

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL**  
**ESCOLA DE ENGENHARIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**MODELAGEM DE EQUAÇÕES ESTRUTURAIS:  
apresentação de uma metodologia**

**Juliane Silveira Freire da Silva**

Porto Alegre  
2006

**JULIANE SILVEIRA FREIRE DA SILVA**

**MODELAGEM DE EQUAÇÕES ESTRUTURAIS:  
APRESENTAÇÃO DE UMA METODOLOGIA**

Dissertação submetida ao Programa de Pós  
Graduação em Engenharia de Produção  
como requisito parcial à obtenção do título  
de MESTRE EM ENGENHARIA DE  
PRODUÇÃO – Área de Concentração:  
Gerência da Qualidade, da Universidade  
Federal do Rio Grande do Sul.

Orientadora: Liane Werner, Dra.

Porto Alegre  
2006

JULIANE SILVEIRA FREIRE DA SILVA

**MODELAGEM DE EQUAÇÕES ESTRUTURAIS**  
**APRESENTAÇÃO DE UMA METODOLOGIA**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção.

---

**Liane Werner, Dra.**  
PPGEP/UFRGS  
Orientadora

---

**Prof. Luis Antonio Lindau, Ph.D.**  
Coordenador PPGEP/EE/UFRGS

**Banca Examinadora**

**Cláudio Damacena, Dr.**

Prof. Centro de Ciências Econômicas Universidade do Vale dos Sinos

**Jandyra Maria Guimarães Fachel, Ph. D.**

Prof<sup>a</sup>. Departamento de Estatística / UFRGS

**Márcia Echeveste, Dra.**

Prof<sup>a</sup>. Programa de Pós-Graduação em Engenharia de Produção / UFRGS

Dedico esse trabalho a minha  
querida avó, que sempre esteve  
ao meu lado como uma fortaleza  
me apoiando, e é meu exemplo  
de vida.

*Aprender é a única coisa de que a mente nunca se cansa, nunca tem medo e nunca se arrepende.*

*(Leonardo da Vinci)*

## AGRADECIMENTOS

Agradeço ao Programa de Pós-Graduação em Engenharia de Produção, em especial ao Professor Dr. Flávio Sanson Fogliato por sua atenção e ensinamentos prestados durante a bolsa de iniciação científica e também durante o mestrado e orientação.

A Professora Dra. Liane Werner por ter me aceitado como sua orientada e ter me ajudado a concluir esse trabalho, com dedicação e paciência.

Ao Dr. Gabriel Milan por ceder os dados de sua pesquisa para que eu pudesse realizar a análise nesse trabalho.

Ao Bacharel em Estatística Cristiano Lemke pela ajuda prestada com o software AMOS.

Aos muitos amigos que sempre me deram palavras de apoio e incentivo para a concretização desse trabalho, em especial as colegas de mestrado, Luciane Weber, Patrícia Klaser Biasoli, Melissa Gernhardt, Fabiane Brand e Tatiane Fachinello. À amiga do coração, Roselaine Batista, aos colegas de trabalho que sempre me ajudaram a continuar e chegar até aqui.

À minha família que apesar de pequena tem uma força enorme. A minha mãe que muitas vezes teve que entender meu mau humor, a minha avó que nunca saiu do meu lado e me apoiou em todos os momentos de “baixa”, ao meu pai pela paciência e por muitas tardes ao meu lado com o incansável trabalho de tradução de artigos e a minha madrasta que soube entender os momentos que necessitava do auxílio do meu pai.

Enfim, agradeço a todos que de alguma maneira colaboraram com esse trabalho e com o meu crescimento.

## Sumário

RESUMO .....	8
ABSTRACT .....	9
1 INTRODUÇÃO .....	10
1.1 Comentários Iniciais .....	10
1.2 Tema e Justificativa .....	11
1.3 Objetivos .....	13
1.3.1 <i>Objetivo Geral</i> .....	13
1.3.2 <i>Objetivos específicos</i> .....	13
1.4 Metodologia .....	14
1.5 Limitações da dissertação .....	15
1.6 Estrutura .....	16
2 MODELAGEM DE EQUAÇÕES ESTRUTURAIS .....	17
2.1 Introdução .....	17
2.2 Distinção entre variáveis (ou construtos) latentes e variáveis observadas .....	24
2.2.1 <i>Análise de dados categóricos em SEM</i> .....	26
2.2.2 <i>Variáveis latentes exógenas e variáveis latentes endógenas</i> .....	26
2.3 Análise de Caminhos ( <i>Path Analysis</i> ) .....	28
2.3.1 <i>Modelo de Caminho (path models)</i> .....	31
2.4 Análise fatorial confirmatória .....	33
2.4.1 <i>Requisitos para identificação de modelo AFC</i> .....	35
2.5 Estimação de coeficientes em SEM e verificação do modelo .....	36
2.6 Características dos três pacotes computacionais (AMOS, EQS e LISREL) .....	43
2.6.1 <i>AMOS</i> .....	45
3 ESTÁGIOS PARA A UTILIZAÇÃO DA MODELAGEM DE EQUAÇÕES ESTRUTURAIS .....	47
3.1 Estágio 1: Desenvolvendo um modelo teórico .....	48
3.2 Estágio 2: Construção de diagrama de caminhos de relações causais .....	49
3.3 Estágio 3: Conversão do diagrama de caminhos em um conjunto de modelos estrutural e de mensuração .....	52
3.4 Estágio 4: Escolha do tipo de matriz de entrada e estimação do modelo proposto .....	53
3.5 Estágio 5: Avaliação da identificação do modelo estrutural .....	57
3.6 Estágio 6: Avaliação de critérios de bondade de ajuste .....	58
3.7 Estágio 7: Interpretação e modificação do modelo .....	60
4 APLICAÇÃO DE SEM EM UM ESTUDO PRÁTICO .....	62
4.1 Desenvolvimento de um modelo teórico .....	63
4.2 Construção de diagrama de caminhos de relações causais .....	63
4.3 Estágio 3: Conversão do diagrama de caminhos em um conjunto de modelos estrutural e de mensuração .....	65
4.4 Estágio 4: Escolha do tipo de matriz de entrada e estimação do modelo proposto .....	66
4.5 Estágio 5: Avaliação da identificação do modelo estrutural .....	69
4.6 Estágio 6: Avaliação de critérios de qualidade do ajuste .....	70
4.7 Estágio 7: Interpretação e modificação do modelo .....	72
5 CONCLUSÃO .....	83
5.1 Considerações Finais .....	83
5.2 Trabalhos futuros .....	85
Referências .....	87
ANEXO A: Demais índices utilizados em SEM .....	90
ANEXO B – Questionário .....	93
APÊNDICE A - Forma tabular retirada da saída do AMOS .....	95
APÊNDICE B – Índices de modificação fornecidos pelo AMOS .....	97
APÊNDICE C – Pesos de regressão fornecidos pelo AMOS .....	103

