
Saturated model	231		0,000	0		
Independence model	21		1529,979	210	0,000	7,286

Model	RMR	GFI	AGFI	PGFI
Default model	0,036	0,908	0,887	0,739
Saturated model	0,000	1,000		
Independence model	0,149	0,472	0,419	0,429

Model	DELTA1 NFI	RHO1 RFI	DELTA2 IFI	RHO2 TLI	CFI
Default model	0,778	0,752	0,887	0,872	0,885
Saturated model	1,000	1,000	1,000		
Independence model	0,000	0,000	0,000	0,000	0,000

tab. 6.7

continuação tab.6.7

Model	PRATIO	PNFI	PCFI	
Default model	0,895	0,696	0,792	
Saturated model	0,000	0,000	0,000	
Independence model	1,000	0,000	0,000	

Model	RMSEA	LO 90	HI 90	PCLOSE
Default model	0,050	0,042	0,059	0,471
Independence model	0,140	0,134	0,147	0,000

Model	AIC	BCC	BIC	CAIC
Default model	425,836	432,185	718,923	631,008
Saturated model	462,000	496,107	2036,488	1564,203
Independence model	1571,979	1575,080	1715,114	1672,179

Model	ECVI	LO 90	HI 90	MECVI
Default model	1,331	1,182	1,504	1,351
Saturated model	1,444	1,444	1,444	1,550
Independence model	4,912	4,536	5,312	4,922

Nenhum MI nos pesos de regressão foi significativo. Os MIs na parte das covariâncias tem um valor significativo (22,239), referente a um erro de covariância entre o item 20 (hipocondria) e o item 21 (perda da libido). A estatística EPC correspondente é 0,102. A partir desta informação, podemos antecipar que se o modelo for reestimado com este parâmetro especificado para ser livre, haverá uma queda no valor do χ^2 de pelo menos 22,239, e o valor da estimativa para este parâmetro será aproximadamente 0.102.

Byrne (2001) enfatiza que qualquer decisão de reparametrizar o modelo baseado nos MIs deve fazer algum sentido prático. “Qualquer correlação entre termos de erro deve ser justificada e interpretada substantivamente.”. No caso deste exemplo, dado que a amostra é feminina e lida com aspectos depressivos, é totalmente justificável que haja correlação entre a hipocondria e a perda da libido. O modelo será, então, reespecificado com o erro de covariância entre o item 20 e o item 21.

Modification Indices

Covariances:	M.I.	Par Change
e18 <-----> res2	5,293	-0,047
e19 <-----> res3	8,270	0,050
e19 <-----> e16	4,055	0,051
e21 <-----> res2	4,409	0,030
e4 <-----> e18	4,527	-0,074
e12 <-----> e11	5,342	0,055
e20 <-----> res2	12,101	-0,059
e20 <-----> res1	10,553	0,045
e20 <-----> e21	22,239	0,102
e20 <-----> e4	10,653	-0,094
e1 <-----> e17	10,071	0,071
e2 <-----> e11	9,554	-0,103
e6 <-----> e15	4,322	-0,069
e6 <-----> e20	9,270	0,102
e7 <-----> e11	6,083	-0,071
e8 <-----> res2	6,655	0,048
e8 <-----> res1	5,127	-0,034
e8 <-----> e19	5,893	0,060
e8 <-----> e13	11,836	0,109
e8 <-----> e15	4,660	0,059
e8 <-----> e6	4,233	-0,075
e9 <-----> e18	9,231	0,073
e9 <-----> e20	4,089	-0,040
e9 <-----> e3	7,618	-0,048
e9 <-----> e5	5,335	-0,038
e10 <-----> e11	11,072	0,162
e10 <-----> e1	4,248	0,070
e10 <-----> e2	5,306	-0,082
e10 <-----> e7	4,559	-0,066
e10 <-----> e8	4,058	-0,079
e14 <-----> e2	5,954	0,088

Variances:	M.I.	Par Change
------------	------	------------

Regression Weights:	M.I.	Par Change
---------------------	------	------------

BDI16 <-----> BDI19	4,023	0,142
BDI18 <-----> BDI9	6,400	0,187
BDI21 <-----> BDI20	19,158	0,189
BDI4 <-----> BDI20	8,365	-0,168
BDI11 <-----> BDI12	4,094	-0,198
BDI11 <-----> BDI2	5,950	-0,162
BDI11 <-----> BDI10	8,467	0,135
BDI12 <-----> BDI11	4,796	-0,062
BDI13 <-----> BDI8	9,282	0,162
BDI15 <-----> BDI6	4,014	-0,073
BDI17 <-----> BDI1	4,521	0,099
BDI20 <-----> BDI21	21,856	0,304
BDI20 <-----> BDI4	6,423	-0,108
BDI20 <-----> BDI6	9,949	0,117
BDI1 <-----> BDI17	7,564	0,135
BDI2 <-----> BDI11	9,381	-0,121

BDI2 <-----> BDI14	4,626	0,074
BDI3 <-----> BDI9	4,839	-0,118
BDI6 <-----> BDI20	6,526	0,173
BDI7 <-----> BDI11	6,226	-0,086
BDI8 <-----> BDI19	5,727	0,163
BDI8 <-----> BDI13	9,566	0,137
BDI8 <-----> BDI15	5,106	0,124
BDI9 <-----> BDI18	6,147	0,081
BDI9 <-----> BDI3	4,145	-0,082
BDI10 <-----> BDI11	11,176	0,193
BDI14 <-----> BDI2	4,023	0,144

tab. 6.8

6.3 Análise Post Hoc

A fig. 6.3 mostra a nova especificação do modelo.