## RESUMO

Um dos principais objetivos das técnicas multivariadas é expandir a habilidade exploratória do pesquisador e a eficiência estatística. Entretanto, todas elas compartilham de uma limitação: cada técnica pode examinar somente uma relação entre as variáveis. Algumas vezes é interessante para o pesquisador o fato de ter relações simultâneas, em alguns modelos existem variáveis que são independentes em algumas relações e, dependentes em outras. Visando suprir esta necessidade, a Modelagem de Equações Estruturais examina uma série de relações de dependência simultaneamente, esse método é particularmente útil quando uma variável dependente se torna independente em relações subsequentes de dependência. Com o intuito de aproximar a metodologia da área de Engenharia de Produção, essa dissertação apresenta uma descrição das técnicas relacionadas à Modelagem de Equações Estruturais como: a Análise Fatorial Confirmatória e a Análise de Caminhos; aborda conceitos e testes específicos de Modelagem de Equações Estruturais e também aborda um software, o AMOS. Para complementar o trabalho mostra uma aplicação prática sobre a Modelagem utilizando dados de uma pesquisa para se medir a opinião de clientes com relação a um provedor de serviços.

Palavras-chave: Modelagem de Equações Estruturais, Análise Fatorial Confirmatória, AMOS.



## **ABSTRACT**

One of the principal goals of the multivariate techniques is to expand the researcher's exploratory ability and the statistical efficiency. However, all of them share of a limitation: each technique can examine only a relationship among the variables. It is sometimes interesting for the researcher the fact of having simultaneous relationships, in some models variables that are independent in some relationships and dependent in other one. Seeking to supply this need the Structural Equations Modeling examines a series of dependence relationships simultaneously, that method is particularly useful when a dependent variable becomes independent in subsequent relationships of dependence. Starting from bibliographical references on the theme and with the intention of approximating the methodology of Industrial Engineering area, this dissertation presents a description of the techniques related to the Structural Equations Modeling as: the Confirmatory Factor Analysis and the Path Analysis; it approaches concepts and specific tests of Structural Equations Modeling and it also focuses a software, the AMOS. To complement, the dissertation shows a practical application on the Structural Equations Modeling using data of a research, in order to measure the customers' opinion related to a provider of services.

Key-words: Structural Equations Modeling, Confirmatory Factor Analysis, AMOS.

# 1 INTRODUÇÃO

## 1.1 Comentários Iniciais

Um dos principais objetivos das técnicas multivariadas é expandir a habilidade exploratória do pesquisador e tratar das interações entre variáveis simultaneamente. Análise fatorial, análise multivariada de variância (MANOVA), análise discriminante e outras técnicas multivariadas fornecem poderosas ferramentas para abordar uma vasta gama de questões administrativas e teóricas. As técnicas que permitem múltiplas variáveis dependentes, tais como análise multivariada de variância e análise canônica, tem como foco as relações entre as variáveis dependentes e independentes. Algumas vezes é interessante para o pesquisador o fato de ter relações simultâneas, em alguns modelos existem variáveis que são independentes em algumas relações e, dependentes em outras. Suprindo essa necessidade de abordar relações simultâneas de dependência, a Modelagem de Equações Estruturais examina uma série de relações de dependência simultaneamente. Sendo assim, esse método é particularmente útil quando uma variável dependente se torna independente em relações subsequentes de dependência. Esse conjunto de relações - cada uma com variáveis dependentes e independentes - é a base da Modelagem de Equações Estruturais (HAIR *et al.*, 1998).

A Modelagem de Equações Estruturais leva em conta o modelo de interações causais entre as variáveis e o erro de mensuração (grau onde as variáveis que podem ser medidas não descrevem perfeitamente grupos de variáveis que não são medidos diretamente, denominados construtos latentes). Como casos particulares da Modelagem de Equações Estruturais temos os seguintes modelos: regressão múltipla, análise de caminho (*path analysis*), análise fatorial exploratória e análise de covariância. A técnica é uma extensão do modelo linear geral (GLM – do inglês *General Linear Model*) do qual a regressão múltipla faz parte, podendo ser interpretada como uma extensão de várias técnicas multivariadas.

O termo Modelagem de Equações Estruturais (SEM – do inglês, *Structural Equation Modeling*) não designa uma única técnica, mas uma família de procedimentos. Outros termos como análise de covariância estrutural, modelo estrutural de covariância, ou análise de estruturas de covariância, também são usados na literatura para classificar essas várias técnicas dentro de um único rótulo (KLINE, 1998). Sua diferença em relação a essas técnicas multivariadas é que, através da SEM, pode-se examinar uma série de relações de dependência simultaneamente (HOYLE, 1995; HAIR *et al.*, 1998).

Comparada à regressão e à análise fatorial, a SEM é uma técnica relativamente nova. A SEM tem sido usada em quase todas as áreas de estudo, incluindo educação, marketing, psicologia, sociologia, administração, saúde, demografia, comportamento organizacional, biologia e genética. As razões para o interesse por essa técnica em tantas áreas são: a) fornecer um método direto para lidar com múltiplas relações simultaneamente com eficiência estatística e b) permitir avaliar as relações em âmbito geral e fornecer uma transição da análise exploratória para a análise confirmatória (HAIR *et al.*, 1998).

A SEM admite um grande número de variáveis dependentes e independentes. As variáveis observadas podem ser fatoradas, através de análise fatorial para formar os construtos latentes (construtos que não podem ser medidos diretamente por serem subjetivos, sendo obtidos através de variáveis observáveis). A Modelagem de Equações Estruturais é um método mais confirmatório do que exploratório, onde se faz necessário construir um modelo em termos de um sistema de efeitos unidirecionais de uma variável sobre outra em um diagrama de caminho (GOLOB, 2003).