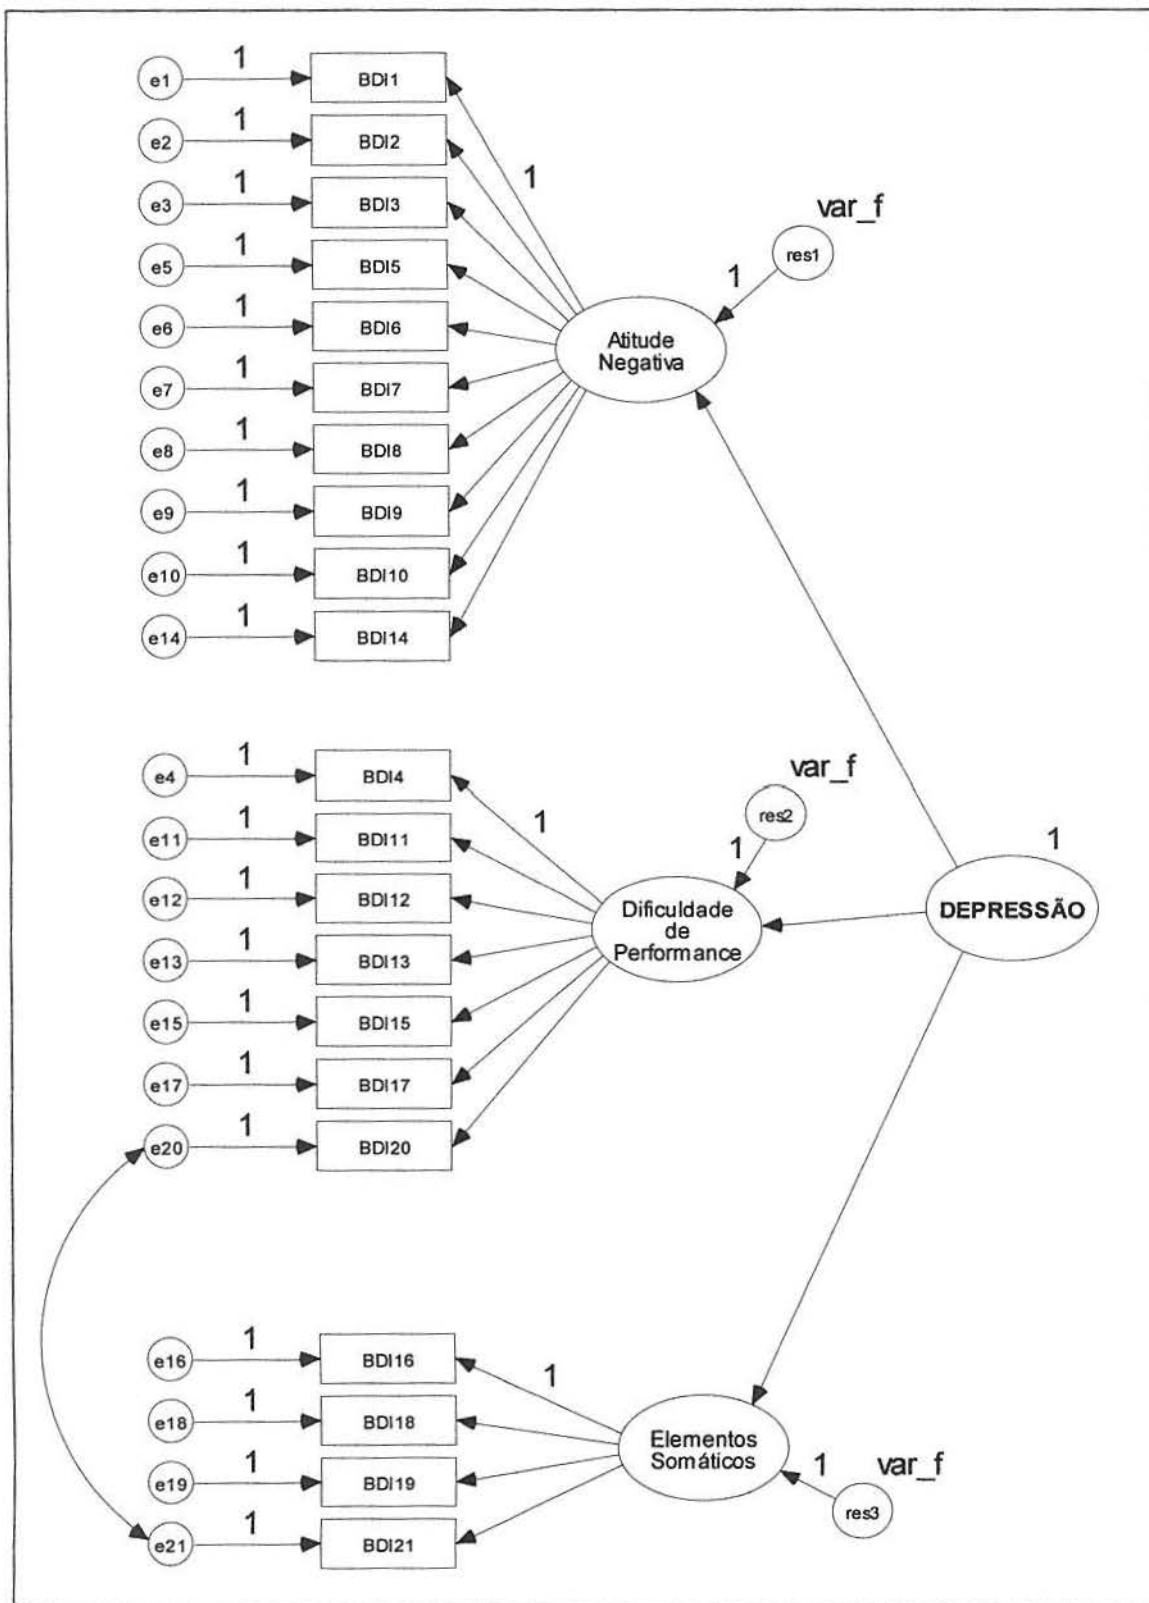


fig. 6.3

Avaliação do Modelo 2

Índices de Ajuste: A tab. 6.9 mostra que o modelo 2 gerou um ajuste geral do $\chi^2_{(187)}=316,681$. A estatística GFI aumentou, agora é 0,913 e a CFI passou a ser 0,902 (tab. 6,13). Assim, a queda esperada no valor $\chi^2_{(1)}$ (EPC=22,239) levemente subestimou o atual valor $\chi^2_{(1)} = 23,155$. Por outro lado, o valor estimado para o erro de covariância entre o item 20 e o item 21 foi basicamente predita (0,103 vs 0,102), como mostra a tab. 6.12.

Computation of degrees of freedom
Number of distinct sample moments = 231
Number of distinct parameters to be estimated = 44
Degrees of freedom = 231 - 44 = 187
Minimum was achieved
Chi-square = 316,681
Degrees of freedom = 187
Probability level = 0,000

tab. 6.9

Índices de Modificação: A tab. 6.10 mostra os MIs associados com o modelo 2. Uma leitura detalhada desta tabela mostra que nenhuma das cargas fatoriais e as covariâncias entre os resíduos dos parâmetros foram substancialmente significativas. Os MIs não indicam que este modelo precisa ser reespecificado.

Byrne (2001) admite que o ajuste deste modelo pode ser considerado apenas marginalmente bom, mas que apesar disto é razoável, visto as estatísticas CFI e os demais índices de ajuste tab. 6.13. Mais especificamente, em comparação com o modelo hipotético no qual não foi especificado erro de covariância, o valor do RMSEA caiu para 0,047 (antes era 0,050), o ECVI caiu para 1,265 (antes era 1,331). Já o GFI aumentou para 0,913 (antes era 0,908), e o CFI também aumentou, foi para 0,902 (de 0,885).

Modification Indices				
Covariances:			M.I.	Par Change
e18	<->	res2	5,325	-0,048
e19	<->	res3	8,601	0,051
e19	<->	e16	4,100	0,052
e21	<->	res2	4,054	0,028
e4	<->	e18	4,963	-0,077
e12	<->	e11	5,343	-0,055
e20	<->	res2	12,088	-0,057
e20	<->	res1	15,666	0,054
e20	<->	e4	9,652	-0,086
e1	<->	e17	10,115	0,071
e2	<->	e11	9,627	-0,104
e6	<->	e15	4,362	-0,069
e6	<->	e20	10,840	0,107
e7	<->	e11	6,094	-0,071
e8	<->	res2	6,792	0,049
e8	<->	res1	5,473	-0,035
e8	<->	e19	5,945	0,060
e8	<->	e13	11,626	0,108
e8	<->	e15	4,539	0,058
e8	<->	e6	4,267	-0,075
e9	<->	e18	8,929	0,071
e9	<->	e3	7,740	-0,048
e9	<->	e5	5,408	-0,038
e10	<->	e11	11,161	0,162
e10	<->	e1	4,307	0,071
e10	<->	e2	5,268	-0,082
e10	<->	e7	4,456	-0,065
e10	<->	e8	4,042	-0,079
e14	<->	e2	5,938	0,088
Regression Weights:			M.I.	Par Change
BDI16	<-	BDI19	4,052	0,142
BDI18	<-	BDI4	4,041	-0,103
BDI18	<-	BDI9	6,170	0,183
BDI4	<-	BDI20	7,865	-0,163
BDI11	<-	BDI12	4,091	-0,198
BDI11	<-	BDI2	5,979	-0,162
BDI11	<-	BDI10	8,556	0,136
BDI12	<-	BDI11	4,797	-0,062
BDI13	<-	BDI8	9,085	0,160
BDI15	<-	BDI6	4,076	-0,074
BDI17	<-	BDI1	4,598	0,100
BDI20	<-	BDI4	5,753	-0,099
BDI20	<-	BDI6	11,842	0,123
BDI20	<-	BDI7	4,128	0,100
BDI1	<-	BDI17	7,571	0,135
BDI2	<-	BDI11	9,403	-0,122
BDI2	<-	BDI14	4,614	0,074
BDI3	<-	BDI9	4,895	-0,119
BDI6	<-	BDI20	6,989	0,179
BDI7	<-	BDI11	6,219	-0,086
BDI8	<-	BDI19	5,769	0,163
BDI8	<-	BDI13	9,501	0,137
BDI8	<-	BDI15	5,048	0,124
BDI9	<-	BDI18	6,070	0,080
BDI9	<-	BDI3	4,224	-0,083
BDI9	<-	BDI5	4,056	-0,096
BDI10	<-	BDI11	11,222	0,193
BDI14	<-	BDI2	4,005	0,144

tab. 6.10

ESTIMATIVAS				Estimate	S.E.	C.R.	P
Regression Weights							
Atitude_Negativa	<--	DEPRESSÃO	0,419	0,042	9,948	0,000	
Dificuldade_de_Performance	<--	DEPRESSÃO	0,481	0,051	9,454	0,000	
Elementos_Somáticos	<--	DEPRESSÃO	0,349	0,049	7,111	0,000	
BDI14	<--	Atitude_Negativa	1,032	0,151	6,821	0,000	
BDI10	<--	Atitude_Negativa	1,167	0,155	7,508	0,000	
BDI9	<--	Atitude_Negativa	0,764	0,091	8,417	0,000	
BDI8	<--	Atitude_Negativa	0,853	0,116	7,327	0,000	
BDI7	<--	Atitude_Negativa	1,122	0,115	9,764	0,000	
BDI6	<--	Atitude_Negativa	1,186	0,148	7,995	0,000	
BDI5	<--	Atitude_Negativa	0,629	0,088	7,171	0,000	
BDI3	<--	Atitude_Negativa	0,997	0,109	9,119	0,000	
BDI2	<--	Atitude_Negativa	0,883	0,111	7,987	0,000	
BDI1	<--	Atitude_Negativa	1,000				
BDI20	<--	Dificuldade_de_Performance	0,589	0,096	6,131	0,000	
BDI17	<--	Dificuldade_de_Performance	0,753	0,100	7,515	0,000	
BDI15	<--	Dificuldade_de_Performance	0,705	0,101	7,008	0,000	
BDI13	<--	Dificuldade_de_Performance	1,096	0,133	8,261	0,000	
BDI12	<--	Dificuldade_de_Performance	0,440	0,068	6,440	0,000	
BDI11	<--	Dificuldade_de_Performance	0,529	0,118	4,494	0,000	
BDI4	<--	Dificuldade_de_Performance	1,000				
BDI21	<--	Elementos_Somáticos	0,350	0,104	3,350	0,001	
BDI19	<--	Elementos_Somáticos	-0,080	0,102	-0,785	0,433	
BDI18	<--	Elementos_Somáticos	1,211	0,204	5,937	0,000	
BDI16	<--	Elementos_Somáticos	1,000				
Standardized Regression Weights				Estimate			
Atitude_Negativa	<--	DEPRESSÃO	0,909				
Dificuldade_de_Performance	<--	DEPRESSÃO	0,929				
Elementos_Somáticos	<--	DEPRESSÃO	0,877				
BDI14	<--	Atitude_Negativa	0,443				
BDI10	<--	Atitude_Negativa	0,496				
BDI9	<--	Atitude_Negativa	0,570				
BDI8	<--	Atitude_Negativa	0,482				
BDI7	<--	Atitude_Negativa	0,695				
BDI6	<--	Atitude_Negativa	0,535				
BDI5	<--	Atitude_Negativa	0,469				
BDI3	<--	Atitude_Negativa	0,633				
BDI2	<--	Atitude_Negativa	0,534				
BDI1	<--	Atitude_Negativa	0,605				
BDI20	<--	Dificuldade_de_Performance	0,416				
BDI17	<--	Dificuldade_de_Performance	0,540				
BDI15	<--	Dificuldade_de_Performance	0,492				
BDI13	<--	Dificuldade_de_Performance	0,617				
BDI12	<--	Dificuldade_de_Performance	0,443				
BDI11	<--	Dificuldade_de_Performance	0,293				
BDI4	<--	Dificuldade_de_Performance	0,583				
BDI21	<--	Elementos_Somáticos	0,239				
BDI19	<--	Elementos_Somáticos	-0,053				
BDI18	<--	Elementos_Somáticos	0,534				
BDI16	<--	Elementos_Somáticos	0,482				

tab. 6.11

ESTIMATIVAS				Estimate	S.E.	C.R.	P
Covariances							
e20	<-->	e21		0,103	0,023	4,559	0,000
Variances							
		DEPRESSÃO		Estimate	S.E.	C.R.	P
				1,000			
		res1		0,037	0,009	4,120	0,000
		res2		0,037	0,009	4,120	0,000
		res3		0,037	0,009	4,120	0,000
		e14		0,924	0,076	12,121	0,000
		e10		0,886	0,074	11,944	0,000
		e9		0,256	0,022	11,603	0,000
		e8		0,510	0,043	11,996	0,000
		e7		0,285	0,027	10,609	0,000
		e6		0,743	0,063	11,780	0,000
		e5		0,296	0,025	12,037	0,000
		e3		0,316	0,028	11,197	0,000
		e2		0,413	0,035	11,783	0,000
		e1		0,367	0,032	11,409	0,000
		e20		0,444	0,037	11,990	0,000
		e17		0,370	0,033	11,343	0,000
		e15		0,417	0,036	11,636	0,000
		e13		0,525	0,049	10,674	0,000
		e12		0,213	0,018	11,879	0,000
		e11		0,797	0,065	12,355	0,000
		e4		0,522	0,047	11,048	0,000
		e21		0,320	0,026	12,307	0,000
		e19		0,360	0,028	12,634	0,000
		e18		0,581	0,058	10,087	0,000
		e16		0,522	0,047	11,145	0,000

Tab. 6.12

Fit Measures	CMIN	DF	P	NPAR	CMINDF	RMR	GFI	AGFI	PGFI	NFI
Default model	316,681	187,000	0,000	44,000	1,693	0,035	0,913	0,893	0,739	0,793
Saturated	0,000	0,000		231,000		0,000	1,000			1,000
Independence	1529,979	210,000	0,000	21,000	7,286	0,149	0,472	0,419	0,429	0,000
Fit Measures	RFI	IFI	TLI	CFI	PRATIO	PNFI	PCFI	NCP	NCPLO	NCPHI
Default model	0,768	0,903	0,890	0,902	0,890	0,706	0,803	129,681	84,433	182,810
Saturated		1,000		1,000	0,000	0,000	0,000	0,000	0,000	0,000
Independence	0,000	0,000	0,000	0,000	1,000	0,000	0,000	1319,979	1199,479	1447,927
Fit Measures	FMIN	F0	F0LO	F0HI	RMSEA	RMSEALO	RMSEHI	PCLOSE		
Default model	0,990	0,405	0,264	0,571	0,047	0,038	0,055	0,733		
Saturated	0,000	0,000	0,000	0,000						
Independence	4,781	4,125	3,748	4,525	0,140	0,134	0,147	0,000		
Fit Measures	AIC	BCC	BIC	CAIC	ECVI	ECVILO	ECVIHI	MECVI	HFIVE	HONE
Default model	404,681	411,178	704,584	614,625	1,265	1,123	1,431	1,285	223,000	238,000
Saturated	462,000	496,107	2036,488	1564,203	1,444	1,444	1,444	1,550		
Independence	1571,979	1575,080	1715,114	1672,179	4,912	4,536	5,312	4,922	52,000	55,000

tab. 6.13

Com relação às estimativas listadas na tab. 6.11 e na tab. 6.12, todas, com uma exceção, são razoáveis e estatisticamente significativas (incluindo a covariância do erro entre o item 20 e o item 21), e todos os erros padrões são coerentes. A exceção é

referente à carga do item 19 (perda de peso) no fator elementos somáticos, que não é estatisticamente significante (-0,08; C.R.=-0,785).

Em termos gerais, com base na adequação das estatísticas de ajuste e nas soluções padronizadas/não padronizadas, no fato do modelo alcançar um ajuste de médio a bom aos dados observados, e no fato de que os MIs não justificam deixar novos parâmetros livres para serem estimados, o modelo dois pode ser considerado o que melhor representa a estrutura dos itens de escores do BDI para adolescentes femininas.

Byrne (2001) ainda conclui que, dando o mesmo número de parâmetros estimáveis, as estatísticas de ajuste do modelo parametrizado tanto para a estrutura de primeira ordem como para estrutura de segunda ordem serão equivalentes. A diferença entre as duas especificações é que o modelo de segunda ordem é um caso especial do modelo de primeira ordem, com a restrição de que a estrutura terá um modelo correlacional entre os fatores de primeira ordem. Já a decisão se o instrumento de medida deve ser modelado com uma estrutura de primeira ou segunda ordem, será ditada pela teoria no assunto.

7 ANÁLISE FATORIAL CONFIRMATÓRIA DO INSTRUMENTO DE MEDIDA: PROSPECTIVE AND RETROSPECTIVE MEMORY QUESTIONNAIRE (PRMQ)

Neste capítulo apresentaremos uma análise fatorial confirmatória para o instrumento de medida (questionário de memória prospectiva e retrospectiva -PRMQ) utilizado na dissertação de mestrado de Daniela Benites cujo título é “Tradução para o português-brasileiro e validação do *Prospective and Retrospective Memory Questionnaire* (PRMQ)” da Universidade Federal do Rio Grande do Sul. No próximo tópico constará uma introdução ao assunto, um resumo e a metodologia utilizada na obtenção da amostra. O tópico 7.1 foi desenvolvido com a participação de Daniela Benites.

7.1 Introdução ao Prospective and Retrospective Memory Questionnaire

Um dos objetivos da dissertação de mestrado é investigar as relações entre falhas cotidianas de memória prospectiva e retrospectiva. Memória retrospectiva (MR) é a memória para eventos passados, e a memória prospectiva (MP) é aquela memória que codifica e recupera intenções, ou seja, aquelas ações que devem ser realizadas no futuro. O relato de falhas de memória prospectiva e retrospectiva será avaliado segundo o Questionário de Memória Prospectiva e Retrospectiva (QMPR), que está sendo validado nesta dissertação.

Um modelo de uso de MP e MR foi desenvolvido por Smith e cols. (2000) e aprofundado por Crawford e cols. (2003). Este modelo focaliza as falhas MP e MR relatadas tanto por portadores de déficits cognitivos e seus cuidadores quanto por pessoas consideradas saudáveis. O seu desenvolvimento começou a partir da investigação de dois pontos principais: 1) as sugestões de que falhas de MP ocorriam mais frequentemente em pacientes com Alzheimer do que falhas de MR, e 2) a hipótese de que falhas de MP são mais frequentes do que falhas de MR durante o envelhecimento normal (Smith e cols., 2000). Participaram do estudo pacientes com Alzheimer, seus

cuidadores e um grupo controle de pessoas adultas saudáveis. Uma vez que interessava o relato dos cuidadores, estudos experimentais não se aplicariam à pesquisa. Houve a necessidade de elaborar um questionário que extraísse falhas de MP e MR e que quantificasse o relato de cuidadores, de pessoas saudáveis e de pacientes com déficits cognitivos específicos de memória. Para tanto, foi desenvolvido o Questionário de Memória Prospectiva e Retrospectiva (PRMQ) (Smith e cols., 2000). Salienta-se que os cuidadores responderam às mesmas escalas, mas na terceira pessoa do singular, ou seja, referiram-se aos pacientes de Alzheimer. A fidedignidade do QMPR foi considerada bem aceitável para estudos de grupos, como em pesquisas, e individuais, em ambientes médicos gerais e clínicas de memória, por exemplo (Smith e cols., 2000).