## **1.2 Tema e Justificativa**

A Modelagem de Equações Estruturais foi escolhida para tema deste trabalho por ser uma técnica ainda pouco explorada em aplicações de Engenharia e com grande potencial na análise estatística de dados. De acordo com as pesquisas realizadas em sites acadêmicos e de artigos existem muitos artigos publicados especialmente em marketing, psicologia, medicina e genética, biologia, porém poucos publicados nas áreas de exatas como a engenharia, aproximadamente 20% dos artigos são publicados nessa área comparando às acima citadas, até o presente momento. Na área de engenharia de produção existem menos artigos publicados, onde talvez ainda não exista o conhecimento necessário para a utilização da técnica, nem tampouco o conhecimento das vantagens de sua utilização.

A Modelagem de Equações Estruturais passa a ser útil em casos onde algumas premissas necessárias para a utilização da análise multivariada de dados não são verificadas. A SEM é uma técnica emergente que possui suposições pouco restritivas nos seus modelos, o que garante uma grande aplicabilidade em comparação com as técnicas estatísticas multivariadas usuais.

Verifica-se que a SEM pode ser usada mais largamente na indústria em áreas de Ergonomia e Segurança do Trabalho (algumas das subdivisões da engenharia de produção), onde se busca verificar o relacionamento do usuário com o produto a ser utilizado, em Engenharia de Produto, seja na parte de desenvolvimento do produto ou no momento de verificar a satisfação do usuário com o produto, e em Estratégia e Organizações, para avaliação do mercado ou no marketing estratégico industrial.

A SEM é aplicável em subáreas da Ergonomia e Segurança do Trabalho, como por exemplo a Psicologia do Trabalho, onde se pode realizar um estudo com os funcionários na linha de montagem de uma empresa, considerando o efeito de vários fatores, como: ambiente, iluminação e horário de almoço, sobre a satisfação do funcionário e sua produtividade. Dependendo do objetivo, neste exemplo as técnicas já conhecidas de modelagem multivariada não seriam apropriadas, pois existem várias relações de dependência entre as variáveis e não é possível avaliar o erro de mensuração que pode ser significativo e, conseqüentemente, incorporado na análise. Esses pontos são contemplados pela SEM.

Em Engenharia do Produto a SEM pode ser utilizada especialmente em pesquisa de mercado. Por exemplo, uma empresa automobilística quer avaliar um novo carro que está entrando no mercado quanto à satisfação do consumidor com o produto. Existem vários construtos que podem ser formulados como desempenho, *design*, economia e razão custo-benefício. Nesta situação, talvez pudesse ser utilizada a análise fatorial (que é comumente utilizada nesses casos para a formação dos construtos), mas essa análise não permitiria a validação de um modelo de medida (submodelo em SEM que especifica os indicadores para cada construto e avalia a confiabilidade de cada construto para estimar relações causais) como a Modelagem de Equações Estruturais permite. Essa técnica já é muito utilizada em pesquisas na área de marketing e administração.

Outros exemplos de aplicações na área de Engenharia podem ser encontrados na literatura. Por exemplo, Koufteros (1998) utilizou a resposta de 244 empresas para testar modelos de produção puxada<sup>1</sup> usando a análise de SEM, onde o modelo estrutural hipotetizado relaciona a produção puxada com dois de seus fatores antecedentes, melhoria de montagem e as práticas de manutenção preventiva, posteriormente a produção puxada é relacionada a uma de suas respostas, a dependência de entrega, nesse mesmo modelo. Em outro exemplo, Matos *et al.* (2004) realizaram uma pesquisa com 398 proprietários de automóveis de uma capital brasileira para investigar a influência que as notícias de *recall* exercem nas percepções dos consumidores, bem como os

---

<sup>1</sup> Produção realizada de acordo com a demanda do cliente para reduzir o desperdício

fatores que interferem nesse processo. Com base em pesquisas anteriores e na teoria de comportamento do consumidor foi desenvolvido um modelo relacionando os construtos a) envolvimento com o produto; b) envolvimento com a notícia de *recall*; c) responsabilidade social percebida; d) atribuição de culpa; e) perigo percebido no problema com os construtos imagem percebida e as intenções comportamentais dos consumidores.

Devido ao fato de que a SEM é uma técnica muito útil em várias áreas, seja da engenharia, ou outras áreas, decidiu-se por investigar essa técnica mais detalhadamente e explorar os estágios para a utilização da mesma, bem como conhecer um aplicativo que realiza a modelagem.

### **1.3 Objetivos**

#### *1.3.1 Objetivo Geral*

Nesse trabalho, propõe-se criar mecanismos para ampliar a aplicação de Modelagem de Equações Estruturais, tendo como objetivo principal apresentar uma metodologia para a utilização da SEM, a partir de referências bibliográficas sobre o tema.

#### *1.3.2 Objetivos específicos*

Como objetivos secundários têm-se:

- a) fazer um levantamento do referencial teórico das aplicações, em especial nas áreas de Engenharia;
- b) abordar os aplicativos mais conhecidos em SEM, como o LISREL, EQS, AMOS;
- c) apresentar uma descrição do aplicativo AMOS;
- d) realizar uma aplicação da SEM, utilizando dados de uma pesquisa realizada para entender como uma empresa poderia explicar o relacionamento com os seus clientes.

## 1.4 Metodologia

A metodologia de pesquisa deste trabalho, do ponto de vista da sua natureza, é do tipo pesquisa aplicada, pois tem por objetivo gerar conhecimentos para uma aplicação prática, tendo uma abordagem quantitativa. Essa abordagem considera que tudo pode ser quantificável, podendo traduzir em números, opiniões e informações para classificá-los e analisá-los com o uso de recursos computacionais e de técnicas estatísticas.

Quanto aos objetivos da pesquisa, essa será uma pesquisa exploratória o que, segundo Gil (1991), visa proporcionar maior familiaridade com o problema com vistas a torná-lo explícito ou a concluir hipóteses, envolvendo o levantamento bibliográfico, entrevistas e análise de exemplos. O trabalho apresentará uma pesquisa bibliográfica a partir de material já publicado em livros, artigos de periódicos e publicações da *internet*. Também será apresentada uma aplicação com dados de uma pesquisa que envolve o estudo de alguns objetos de maneira que se permita o seu amplo e detalhado conhecimento.