A amostra é composta por 504 estudantes de uma universidade do interior do Rio Grande do Sul, que responderam a todas as perguntas. Os universitários assinaram o Termo de Consentimento Livre e Esclarecido, preencheram uma Ficha de dados sócio-demográficos e o Questionário de Memória Prospectiva e Retrospectiva (QMPR) (Smith e cols., 2000). O QMPR consiste de 16 perguntas referentes às falhas cotidianas de memória, sendo oito de memória prospectiva e oito de retrospectiva, seguidas de uma escala likert de cinco pontos (nunca [1], raramente [2], algumas vezes [3], freqüentemente [4] e quase sempre [5]). O instrumento foi traduzido através de procedimentos de back translation e discussões no grupo de pesquisa, a fim de ser realizada uma adaptação para o português sensível à cultura. Dos dezesseis itens do questionário, oito itens avaliam o auto-relato de falhas de memória prospectiva (intenções), e oito de memória retrospectiva (eventos passados). Cada item de MP e MR é categorizado, ainda, de acordo com duas subcategorias: de tempo (curto e longo prazo) e pista (interna ou externa). Na memória prospectiva (MP), intenções de curto-prazo são ações que devem ser realizadas dentro de alguns minutos ou poucas horas, intenções de longo-prazo são aquelas que devem ser realizadas em alguns dias, meses ou anos. Na memória retrospectiva (MR), eventos de curto prazo aconteceram há alguns dias ou poucos meses, e de longo prazo correspondem a eventos que aconteceram há muitos meses ou anos. Ao categorizar quanto à disponibilidade ou não de pistas que lembram intenções ou eventos, estas podem estar no ambiente (pistas externas) ou serem autogeradas (pistas internas). Pistas relevantes e disponíveis, que podem ser tanto externas quanto internas, são as responsáveis pela incitação da lembrança de uma ação (MP) ou evento (MR) (Smith e cols., 2000). Assim, as escalas de auto-relato de falhas de memória prospectiva e retrospectiva possuem o mesmo número de itens sobre

memória de curto e longo-prazo, e memória com pista externa e pista interna. Cada um dos 16 itens apresenta três dimensões (MP ou MR, curto ou longo prazo, e pista interna ou externa).

O Questionário PRMQ

<i>Item n°</i>	<i>Item</i>	<i>Prospectiva vs Retrospectiva</i>	<i>Curto vs Longo prazo</i>	<i>Pista interna vs Pista externa</i>
1	Você decide fazer alguma coisa em alguns minutos e então se esquece de fazê-la?	Prospectiva	Curto prazo	Pista interna
2	Você falha em reconhecer um lugar que você tenha visitado antes?	Retrospectiva	Longo prazo	Pista externa
3	Você falha em fazer alguma coisa que você deveria fazer poucos minutos mais tarde mesmo que esteja lá na sua frente, como tomar um remédio ou apagar o fogo da chaleira?	Prospectiva	Curto prazo	Pista externa
4	Você esquece alguma coisa que lhe foi contada alguns minutos antes?	Retrospectiva	Curto prazo	Pista interna
5	Você esquece de compromissos se não for lembrado por outra pessoa ou por um lembrete, como um calendário ou agenda?	Prospectiva	Longo prazo	Pista interna
6	Você falha em reconhecer um personagem em um programa de rádio ou de TV de uma cena para outra?	Retrospectiva	Curto prazo	Pista externa
7	Você esquece de comprar algo que você planejou comprar, como um cartão de aniversário, mesmo quando você vê a loja?	Prospectiva	Longo prazo	Pista externa
8	Você falha ao lembrar coisas que aconteceram com você nos últimos dias?	Retrospectiva	Longo prazo	Pista interna
9	Você repete a mesma história para a mesma pessoa em ocasiões diferentes?	Retrospectiva	Longo prazo	Pista externa
10	Você pretende levar algo com você, antes de deixar uma sala ou sair para a rua, mas minutos depois deixa o que queria levar para trás, mesmo que esteja lá na sua frente?	Prospectiva	Curto prazo	Pista externa
11	Você esquece o lugar onde recém colocou alguma coisa, como uma revista ou óculos?	Retrospectiva	Curto prazo	Pista interna
12	Você falha em dar um recado ou um objeto que lhe pediram para dar a um visitante?	Prospectiva	Longo prazo	Pista externa
13	Você olha para algo sem notar que viu a mesma coisa momentos antes?	Retrospectiva	Curto prazo	Pista externa
14	Se você tentasse entrar em contato com um amigo ou parente que estava fora, você se esqueceria de tentar novamente mais tarde?	Prospectiva	Longo prazo	Pista interna
15	Você esquece o que você viu na televisão no dia anterior?	Retrospectiva	Longo prazo	Pista interna
16	Você se esquece de falar pra alguém algo que você queria falar alguns minutos antes?	Prospectiva	Curto prazo	Pista interna

7.2 CFA do PRMQ

Neste tópico apresentaremos os testes para a validação fatorial dos escores a partir do instrumento de medida PRMQ (questionário sobre memória prospectiva e memória retrospectiva). Para tanto, testaremos quatro modelos diferentes:

Modelo 1: apenas um fator latente de memória geral;

Modelo 2: dois fatores latentes correlacionados – memória prospectiva (MP) e memória retrospectiva (MR). Cada fator com suas 8 perguntas correspondentes do questionário.

Modelo 3: dois fatores latentes correlacionados – memória prospectiva (MP) e memória retrospectiva (MR), com os itens 7, 9 e 11 trocando de fator.

Modelo 3a: dois fatores latentes correlacionados – memória prospectiva (MP) e memória retrospectiva (MR), com os itens 7, 9 e 11 trocando de fator e covariâncias dos erros entre alguns itens, como mostra a fig. 7.1.

Modelo	χ^2	GL	RMSEA	PCLOSE	GFI	CFI
1	296,752	104	0,061	0,015	0,927	0,896
2	291,752	103	0,060	0,018	0,928	0,898
3	249,020	103	0,053	0,263	0,941	0,921
3a	198,544	100	0,044	0,848	0,954	0,947

tab. 7.1

A tab. 7.1 mostra alguns dos índices de ajuste dos modelos testados. O modelo 1 não ajusta-se bem aos dados. Isso fica evidente pela estatística PCLOSE, que é muito baixa (lembrando que PCLOSE informa a probabilidade de que RMSEA seja $< 0,05$). Além disso, os resíduos deste modelo foram altos, assim como os índices de modificação (ambos não apresentados aqui). Também as estatísticas de comparação, como AIC, CAIC, BIC e ECVI foram bem maiores para o modelo testado do que para os modelos saturado e de independência. Fica então evidente que a memória não é bem representada por apenas um fator geral, por esta amostra.

O modelo 2 apresentou os mesmos problemas. Uma análise nos índices de modificação e nos resíduos padronizados mostrou que o modelo 2 não está bem especificado (as tabelas foram omitidas).

Neste momento, entramos no cenário de geração de modelos, descrito no segundo capítulo. O modelo 3 foi reespecificado com alguns itens trocando de fator (item 7, item 9 e item 11). A partir desse modelo apresentaremos algumas tabelas.

Conforme mostra a tab. 7.1 o modelo 3 ainda apresenta baixo PCLOSE (0,263). Já a partir da tab. 7.2, dos índices de modificação, destacamos três covariâncias dos erros (10 \leftrightarrow 11, 16 \leftrightarrow 15, e 14 \leftrightarrow 13).

Covariâncias:			M.I.	Par Change
e6	\leftrightarrow	MR	5,582	0,024
e6	\leftrightarrow	MP	7,251	-0,050
e2	\leftrightarrow	e6	4,350	0,048
e8	\leftrightarrow	e15	4,022	0,052
e7	\leftrightarrow	e6	4,279	0,056
e13	\leftrightarrow	MP	4,114	0,036
e11	\leftrightarrow	e2	12,482	-0,082
e12	\leftrightarrow	MR	8,160	-0,028
e12	\leftrightarrow	MP	4,982	0,039
e12	\leftrightarrow	e15	4,868	-0,057
e12	\leftrightarrow	e8	6,527	-0,063
e10	\leftrightarrow	e15	6,273	-0,065
e10	\leftrightarrow	e7	4,446	0,055
e10	\leftrightarrow	e11	15,556	0,099
e9	\leftrightarrow	e8	4,663	0,061
e9	\leftrightarrow	e11	6,758	0,076
e5	\leftrightarrow	e2	4,970	0,055
e5	\leftrightarrow	e12	14,666	0,104
e1	\leftrightarrow	e4	6,181	0,058
e16	\leftrightarrow	MR	10,547	0,028
e16	\leftrightarrow	MP	6,410	-0,039
e16	\leftrightarrow	e15	15,807	0,091
e16	\leftrightarrow	e5	9,576	-0,074
e3	\leftrightarrow	e2	9,092	0,069
e3	\leftrightarrow	e1	6,069	0,056
e14	\leftrightarrow	MR	6,026	0,024
e14	\leftrightarrow	e15	5,539	0,061
e14	\leftrightarrow	e13	18,389	0,107
e14	\leftrightarrow	e10	6,394	-0,062

tab. 7.2

O modelo 3a foi reestruturado com a imposição destas três covariâncias dos erros, conforme mostra a fig. 7.1, já com as estimativas padronizadas. A tab. 7.3 indica

que todas as estimativas foram significativas ($|CR| \geq 1.96$). Inclusive as covariâncias dos erros que foram adicionadas ao modelo.

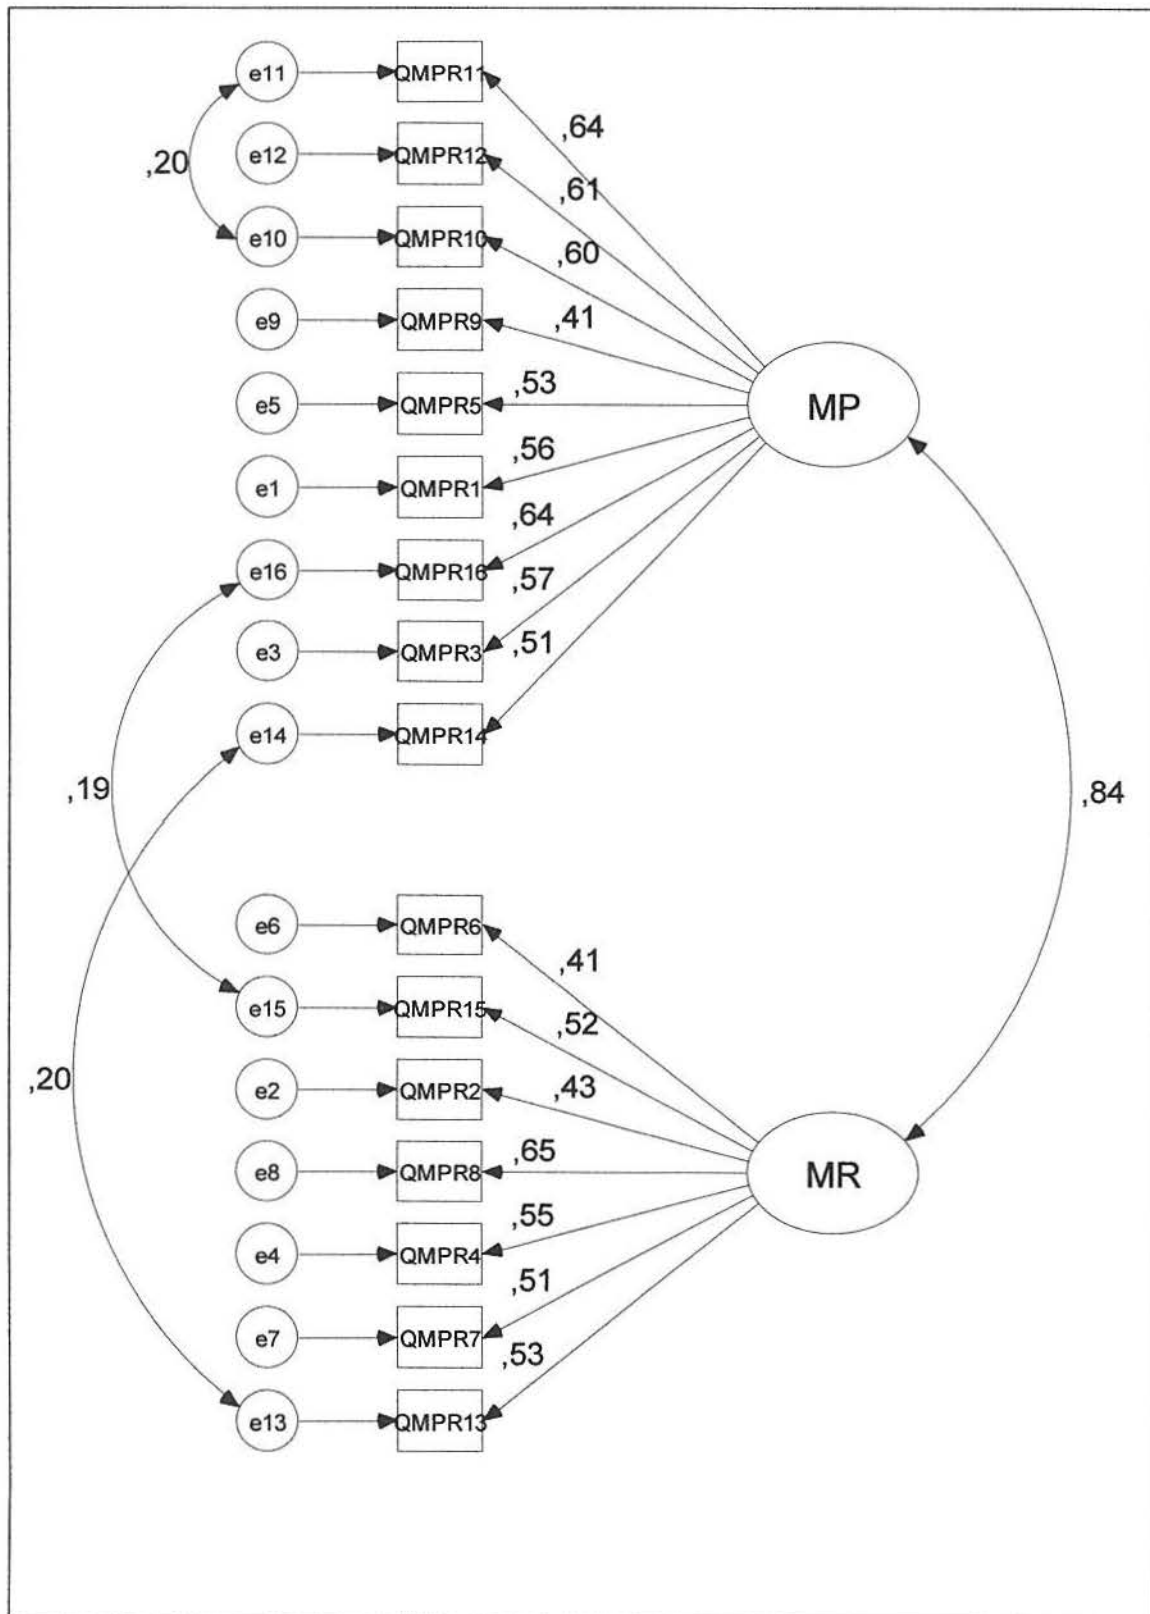


fig. 7.1

Regression Weights			Estimate	S.E.	C.R.	P
QMPR14	<--	MP	0,695	0,071	9,779	0,000
QMPR3	<--	MP	0,817	0,076	10,721	0,000
QMPR16	<--	MP	0,829	0,071	11,695	0,000
QMPR1	<--	MP	0,701	0,067	10,532	0,000
QMPR5	<--	MP	0,805	0,079	10,124	0,000
QMPR9	<--	MP	0,608	0,076	8,042	0,000
QMPR10	<--	MP	0,868	0,069	12,583	0,000
QMPR12	<--	MP	0,885	0,078	11,339	0,000
QMPR11	<--	MP	1,000			
QMPR13	<--	MR	1,333	0,187	7,113	0,000
QMPR7	<--	MR	1,349	0,192	7,029	0,000
QMPR4	<--	MR	1,472	0,202	7,275	0,000
QMPR8	<--	MR	1,747	0,226	7,731	0,000
QMPR2	<--	MR	0,918	0,144	6,388	0,000
QMPR15	<--	MR	1,385	0,195	7,102	0,000
QMPR6	<--	MR	1,000			
Covariances			Estimate	S.E.	C.R.	P
MP	<-->	MR	0,176	0,026	6,774	0,000
e14	<-->	e13	0,108	0,026	4,135	0,000
e16	<-->	e15	0,091	0,024	3,760	0,000
e10	<-->	e11	0,106	0,029	3,685	0,000
Variances			Estimate	S.E.	C.R.	P
		MP	0,389	0,053	7,398	0,000
		MR	0,114	0,027	4,244	0,000
		e14	0,527	0,036	14,757	0,000
		e3	0,532	0,037	14,355	0,000
		e16	0,390	0,028	13,736	0,000
		e1	0,418	0,029	14,447	0,000
		e5	0,629	0,043	14,627	0,000
		e9	0,705	0,046	15,234	0,000
		e10	0,518	0,037	13,927	0,000
		e12	0,504	0,036	13,993	0,000
		e11	0,551	0,041	13,517	0,000
		e13	0,529	0,037	14,299	0,000
		e7	0,579	0,040	14,399	0,000
		e4	0,555	0,040	14,039	0,000
		e8	0,471	0,037	12,809	0,000
		e2	0,432	0,029	14,959	0,000
		e15	0,575	0,040	14,296	0,000
		e6	0,576	0,038	15,058	0,000

tab. 7.3

Na tab. 7.4, dos resíduos padronizados, nenhum valor foi significativo, pois não excederam 2,58.