Uma pesquisa também pode ser definida como a construção de conhecimento original de acordo com certas exigências científicas. Para que um estudo seja considerado científico deve obedecer aos critérios de coerência, consistência, originalidade e objetivação. É desejável que uma pesquisa científica preencha os seguintes requisitos: a) existência de uma pergunta que se deseja responder; b) elaboração de um conjunto de passos que permitam chegar à resposta; e c) indicação do grau de confiabilidade na resposta obtida (GOLDEMBERG, 1999). O planejamento de uma pesquisa dependerá basicamente de três fases: a) fase decisória, referente a escolha do tema, definição e delimitação do problema de pesquisa; b) fase construtiva, referente à construção de um plano de pesquisa e à execução da pesquisa propriamente dita; e c) fase de redação, referente à análise dos dados e informações obtidas na fase construtiva.

Segundo Eisenhardt (1989), a aplicação prática pode ser utilizada para atingir, principalmente, dois objetivos: descrever uma situação e testar teorias. Em relação à descrição de uma situação, utiliza-se uma experimentação prática com o objetivo de explicar como ocorre a inter-relação de seus fatores na construção de uma realidade específica. O objetivo de testar teorias pressupõe a utilização de um referencial teórico inicial para o qual se deseja comprovar a validade prática. A aplicação prática, então, é planejada e conduzida de modo a criar um cenário capaz de dar subsídios para refutar ou validar as hipóteses iniciais, ou seja, rejeitar ou aceitar teorias.

Com base no referencial teórico acima, o desenvolvimento deste trabalho pode ser resumido nas seguintes etapas:

- a) a primeira etapa está baseada no levantamento bibliográfico em livros, artigos e *Internet*, sobre Modelagem de Equações Estruturais e técnicas utilizadas conjuntamente em SEM, como a análise de caminhos, modelos de caminhos e Análise Fatorial Confirmatória;
- b) a segunda etapa envolve o conhecimento dos passos a serem realizados para a utilização da Modelagem de Equações Estruturais. Serão estudados nesse trabalho os estágios sugeridos por Hair *et al.* (1999) e algumas considerações de outros autores a respeito do tema;
- c) a terceira etapa compreende o conhecimento e aplicação do *software* AMOS, um dos aplicativos específicos que pode ser utilizado para a análise da SEM. E uma breve citação dos outros dois *softwares* importantes em SEM: o LISREL e o EQS;
- d) na quarta etapa, será realizada uma aplicação prática, de acordo com o conhecimento obtido neste trabalho, que envolverá a análise de um modelo que melhor se adequará aos dados segundo a teoria de Modelagem de Equações Estruturais e os estágios sugeridos para a sua utilização.

### **1.5 Limitações da dissertação**

Este trabalho faz uma revisão bibliográfica sobre a Modelagem de Equações Estruturais, as técnicas a ela relacionadas e os estágios para a sua realização. Uma das maiores limitações do trabalho encontra-se no fato de haver pouca bibliografia a respeito da maneira de se conduzir a Modelagem, os artigos publicados apenas realizam a aplicação, mas raros autores explicam como se chega aos resultados.

Um dos objetivos deste trabalho visa divulgar a técnica de Modelagem de Equações Estruturais para uma aplicação mais ampla em campos variados, no caso particular a Engenharia, onde seu uso ainda é muito restrito, por isto, outros campos de estudo e aplicações de SEM não serão abordados.

A Modelagem de Equações Estruturais é uma técnica estatística importante, e, para que se possa realizar a modelagem adequadamente, o auxílio de softwares

dedicados é essencial. No entanto devido a incipência de publicações sobre a utilização em programas específicos de computador que realizam a operação de Modelagem, limitou-se a explorar apenas um dos softwares disponíveis para a SEM, o AMOS.

## 1.6 Estrutura

Este trabalho está dividido em cinco capítulos, com os conteúdos descritos a seguir.

No Capítulo 1 são apresentados comentários iniciais, tema e justificativa, objetivos, metodologia e limitações da dissertação e esta estrutura.

O Capítulo 2 traz alguns conceitos sobre a análise de equações estruturais, os métodos básicos da SEM, como a análise de caminhos (*path analysis*) e modelos de caminhos (*path models*). Também são apresentados os princípios fundamentais para a distinção entre variáveis latentes e variáveis observadas, e uma apresentação sobre análise fatorial confirmatória. Por fim, apresentam-se algumas considerações a respeito dos três pacotes computacionais mais utilizados para a SEM: AMOS, EQS e LISREL.

No Capítulo 3, são descritos de forma detalhada os passos necessários para a Modelagem de Equações Estruturais. Apresenta-se ao leitor usuário um roteiro para a utilização do SEM, baseado em Hair *et al.* (1998), visando auxiliar no procedimento e compreensão de como se estabelece, modela e interpreta Modelos de Equações Estruturais.

O Capítulo 4 traz uma aplicação da Modelagem de Equações Estruturais em dados oriundos de uma pesquisa realizada com clientes de uma empresa, a fim de analisar a retenção dos mesmos. Para a construção dos Modelos de Equações Estruturais, será utilizado o *software* AMOS.

O Capítulo 5 encerra esta dissertação apresentando considerações finais e indicações para o desenvolvimento de trabalhos futuros.



## 2 MODELAGEM DE EQUAÇÕES ESTRUTURAIS

### 2.1 Introdução

O conceito de Modelagem de Equações Estruturais foi introduzido há aproximadamente 80 anos por Sewall Wright. Ele trabalhou com padrões de covariância entre várias características de porcos *Guinea*. Também desenvolveu uma maneira de transformar as correlações observadas num sistema de equações que descrevia matematicamente suas hipóteses concernentes as relações causais. Essas relações entre as variáveis foram representadas num diagrama de caminhos. Esse método ficou conhecido como análise de caminhos. Mais tarde esse método foi independentemente redescoberto por economistas e sociólogos, principalmente por Jöreskog (1973; 1977; 1981) e por Jöreskog & Sörbom (1982). Eles transformaram a análise de caminhos de Sewall Wright em uma nova técnica chamada de Modelagem de Equações Estruturais, que combinava a análise fatorial com a análise de caminhos e que era capaz de testar, além de simplesmente descrever, as relações causais (IRIONDO *et al.*, 2003).