Standardized Residual Covariances

QMPR	6	15	2	8	4	7	13	11	12	10	9	5	1	16	3	14
6	0	0,792	1,583	-0,58	0,357	1,463	0,489	-1,17	-1,9	-1,52	-0,85	0,108	-1,81	0,051	-0,14	0,024
15	0,792	0,067	-0,07	1,341	0,238	-0,38	0,297	-0,56	-1,74	-1,46	-1,42	0,227	-0,34	-0,06	-0,83	1,993
2	1,583	-0,07	0	-0,72	0,239	0,658	-0,7	-2,21	-1,11	-0,01	-0,07	1,57	-0,59	0,26	2,166	1,12
8	-0,58	1,341	-0,72	0	0,321	-0,36	-0,14	-0,48	-1,81	0,46	1,301	-0,19	-0,61	1,391	0,523	0,008
4	0,357	0,238	0,239	0,321	0	-1,09	-0,41	0,237	-0,89	-0,83	-0,5	-0,25	1,292	0,633	1,096	-0,47
7	1,463	-0,38	0,658	-0,36	-1,09	0	-0,66	0,719	0,652	1,484	-0,71	0,45	-0,59	-0,04	0,526	0,329
13	0,489	0,297	-0,7	-0,14	-0,41	-0,66	0,061	0,91	1,064	-0,08	1,206	0,042	-0,63	0,894	0,419	0,449
11	-1,17	-0,56	-2,21	-0,48	0,237	0,719	0,91	0	1,197	0	1,807	-0,76	-0,26	-0,14	-0,11	-0,62
12	-1,9	-1,74	-1,11	-1,81	-0,89	0,652	1,064	1,197	0	0,051	-0,34	2,128	-0,14	-0,6	-0,77	1,082
10	-1,52	-1,46	-0,01	0,46	-0,83	1,484	-0,08	0	0,051	0	0,543	-0,46	-0,13	0,201	0,953	-1,09
9	-0,85	-1,42	-0,07	1,301	-0,5	-0,71	1,206	1,807	-0,34	0,543	0	0,144	-1,16	-0,11	-1,02	-0,11
5	0,108	0,227	1,57	-0,19	-0,25	0,45	0,042	-0,76	2,128	-0,46	0,144	0	0,963	-1,87	-0,84	0,57
1	-1,81	-0,34	-0,59	-0,61	1,292	-0,59	-0,63	-0,26	-0,14	-0,13	-1,16	0,963	0	0,622	1,333	-1,04
16	0,051	-0,06	0,26	1,391	0,633	-0,04	0,894	-0,14	-0,6	0,201	-0,11	-1,87	0,622	-0,07	-0,88	1,011
3	-0,14	-0,83	2,166	0,523	1,096	0,526	0,419	-0,11	-0,77	0,953	-1,02	-0,84	1,333	-0,88	0	-0,39
14	0,024	1,993	1,12	0,008	-0,47	0,329	0,449	-0,62	1,082	-1,09	-0,11	0,57	-1,04	1,011	-0,39	0,077

tab. 7.4

A tab.7.5 apresenta as estatísticas de ajuste para o modelo 3a.

Fit Measures	CMIN	DF	NPAR	CMINDF	RMR	GFI	AGFI	PGFI
Default model	198,544	100	36	1,985	0,03	0,954	0,937	0,701
Fit Measures	NFI	RFI	IFI	TLI	CFI	PRATIO	PNFI	PCFI
Default model	0,899	0,879	0,947	0,936	0,947	0,833	0,75	0,789
Fit Measures	NCP	NCPLO	NCPHI	FMIN	F0	F0LO	F0HI	
Default model	98,544	62,288	142,587	0,395	0,196	0,124	0,283	
Fit Measures	RMSEA	RMSEALO	RMSEAH1	PCLOSE				
Default model	0,044	0,035	0,053	0,848				
Fit Measures	ECVI	ECVILO	ECVIHI	MECVI	AIC	BCC	BIC	CAIC
Default model	0,538	0,466	0,625	0,543	270,544	273,062	522,370	458,557
Saturated	0,541	0,541	0,541	0,56	272,000	281,514	1223,342	982,270
Independence	3,990	3,711	4,284	3,992	2007,098	2008,218	2119,021	2090,660

tab. 7.5

Todas as estatísticas apresentaram ótimos indicativos da adequação do modelo aos dados amostrais, como CFI=0,947; PCLOSE=0,848; RMSEA=0,044; AIC, BIB, BCC, CAIC e ECVI menores do que para os modelos saturado e de independência. Da mesma forma, a análise dos resíduos e as estimativas dos parâmetros (mostradas anteriormente) reforçam esta consistência encontrada. Esse modelo nos leva a crer que a memória é explicada por dois fatores (memória prospectiva e memória retrospectiva). Como o objetivo deste capítulo é a didática da modelagem, encerraremos por aqui o tratamento deste modelo. Maiores explicações sobre as covariâncias entre os termos de erro e mudanças de itens entre os fatores poderão ser encontradas em Benites (2005).

8 CONCLUSÃO

Modelos de equações estruturais formam um conjunto de técnicas multivariadas muito eficazes para a análise simultânea de variáveis endógenas e exógenas. É um campo muito complexo, abrangendo diversas metodologias estatísticas, como regressão, análise de covariância, análise de trajetórias (*path analysis*) e análise fatorial, e está em grande expansão nos últimos anos. Principalmente no que diz respeito à análise fatorial confirmatória (CFA), que possibilita os pesquisadores de diversas áreas validarem algum instrumento de medida ou confirmarem um construto teórico.

Este trabalho apresentou a metodologia de SEM, com ênfase na CFA realizada através do software AMOS, da empresa SPSS, na versão 4.0, em sua programação gráfica. Mostramos a CFA de primeira ordem e CFA de segunda ordem, onde os fatores de primeira ordem são explicados por uma estrutura de ordem maior. Mas a CFA no software AMOS possibilita ainda a análise de múltiplos grupos, que não foi abordada aqui.

O AMOS é um programa de uso amigável, mas que requer conhecimentos teóricos e muito cuidado ao usar. Apesar de ser fácil modelar visualmente, é preciso saber, por exemplo, como usar contrastes para identificar o modelo, deixando-o com número de graus de liberdade suficiente para proceder às estimativas, e principalmente analisar com cuidado todos os resultados. De nada adianta o modelo estudado apresentar bons índices de ajuste, mas estimar variâncias negativas ou correlações maiores que um. Os resíduos têm grande poder de informação, e juntamente com os índices de modificação e as estatísticas de ajuste, devem ser avaliados.

Mesmo que o modelo apresente ótimos resultados na avaliação numérica, isso não é garantia que ele esteja corretamente especificado (especialmente na CFA). O modelo precisa ser plausível, e este julgamento é de responsabilidade do pesquisador, que deve apresentar fundamentação teórica ou prática para o modelo hipotético.

Por fim, recomendamos a leitura de Bollen (1989) para aprofundamento teórico e de Arbuckle (1999) para detalhamento da programação do software AMOS 4.0.

9 REFERÊNCIAS BIBLIOGRÁFICAS

ARBUCKLE, J. L., & WOTHKE, W. (1999). *AMOS 4.0 User's guide*. Chicago: Smallwaters.

ATKINSON, L. (1988). *The measurement –statistics controversy: Factor analysis and subinterval data*. *Bulletin of the Psychometric Society*, 26, 361-364.

BABAKUS, E., FERGUSON, C. E., Jr., & JORESKOG, K. C. (1987). *The sensitivity of confirmatory maximum likelihood factor analysis to violations of measurement scale and distributional assumptions*. *Journal of Marketing Research*, 24, 222-228.

BECKER, A. T., WARD, C. H., MENDELSON, M., MOCK, J., & ERBAUGH, J. (1961). *An inventory for a measuring depression*. *Archives of General Psychiatry*, 4, 561-571.

BENITES, D. (2005). *Tradução para o português-brasileiro e validação do Prospective and Retrospective Memory Questionnaire (PRMQ)*. UFRGS, Dissertação de Mestrado em Psicologia (em andamento).

BENTLER, P. M. (1995). *EQS: Structural equations program manual*. Encino, CA: Multivariate Software, Inc.

BENTLER, P. M., & CHOU, C. P. (1987). *Practical issues in structural modeling*. *Sociological Methods & Research*, 16, 78-117.

BENTLER, P. M., & WU, E. J. C. (1995). *EQS for Windows: User's Guide*. Encino, CA: Multivariate Software, Inc.

BOLLEN, K. A. (1989). *Structural equations with latent variables*. New York: Wiley.

- BOZDAGAN, H. (1987). *Model selection and Akaike's information criteria (AIC): The general theory and its analytical extensions*. *Psychometrika*, 52, 345-370.
- BYRNE, B. M. (2001). *Structural equation modeling with AMOS: Basic concepts, applications, and programming*. Lawrence Erlbaum Associates. New Jersey: Mahwah.
- CHOU, C. P., BENTLER, P. M., & SATORRA, A. (1991). *Scaled test statistics and robust standard errors for non-normal data in covariance structure analysis: A Monte Carlo study*. *British Journal of Mathematical and Statistical Psychology*, 44, 347-357.
- CRAIK, F. I. M., GOVONI, R., NAVEH-BENJAMIN, M., & ANDERSON, N. (1996). *The Effects of Divided Attention on Encoding and Retrieval Processes in Human Memory*. *Journal of Experimental Psychology: General*, 125 (2), 159-180.
- CRAWFORD, J., SMITH, G., MAYLOR, E. A., SALA, S. D., & LOGIE, R. (2003). *The Prospective and Retrospective Memory Questionnaire (PRMQ): normative data and latent structure in a large non-clinical sample*. *Memory*, 11 (3), 261-275.
- EINSTEIN, G. O. & MCDANIEL, M. A. (1990). *Normal aging and prospective memory*. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 16, 717-726.
- GREEN, S. B., AKEY, T. M., FLEMING, K. K., HERSHBERGER, S. L., & MARQUIS, J. C. (1997). *Structural equation modeling: A multidisciplinary Journal*, 4, 108-120.
- HAIR, J. F., ANDERSON, R. E., THATHAN, R. L. & BLACK, W. C. (1998). *Multivariate data analysis*. 5 ed. Prentice-Hall, New Jersey.
- JORESKOG, K. G. (1990). *New developments in LISREL: Analysis of ordinal variables using polychoric correlations and weighted least squares*. *Quality and Quantity*, 24, 387-404.

MARSH, R., L., HICKS, J. L. & WATSON, V. (2002). *The Dynamics of Intention Retrieval and Coordination of Action in Event-Based in Prospective Memory*. Journal of Experimental Psychology: Learning, Memory, and Cognition, 28 (4), 652-659.

MUTHÉN, B. O. (1984). *A general structural equation model with dichotomous, ordered categorical, and continuous latent variable indicators*. Psychometrika, 49, 115-132.

SANTOS, R. B. (2002). *Modelos de Equações Estruturais*. Monografia Bacharelado em Estatística – UFRGS.

SATORRA, A., & BENTLER, P. M. *Scaling corrections for chi-square statistics in covariance structure analysis. American Statistical Association 1988 proceedings of the business and economics section* (pp. 308-313). Alexandria VA: American Statistical Association.

SHAVELSON, R. J., HUBNER, J. J., & STANTON, G. C. (1976). *Self-concept: Validation of construct interpretations*. Review of Educational Research, 46, 407-441.

SMITH, G., SALA, S. D., LOGIE, R. & MAYLOR, E. A. (2000). *Prospective and retrospective memory in normal aging and dementia: A questionnaire study*. Memory, 8 (5), 311-321.

STEIGER, J. H., & LIND, J. C. (1980). *Statistically based tests for the number of common factors*. Paper presented at the Psychometric Society Annual Meeting, Iowa City, IA.

WOTHKE, W. (1993). *Non-positive definite matrices in structural modeling*. Newbury Park, CA: Sage.

APÊNDICES

Esse apêndice tem por objetivo apresentar as fórmulas das principais estatísticas utilizadas no AMOS. Ele é baseado no livro “*AMOS 4.0 User`s Guide*”, de Arbuckle & Wothke (1999).

APÊNDICE A: Notações

- q = número de parâmetros.
- γ = vetor de parâmetros (de ordem q).
- G = número de grupos.
- $N^{(g)}$ = número de observações no grupo g .
- $N = \sum_{g=1}^G N^{(g)}$, número total de observações em todos os grupos combinados.
- $p^{(g)}$ = número de variáveis observadas no grupo g .
- $p^{*(g)}$ = número de momentos amostrais no grupo g . Quando as médias e os interceptos estão explícitos nos parâmetros do modelo, os momentos amostrais relevantes são as médias, variâncias e covariâncias, de forma que $p^{*(g)} = p^{(g)}(p^{(g)} + 3)/2$.
- $p = \sum_{g=1}^G p^{*(g)}$, número de momentos amostrais em todos os grupos combinados.
- $d = p - q$, número de graus de liberdade para testar o modelo.
- $x_{ir}^{(g)}$ = a r -ésima observação na i -ésima variável do grupo g .
- $X_r^{(g)}$ = a r -ésima observação no grupo g .
- $S^{(g)}$ = matriz amostral de covariância para o grupo g .
- $\sum^{(g)}(\gamma)$ = matriz de covariância para o grupo g , de acordo com o modelo.
- $\mu^{(g)}(\gamma)$ = a média do vetor para o grupo g , de acordo com o modelo.
- $\sum_0^{(g)}$ = matriz de covariância da população para o grupo g .

- $\mu_0^{(g)}$ = média populacional do vetor para o grupo g .
- $s^{(g)} = \text{vec}(S^{(g)})$, os $p^{*(g)}$ elementos distintos de $S^{(g)}$ organizados em vetor uma única coluna.
- $\sigma^{(g)}(\gamma) = \text{vec}\left(\sum^{(g)}(\gamma)\right)$
- r = número inteiro não negativo. Por *default* $r = G$.
- $n = N - r$
- \mathbf{a} = vetor de ordem p contendo os momentos amostrais para todos os grupos. Isto é, \mathbf{a} contém os elementos de $S^{(1)}, \dots, S^{(G)}$, e também (se as médias e os interceptos estão explícitos nos parâmetros do modelo) $\bar{x}^{(1)}, \dots, \bar{x}^{(G)}$.
- α_0 = vetor de ordem p contendo os momentos populacionais para todos os grupos. Isto é, α_0 contém os elementos de $\sum_0^1, \dots, \sum_0^G$, e também (se as médias e os interceptos estão explícitos nos parâmetros do modelo) $\mu^{(1)}, \dots, \mu^{(G)}$. A ordem dos elementos de α_0 deve seguir a ordem dos elementos de \mathbf{a} .
- $\alpha(\gamma)$ = vetor de ordem p contendo os momentos populacionais para todos os grupos de acordo com o modelo. Isto é, $\alpha(\gamma)$ contém os elementos de $\sum^1(\gamma), \dots, \sum^G(\gamma)$, e também (se as médias e os interceptos estão explícitos nos parâmetros do modelo) $\mu^{(1)}(\gamma), \dots, \mu^{(G)}(\gamma)$. A ordem dos elementos de $\alpha(\gamma)$ deve seguir a ordem dos elementos de \mathbf{a} .
- $F(\alpha(\gamma), a)$ = função (de γ) que é minimizada ajustando o modelo para a amostra.
- $\hat{\lambda}$ = valor de λ que minimiza $F(\alpha(\gamma), a)$.
- $\hat{\sum}^{(g)} = \sum^{(g)}(\hat{\gamma})$
- $\hat{\mu}^{(g)} = \mu^{(g)}(\hat{\gamma})$
- $\hat{\alpha} = \alpha(\hat{\gamma})$

APÊNDICE B: Funções de Discrepância para Estimação no AMOS:

Funções que minimizam a discrepância:

$$C(\alpha, a) = (N - r) \left[\frac{\sum_{g=1}^G N^{(g)} f(\mu^{(g)}, \Sigma^{(g)}; \bar{x}, S^{(g)})}{N} \right] = (N - r) F(\alpha, a)$$

As funções de discrepância C_{KL} e F_{KL} (Kullback & Leibler, 1951) são obtidas tomando f como:

$$f_{kl}(\mu^{(g)}, \Sigma^{(g)}; \bar{x}^{(g)}, S^{(g)}) = \log |\Sigma^{(g)}| + \text{tr}(S^{(g)} \Sigma^{(g)^{-1}}) + (\bar{x}^{(g)} - \mu^{(g)}) \Sigma^{(g)^{-1}} (\bar{x}^{(g)} - \mu^{(g)})$$

Para a estimação de Máxima Verossimilhança (ML), C_{ML} e F_{ML} são obtidos tomando f como:

$$\begin{aligned} f_{ML}(\mu^{(g)}, \Sigma^{(g)}; \bar{x}^{(g)}, S^{(g)}) &= f_{kl}(\mu^{(g)}, \Sigma^{(g)}; \bar{x}^{(g)}, S^{(g)}) - f_{kl}(\bar{x}^{(g)}, S^{(g)}; \bar{x}^{(g)}, S^{(g)}) \\ &= \log |\Sigma^{(g)}| + \text{tr}(S^{(g)} \Sigma^{(g)^{-1}}) - \log |S^{(g)}| - p^{(g)} + (\bar{x}^{(g)} - \mu^{(g)}) \Sigma^{(g)^{-1}} (\bar{x}^{(g)} - \mu^{(g)}) \end{aligned}$$

Para a estimação de Mínimos Quadrados Generalizados (GLS), C_{GLS} e F_{GLS} são obtidos tomando f como:

$$f_{GLS}(\Sigma^{(g)}; S^{(g)}) = \frac{1}{2} \text{tr} \left[S^{(g)^{-1}} (S^{(g)} - \Sigma^{(g)})^2 \right]$$

Para a estimação distribuição-livre assintótica (ADF), C_{ADF} e F_{ADF} são obtidos tomando f como:

$$f_{ADF}(\sum^{(g)}; S^{(g)}) = \sum_{g=1}^G [S^{(g)} - \sigma^{(g)}(\gamma)] U^{(g)-1} [S^{(g)} - \sigma^{(g)}(\gamma)]$$

Onde $U^{(g)}$ é dado pelas equações:

$$\bar{x}_i^{(g)} = \frac{1}{N_g} \sum_{r=1}^{N_g} x_{ir}^{(g)},$$

$$w_{ij}^{(g)} = \frac{1}{N_g} \sum_{r=1}^{N_g} (x_{ir}^{(g)} - \bar{x}_i^{(g)})(x_{jr}^{(g)} - \bar{x}_j^{(g)})$$

$$w_{ij,kl}^{(g)} = \sum_{r=1}^{N_g} (x_{ir}^{(g)} - \bar{x}_i^{(g)})(x_{jr}^{(g)} - \bar{x}_j^{(g)})(x_{kr}^{(g)} - \bar{x}_k^{(g)})$$

$$[U^{(g)}]_{ij,kl} = w_{ij,kl}^{(g)} - w_{ij}^{(g)} w_{kl}^{(g)}$$

Para a estimação por mínimos quadrados de escala livre (SLS), C_{SLS} e F_{SLS} são obtidos tomando f como:

$$f_{SLS}(\sum^{(g)}; S^{(g)}) = \frac{1}{2} tr [D^{(g)-1} (S^{(g)} - \sum^{(g)})^2]$$

Onde $D^{(g)} = \text{diag}(S^{(g)})$.