A SEM é resultante de uma evolução da modelagem multiequação, desenvolvida principalmente na Econometria e originada dos princípios de mensuração da Psicologia e Sociologia. Ela surgiu como uma técnica completa tanto para a pesquisa acadêmica quanto administrativa. A SEM também pode ser usada como um meio de estimar outros modelos multivariados, incluindo regressão, componentes principais, correlação canônica e até mesmo MANOVA (HAIR *et al.*, 1998).

Segundo Hair *et al.* (1998), a Modelagem de Equações Estruturais compartilha três premissas básicas com outras técnicas multivariadas de análise de dados: a) independência das observações, b) amostras aleatórias de respondentes e c) linearidade de todos os relacionamentos. Além destas, a Modelagem de Equações Estruturais é mais sensível para com as características distribucionais dos dados, particularmente em relação à normalidade multivariada ocasionando assim a necessidade de amostras de tamanho maior para a análise.

A Modelagem de Equações Estruturais engloba uma família de modelos e é conhecida por muitos nomes, entre eles análise de estrutura de covariância, análise de variáveis latentes, análise fatorial confirmatória, modelagem de caminhos (*path modeling*), análise de caminhos (*path analysis*) ou simplesmente análise LISREL (nome do primeiro pacote computacional para esse fim).

O uso de Modelagem de Equações Estruturais não se limita à análise de dependência simultânea dos dados; a técnica proporciona uma transição da análise exploratória para uma perspectiva confirmatória. A Modelagem de Equações Estruturais testa empiricamente um conjunto de relacionamentos de dependência através de um modelo que operacionaliza a teoria. O propósito do modelo é proporcionar uma representação dos relacionamentos a serem examinados, sendo formalizado através de um diagrama de caminhos ou de um conjunto de equações estruturais (MEDEIROS, 2003).

Os modelos de equações estruturais podem ser também representados por equações de regressão. Isto porque as equações de regressão representam a influência de uma ou mais variáveis em outra e, convenientemente em SEM, essa influência é simbolizada por uma seta apontando da variável de influência para a variável de interesse. Pode-se assim pensar que cada equação é um sumário do impacto de todas as variáveis relevantes no modelo em uma variável específica. Uma abordagem relativamente simples para formular estas equações é notar que cada variável que possui pelo menos uma seta apontando em sua direção registra a soma de todas as influências de cada uma dessas variáveis dependentes (LEMKE, 2005).

Duas características distinguem a SEM das demais técnicas de modelagem: a) estimação de relações de independência múltiplas e inter-relacionadas, e b) habilidade para representar construtos latentes (construtos compostos com algumas variáveis mensuráveis que explicam conceitos que não podem ser medidos diretamente) nestas relações de dependência e explicar o erro de mensuração no processo de estimação. A SEM permite expressar relações entre variáveis independentes e dependentes, inclusive quando uma variável dependente se torna independente em relações subsequentes. As relações propostas são traduzidas em uma série de equações estruturais (semelhantes às equações de regressão) para cada variável dependente (HAIR *et al.*, 1998). SEM pode ser vista como extensão da regressão múltipla, se for considerado que na aplicação da regressão o pesquisador está interessado em prever uma única variável dependente, enquanto na SEM há mais de uma variável dependente a ser prevista. A preocupação nesta técnica é com a ordem das variáveis. Na regressão, X influencia Y; na SEM, X influencia Y e Y influencia Z. Uma das características básicas de SEM é que se pode testar uma teoria de ordem causal entre um conjunto de variáveis (KLEM<sup>2</sup> (1995) *apud* FARIAS; SANTOS, 2000). Utiliza-se SEM para procedimentos multivariados não

---

<sup>2</sup> KLEM, L.; Path analysis. In: GRIMM, L. G.; YARNOLD, P. R. **Reading and Understanding Multivariate Statistics**. Washington, DC : American Psychological Association, 1995.

encontrados em outras técnicas estatísticas 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. 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 é essencialmente descritiva por natureza (como a análise fatorial exploratória), onde testes de hipóteses sobre o modelo - o modelo global e não os parâmetros do modelo - são difíceis, se não impossíveis, de serem realizados. Outra vantagem de SEM é que ela possibilita uma estimativa dos erros dos parâmetros, enquanto algumas técnicas alternativas (como modelos lineares generalizados) não fornecem os erros das variáveis exploratórias (LEMKE, 2005).

A SEM oferece ao pesquisador a possibilidade de investigar quão bem as variáveis preditoras (variáveis independentes) explicam a variável dependente e também, qual das variáveis preditoras é mais importante. Isto também é possível com o uso da regressão, porém na SEM pode-se ter mais de uma variável dependente em um único modelo (MARUYAMA<sup>3</sup> (1998) *apud* FARIAS; SANTOS, 2000).

A SEM também pode incorporar construtos ou variáveis latentes na análise. Um construto ou variável latente é um conceito teorizado e não observado que não pode ser medido diretamente, mas pode ser representado ou medido por duas ou mais variáveis observáveis ou mensuráveis. Em SEM, as variáveis observadas que compõe os construtos latentes são amostradas por diversos métodos de coleta de dados (por exemplo, pesquisas, observações ou testes) e são conhecidas como variáveis observadas ou manifestas. A utilização de construtos ou variáveis latentes na modelagem tem justificativa prática e teórica na melhoria da estimação estatística, melhor representando os conceitos teóricos e melhor explicando os conceitos que estão sendo testados (HAIR *et al.*, 1998).

Existem três situações, segundo Goldeberger e Duncan (1973), onde os parâmetros da regressão falham no provimento de informações e torna-se necessário o uso de SEM: a) quando existem construtos latentes; b) quando as variáveis observadas contêm erros de mensuração e a relação desejada é entre as variáveis observáveis; e c) quando existe interdependência entre as variáveis observadas.

---


<sup>3</sup> MARUYAMA, G. M. PARASURAMAN, A.; ZEITHAML, V. A.; BERRY, L. L.; **Basics of Structural Equation Modeling**. London : Sage Publications, 1998.

Segundo Klem (1995) e Maruyama (1998) *apud* Farias e Santos (2000), dois resultados principais podem ser esperados de uma análise com a aplicação da SEM. Primeiro, uma estimativa da magnitude dos efeitos entre variáveis é fornecida. Estas estimativas estão condicionadas ao fato de o modelo especificado (diagrama de caminhos) estar correto. O segundo resultado é a possibilidade de testar se o modelo é consistente com os dados observados. Se o modelo e os dados são consistentes, pode-se dizer que este modelo é plausível, embora não se possa afirmar que este seja o correto.

A razão pela qual SEM tem sido aplicada em muitas áreas é sua habilidade de resolver problemas de pesquisa relacionados às relações causais entre construtos latentes que são medidos pelas variáveis observadas. Muitos conceitos culturais, psicológicos e de mercado são construtos latentes de confiança, medidos por múltiplas variáveis observadas. Quanto menor a confiança nas medidas, maior a dificuldade em observar relações entre os construtos latentes e as demais variáveis. Com o uso da SEM pode-se modelar importantes construtos latentes levando-se em conta a não confiabilidade dos indicadores, como no caso de construtos latentes de percepção, avaliação, satisfação ou medidas de comportamento, que têm baixa confiabilidade (REISINGER; TURNER, 1999).

Existem quatro tipos distintos de relações causais (entre as variáveis) de interesse na SEM, são eles:

- a) relações causais diretas, onde uma variável causa efeito em outra diretamente, como pode ser observado na Figura 1a. Relações diretas também podem ser recíprocas como mostrado na Figura 1b (as setas indicam o caminho ou a relação de causa entre duas variáveis e um efeito direto entre elas);
- b) relações causais indiretas, onde uma variável causa um efeito em outra através de uma terceira variável, como pode ser observado na Figura 1c;
- c) relações espúrias, onde duas variáveis tem uma variável comum que exerce efeito em ambas, como mostra a Figura 1d;
- d) associação sem correlação, onde duas variáveis têm uma variável comum, mas não é possível determinar se a variável comum contribui para a covariação entre as duas variáveis anteriores através de relações espúrias ou indiretas, conforme a Figura 1e (IRIONDO *et al.*, 2003).



**Figura 1 – Diferentes tipos de relações causais entre variáveis**  
(Fonte: IRIONDO *et al.*, 2003)

Na forma primária de análise a SEM é similar a combinar regressão múltipla com análise fatorial, ou seja, a SEM permite expressar a relação linear causal entre dois conjuntos diferentes de construtos latentes. Na SEM, esses construtos latentes são chamados de exógenos (independentes) e/ou endógenos (dependentes) (REISINGER; TURNER, 1999). A SEM informa uma ou mais equações lineares de regressão que descrevem como os construtos endógenos dependem dos exógenos e seus coeficientes são chamados de coeficientes de caminho ou algumas vezes, de peso de regressão (REISINGER; TURNER, 1999).

Outra vantagem na utilização da SEM é o fato de se admitir que o erro de mensuração existe. Em outras técnicas multivariadas se assume que não existe nenhum erro de mensuração nas variáveis, mas se sabe, na prática e na teoria, que não se pode medir um conceito perfeitamente e que sempre existe algum grau de erro (HAIR *et al.*, 1998).

O impacto do erro de mensuração pode ser expresso em função do coeficiente de regressão conforme a equação (1) (HAIR *et al.*, 1998):

$$\beta_{yx} = \beta_s \times \rho_x \quad (1)$$

onde  $\beta_{yx}$  é o coeficiente de regressão observado,  $\beta_s$  é o verdadeiro coeficiente de regressão e  $\rho_x$  é a confiabilidade da variável independente (preditora).

A menos que a confiabilidade ( $\rho_x$ ) seja 100%, a correlação observada sempre subestimar a verdadeira relação. Como todas as relações de dependência estão baseadas na correlação observada (e no coeficiente de regressão resultante) entre

variáveis, espera-se fortalecer as correlações usadas nos modelos de dependência e obter estimativas mais precisas dos coeficientes estruturais, primeiramente pela explicação da correlação atribuível a quaisquer problemas de mensuração. Mesmo presentes em observações de variáveis observáveis e latentes, erros de mensuração são mais comuns nas observações de construtos ou variáveis latentes. O erro de mensuração não é causado apenas por respostas inexatas, mas acontece também quando se usam conceitos abstratos ou teóricos, como aceitação de um produto ou motivações para comportamento. Com esses conceitos, o pesquisador tenta elaborar as melhores perguntas para medir o comportamento do respondente, porém este pode ficar inseguro sobre como responder às questões e isso pode dar origem ao erro de medida. Conhecendo a magnitude desse problema, pode-se incorporar a confiabilidade estatística e melhorar o modelo de dependência entre as variáveis (HAIR *et al.*, 1998).

Na utilização da SEM, existe a necessidade de justificativa teórica para a especificação das relações de dependência, modificações das relações propostas e outros aspectos da estimação de um modelo. A teoria, que pode ser definida como um conjunto sistemático de relações fornecendo uma explicação consistente e abrangente de um fenômeno, fornece o fundamento para quase todos os aspectos de SEM (HAIR *et al.*, 1998).

Segundo Maruyama (1998) *apud* Farias e Santos (2000), os métodos da SEM devem ter início em um modelo conceitual que especifique as relações entre um conjunto de variáveis. A SEM fornece estimativas da força de todas as relações hipotéticas de um esquema teórico, ou seja, tanto do impacto de uma variável sobre outra como da influência indireta de uma variável posicionada entre duas outras. A necessidade de um modelo teórico para orientar o processo de estimação se torna especialmente crítica quando se faz uma modificação no modelo. Por conta da flexibilidade de SEM, em um modelo, quando o número de parâmetros a serem estimados é menor que o número de variâncias e covariâncias das variáveis observadas, as chances de superajustar ou desenvolver um modelo com pouca generalização são altas (HAIR *et al.*, 1998).