Para a estimação por mínimos quadrados não balanceados (*unweighted*) (ULS), C_{ULS} e F_{ULS} são obtidos tomando f como:

$$f_{ULS}(\sum^{(g)}; S^{(g)}) = \frac{1}{2} tr [S^{(g)} - \sum^{(g)}]^2$$

APÊNDICE C: Medidas de Ajuste

- **NPAR:** número de parâmetros distintos a serem estimados. Expressa o número de contrastes no modelo avaliado como uma fração do número de contrastes no modelo independente.

$$\text{NPAR} = q$$

- **DF :** número de graus de liberdade para testar o modelo.
DF = d = p - q , onde p = número de momentos amostrais.

- **PRATIO:** Razão de Parcimônia.

PRATIO = d/d_i, onde d_i = número de graus de liberdade do modelo de independência.

- **CMIN:** é o valor mínimo, \hat{C} , da discrepância, C (veja Apêndice B).
- **P:** *p-value* para testar que a hipótese de que o modelo se ajusta perfeitamente na população.

- **CMIN/DF:** discrepância mínima dividida pelos graus de liberdade.

$$\text{CMIN/DF} = \frac{\hat{C}}{d}$$

- **FMIN:** \hat{F} - valor mínimo da discrepância F (veja Apêndice B).

- **NCP:** é uma estimativa do parâmetro de não centralidade, $\delta = C_0 = nF_0$

As colunas chamadas **LO90** e **HI 90** contém o limite inferior (δ_L) e o limite superior (δ_U) do intervalo de 90% de confiança, com δ, δ_L obtido resolvendo:

$$\Phi(\hat{C} / \delta, d) = 0.95$$

e δ, δ_U obtido resolvendo:

$$\Phi(\hat{C} / \delta, d) = 0.05$$

Para δ , onde $\Phi(x/\delta, d)$ é a função de distribuição de uma distribuição qui-quadrada não central com parâmetro de não centralidade δ e d graus de liberdade.

- **FO**

$$FO = \hat{F}_0 = \max\left(\frac{\hat{C} - d}{n}, 0\right) = \frac{NCP}{n}. \text{ É uma estimativa de } \frac{\delta}{n} = F_0.$$

As colunas chamadas **LO90** e **HI 90** contém o limite inferior e o limite superior do intervalo de 90% de confiança para F_0 :

$$LO90 = \sqrt{\frac{\delta_L}{n}}$$

$$HI90 = \sqrt{\frac{\delta_u}{n}}$$

- **RMSEA: “root mean square error of approximation”**

F_0 não penaliza a complexidade do modelo e tenderá a favor de modelos com muitos parâmetros. Na comparação de dois modelos, F_0 nunca será a favor do modelo mais simples. Steiger e Lind (1980) sugerem a compensação para este problema dividindo F_0 pelos números de graus de liberdade do modelo.

$$RMSEA = \sqrt{\frac{F_0}{d}} \text{ da população.}$$

$$RMSEA = \sqrt{\frac{\hat{F}_0}{d}} \text{ estimado.}$$

As colunas chamadas **LO90** e **HI 90** contém o limite inferior e o limite superior do intervalo do **RMSEA** de 90% de confiança para a população:

$$LO90 = \sqrt{\frac{\delta_L / n}{d}}$$

$$LO90 = \sqrt{\frac{\delta_U / n}{d}}$$

- **PCLOSE:** é o *p-value* do teste de $H_0: RMSEA \leq 0.05$

$$PCLOSE = 1 - \phi(\hat{C}0.05^2 nd.d)$$

O p -value de P (anteriormente descrito) testa $H_0: RMSEA=0$.
 $RMSEA \leq 0.05$ indica ótimo ajuste.

- **AIC:** Akaike Information Criterion

$$AIC = \hat{C} + 2q$$

- **BCC:** The Browne-Cudeck Criteriion

$$BCC = \hat{C} + 2q \frac{\sum_{g=1}^G b^{(g)} \frac{p^{(g)}(p^{(g)} + 3)}{N^{(g)} - p^{(g)} - 2}}{\sum_{g=1}^G p^{(g)}(p^{(g)} + 3)}$$

Onde $b^{(g)} = n \frac{N^{(g)}}{N}$

- **BIC:** Bayes Information Criterion

$$BIC = \hat{C} + q \ln(N^{(1)} p^{(1)}).$$

BIC penaliza mais a complexidade do modelo, se comparado ao AIC, BCC e CAIC.

- **CAIC:** Consistent AIC

$$CAIC = \hat{C} + q(\ln N^{(1)} + 1).$$

Maior penalidade para a complexidade do modelo, se comparado ao AIC ou BBC.

- **ECVI:**

$$ECVI = \frac{1}{n}(AIC) = \hat{F} + \frac{2q}{n}.$$

As colunas chamadas **LO90** e **HI 90** contém o limite inferior e o limite superior do intervalo do **ECVI** de 90% de confiança para a população:

$$LO90 = \frac{\delta_L + d + 2q}{n}$$

$$HI90 = \frac{\delta_U + d + 2q}{n}$$

- **MECVI:**

$$MECVI = \frac{1}{n} BCC$$

- **NFI: Normed Fit Index**

$$NFI = \Delta_1 = 1 - \frac{\hat{C}}{\hat{C}_b} = 1 - \frac{\hat{F}}{\hat{F}_b}$$

Onde $\hat{C} = n\hat{F}$ é a mínima discrepância do modelo avaliado e $\hat{C}_b = n\hat{F}_b$ é a mínima discrepância do modelo usado como referência.

- **RFI: Relative Fit Index**

$$RFI = p_1 = 1 - \frac{\hat{C}/d}{\hat{C}_b/d_b} = 1 - \frac{\hat{F}/d}{\hat{F}_b/d_b}$$

Onde \hat{C} e d são as discrepâncias e os graus de liberdade do modelo que está sendo avaliado, e \hat{C}_b e d_b são as discrepâncias e os graus de liberdade do modelo usado como referência.

- **IFI: Incremental Fit Index**

$$IFI = \Delta_2 = \frac{\hat{C}_b - d}{\hat{C}_b - d_b}$$

Onde \hat{C} e d são as discrepâncias entre os graus de liberdade do modelo que está sendo avaliado, e \hat{C}_b e d_b são as discrepâncias entre os graus de liberdade do modelo referência. Valores de IFI pertos de 1 indicam excelente ajuste.

- **TLI: Tucker-Lewis Index**

$$TLI = p_2 = \frac{\frac{\hat{C}_b}{d_b} - \frac{\hat{C}}{d}}{\frac{\hat{C}_b}{d_b} - 1}$$

- **CFI:** *Comparative Fit index*

$$CFI = 1 - \frac{\max(\hat{C} - d, 0)}{\max(\hat{C}_b - d, 0)} = 1 - \frac{NCP}{NCP_b}$$

Valores de CFI pertos de 1 indicam excelente ajuste ($0 \leq CFI \leq 1$).

- **PNFI:** *Parsimony NFI*

$$PNFI = (NFI)(PRATIO) = NFI \frac{d}{d_b}$$

Onde d graus de liberdade do modelo que está sendo avaliado e d_b graus de liberdade do modelo referência.

- **PCFI:** *Parsimony CFI*

$$PCFI = (CFI)(PRATIO) = CFI \frac{d}{d_b}$$

Onde d é os graus de liberdade do modelo que está sendo avaliado e d_b graus de liberdade do modelo referência.

- **GFI:** *Goodness of Fit Index*

$$GFI = 1 - \frac{\hat{F}}{\hat{F}_b}$$

Onde \hat{F} é o valor mínimo da função de discrepância definida no Apêndice B e \hat{F}_b é obtida na avaliação de F com $\sum^{(g)} = 0$, $g=1, 2, \dots, G$.

- **AGFI:** *Adjusted Goodness of Fit Index*

$$AGFI = 1 - (1 - GFI) \frac{d_b}{d}$$

Onde $d_b = \sum_{g=1}^G p^{*(g)}$

- **PGFI:** *Parsimony GFI*

$$PGFI = GFI \frac{d}{d_b}$$

Onde d é os graus de liberdade do modelo que está sendo avaliado e

$$d_b = \sum_{g=1}^G p^{*(g)} \text{ é os graus de liberdade do modelo referência.}$$

- **HOELTER:** *Critical N*

É o maior tamanho da amostra para a qual iria aceitar a hipótese de que o modelo está correto.

- **RMR:** *Root Mean Square Residual*

Raiz quadrada das médias ao quadrado dos valores com que as covariâncias e variâncias amostrais diferem de suas estimativas, obtidas sobre a suposição de que o modelo está correto. Quanto menor RMR, melhor. RMR=0 indica ajuste perfeito.

$$RMR = \sqrt{\frac{\sum_{g=1}^G \left\{ \sum_{i=1}^{P_g} \sum_{j=1}^{j \leq i} (\hat{s}_{ij}^{(g)} - \sigma_{ij}^{(g)}) \right\}}{\sum_{g=1}^G p^{*(g)}}$$