A SEM é vista mais como um procedimento confirmatório do que exploratório. Nesse sentido, três enfoques são possíveis: a) enfoque estritamente confirmatório: um modelo é testado quanto à sua aderência (*goodness of fit*) para determinar se os padrões de variação e covariação nos dados são consistentes com um modelo estrutural especificado pelo pesquisador. Porém como outros modelos não examinados podem se adequar tão bem, ou melhor aos dados, um modelo aceito é apenas um modelo não

confirmado; b) enfoque de modelos alternativo: pode se testar dois ou mais modelos causais para determinar qual se ajusta melhor. Há muitas medidas de aderência refletindo diferentes considerações. Na prática os pesquisadores informam três ou quatro, e c) enfoque no desenvolvimento do modelo: muitas pesquisas em SEM combinam propósitos exploratórios e confirmatórios. Um modelo é testado usando procedimentos de SEM, e se for considerado deficiente, um modelo alternativo é então testado baseado em mudanças sugeridas pelos índices de modificação de SEM. O problema com o enfoque de desenvolvimento do modelo é que os modelos confirmados desta maneira são *post-hoc* e podem não ser estáveis (pode não ajustar dados novos, tendo sido criado baseado na singularidade de um conjunto de dados inicial). Os analistas podem tentar superar este problema usando uma estratégia de *cross-validation*, usando uma amostra de validação independente (GARSON, 1998).

Um dos conceitos mais importantes que deve estar presente no tocante a técnicas multivariadas é que não existe um só caminho correto para aplicá-las. A aplicação de SEM segue esse mesmo conceito; sua flexibilidade fornece ao pesquisador uma poderosa técnica analítica adequada para muitos objetivos de pesquisa (HAIR *et al.*, 1998).

O modelo completo de SEM pode ser decomposto em dois sub-modelos: um modelo de medida e um modelo estrutural. No modelo de medida estão definidas as relações entre as variáveis observadas e as variáveis não observadas. Ou seja, trata-se da ligação entre os escores de um instrumento de medida (as variáveis indicadoras observadas) e o construto teórico em estudo que foram designadas para medir (variáveis não observadas). O modelo estrutural define as relações entre as variáveis não observadas. Ele especifica como uma variável latente em particular causa (direta ou indiretamente) mudanças em outras variáveis latentes no modelo (LEMKE, 2005).

O processo de Modelagem de Equações Estruturais está centrado em dois passos: validação do modelo de medida e ajuste do modelo estrutural. A validação do modelo de medida é realizada principalmente através de análise fatorial confirmatória. O ajuste do modelo estrutural é realizado principalmente por análise de caminhos com variáveis latentes. Inicia-se especificando um modelo com base na teoria. Cada variável no modelo é conceitualizada como latente, medida por indicadores múltiplos (indicadores são variáveis observadas, algumas vezes chamadas de variáveis de manifesto ou variáveis de referência). São desenvolvidos vários indicadores para cada modelo; tem-se pelo menos três indicadores por variável latente depois da análise fatorial confirmatória. Baseado numa amostra representativa ( $n > 100$ ), a análise fatorial

é usada para estabelecer quais indicadores parecem medir as variáveis latentes correspondentes, representados pelos fatores. O pesquisador só prossegue quando o modelo de medida for validado. Dois ou mais modelos alternativos, um dos quais pode ser o modelo nulo – no modelo nulo, as covariâncias da matriz de covariância para as variáveis latentes são todas consideradas zero - são comparados, então, em termos de ajuste do modelo que mede até que ponto as covariâncias previstas pelo modelo correspondem às covariâncias observadas nos dados, para se chegar a um melhor modelo. Índices de modificação e outros coeficientes podem ser usados pelo pesquisador para alterar um ou mais modelos para melhorar o ajuste (GARSON, 1998).

O modelo completo de SEM 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 (podendo ser comparados as variáveis independentes), uma para as correlações dos construtos endógenos (podendo ser comparados as variáveis dependentes), e duas dos erros de medida das variáveis endógenas e exógenas (LEMKE, 2005).

## **2.2 Distinção entre variáveis (ou construtos) latentes e variáveis observadas**

Variáveis latentes representam conceitos unidimensionais em sua forma mais pura. Outros termos para representá-los são, variáveis não observadas ou não mensuráveis e fatores. As variáveis ou indicadores observáveis de uma variável contém erros sistemáticos ou aleatórios mensuráveis, mas os construtos latentes são livres de tais erros (SANTOS, 2002).

Uma variável latente não pode ser medida diretamente, mas pode ser representada ou medida por uma ou mais variáveis observáveis (ou manifestas). Por exemplo, a atitude de uma pessoa em relação a um produto jamais pode ser medida precisamente a ponto de não haver incerteza, mas em se fazendo várias perguntas pode-se avaliar muitos aspectos da atitude dessa pessoa. O conjunto de respostas a tais questões fornece uma medida mais precisa do construto latente para um indivíduo (HAIR *et al.*, 1998).

Assim como as variáveis latentes, as variáveis observadas possuem uma variedade de nomes, incluindo variáveis manifestas, indicadoras e medidas (SANTOS, 2002). Uma variável observada é o valor observado de um item ou questão específica, obtida de respondentes em questões (como em um questionário), ou a partir de



observações feitas pelo pesquisador; são usadas como indicadores de construtos ou variáveis latentes (HAIR *et al.*, 1998). A percepção de valor ou de qualidade, por exemplo, são teoricamente construtos que apenas podem existir com a combinação de outras variáveis observadas. As variáveis observadas em SEM tem um número finito de valores, exemplos de variáveis medidas são: distância, peso, altura (REISINGER; TURNER, 1999).

Um modelo de variáveis latentes 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 suas medidas observadas, como por exemplo, o modelo de análise fatorial confirmatória (que será apresentado posteriormente). O modelo estrutural descreve as ligações entre variáveis latentes (LEMKE, 2005).

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 ocorre através do conhecimento teórico do pesquisador sobre o assunto, pesquisa empírica, ou pela junção das duas. Depois que o modelo é especificado, o pesquisador testa suas adequações, 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 o modelo é, utilizando o teste de aderência do modelo (*goodness of fit*) aos dados amostrais. Como não há ajuste perfeito, existe uma diferença entre o modelo especificado hipoteticamente e os dados amostrais, chamada resíduo (LEMKE, 2005).

Para medir as variáveis latentes usam-se escalas de multi-itens onde são apresentados aos respondentes mais de dois itens destinados a serem indicadores alternativos do mesmo construto. Os escores dos itens destinados a formar um construto particular são freqüentemente somados para formar um escore composto do construto, que é usado como uma estimativa de um construto no teste de hipóteses (KOUFTEROS, 1999). Logo, os construtos latentes correspondem a junção de uma ou mais variáveis observáveis. Qualquer teste de uma teoria descrita através de um modelos de variáveis latentes só é realizável se for possível coletar medidas observáveis dessas variáveis latentes (SANTOS, 2002).

### ***2.2.1 Análise de dados categóricos em SEM***

Muitas vezes em SEM o pesquisador se depara com dados categóricos para se compor os construtos. Existem três restrições nas metodologias de variáveis categóricas relevantes: a) necessidade de grandes amostras; b) número limitado de variáveis observadas (inferior a 25), e c) forte suposição de que para cada variável categórica observada exista uma variável latente subjacente não observada que seja de escala contínua e que estas variáveis latentes contínuas tenham distribuição normal multivariada (BENTLER; WU, 1995).

Devido ao fato da última suposição apresentada ser extremamente forte e, em certos casos não satisfeita, se discute o que é melhor fazer: tratar as variáveis categóricas como se fossem quantitativas e usar uma correção apropriada para os testes estatísticos utilizados, ou utilizar um outro método de estimação, que não exija esta suposição, mas que certamente apresentará outras suposições e/ou limitações. A escala estatística criada por Satorra e Bentler no ano de 1998, chamada de 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 análise de dados reais (LEMKE, 2005).

### ***2.2.2 Variáveis latentes exógenas e variáveis latentes 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 idade, sexo, classe social. Já o termo variável endógena é um sinônimo para variável dependente, por que 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 (LEMKE, 2005).

Variáveis exógenas em um modelo de caminho não têm causas explícitas (nenhuma seta está apontando para elas, diferente do termo de erro de medida). Se forem correlacionadas, isto será indicado por uma seta que tem duas pontas que as conecta. Variáveis endógenas, então, são as que têm setas entrantes. Variáveis endógenas incluem variáveis causais e dependentes, têm setas causais que entram e

saem no diagrama de caminho. As variáveis dependentes têm apenas setas entrantes em um diagrama de caminhos (GARSON, 1998).

Os valores das variáveis endógenas são explicados por uma ou mais variáveis exógenas do modelo. Os valores das variáveis exógenas são assumidos como resultados, isto é, o modelo não tenta explicá-los. Distinção similar à análise de regressão onde variáveis dependentes são as endógenas e as independentes exógenas. Entretanto, em SEM, uma variável pode ser tanto dependente quanto independente; a regra é essa: se uma variável é dependente em alguma parte do modelo, então ela é endógena. Cada construto endógeno constitui uma variável dependente em equações estruturais (FARIAS; SANTOS, 2000).

A identificação das variáveis é um passo importante para que o pesquisador possa identificar e estruturar o modelo em estudo, podendo assim realizar a análise de caminhos.

As variáveis latentes em modelos de equação estrutural correspondem a um tipo de construto hipotético (latente), apesar de um construto hipotético poder representar praticamente todo tipo de expressão que não é diretamente observável. Segundo Nunnally e Berstein (1994) um construto latente reflete a hipótese de que uma variedade de comportamentos irá se correlacionar com outro em estudos de diferenças individuais e/ou será similarmente afetada por manipulações experimentais.

Essa definição destaca quatro responsabilidades do pesquisador que deseja representar um construto latente num modelo estatístico: a) o construto requer uma definição suficientemente específica; b) onde seus indicadores possam ser selecionados. Porque um construto é tipicamente não considerado igual a qualquer outro indicador, é necessário se ter múltiplos indicadores; c) para afirmar que um conjunto de indicadores avalia algum construto, em comum os dados dos indicadores devem ser consistentes com algumas previsões, por exemplo, indicadores que supostamente medem o mesmo construto têm que ser ao menos moderadamente correlacionados, isto é, eles devem exibir validade convergente; e d) se os dados não são consistentes com essas previsões, então a teoria original do pesquisador – a definição operacional do construto – é chamada à questão.

Quando a definição inicial do construto é por tentativa, então algumas diferenças entre teoria e os dados são esperadas. Qualquer evento que o pesquisador presume sobre o construto e sua medida, pode precisar de revisão (KLINE, 1998). Esse processo é o de validação de construto originalmente descrito na literatura na área da psicologia por

Cronbach & Meeal<sup>4</sup> (1995) *apud* Kline (1998). A lógica geral da validação de construto é basicamente a mesma do que aquela que fundamenta a representação de variáveis latentes em SEM: a teoria prepara o cenário para fazer previsões sobre as relações de indicadores para cada um, baseado no construto latente que se presumiu medir. Essas previsões são representadas na forma de um modelo de medida analisado com as covariâncias observadas entre os indicadores. Se as covariâncias subentendidas no modelo correspondem às observadas, então a teoria é válida; senão, deve-se testar um novo modelo baseado numa teoria revisada (KLINE, 1998).

A má definição das variáveis nos construtos latentes pode gerar erros lógicos potenciais como a rotulação enganosa (apenas por que uma variável latente num modelo de medida está designado com um rótulo particular não significa que o construto latente esteja compreendido, ou mesmo corretamente nomeado) ou a reificação (a crença que um construto hipotético deva necessariamente corresponder a coisa real) a representação de variáveis latentes em SEM não deve ser tomada usualmente. Alguns dizem que as variáveis latentes são mais problemas do que soluções (KLINE, 1998).

### 2.3 Análise de Caminhos (*Path Analysis*)

Análise de caminhos é uma técnica estatística usada para examinar relações causais entre duas ou mais variáveis. É baseada em um sistema de equações lineares e foi desenvolvida inicialmente por Sewall Wright nos anos trinta para uso em estudos filogenéticos. A análise de caminho foi adotada pelas ciências sociais nos anos sessenta e foi usada com frequência na literatura ecológica desde os anos setenta, sendo usada principalmente na tentativa de entender as relações diretas e indiretas entre um conjunto de variáveis. (STOELTING, 2004).

Esta análise está relacionada a modelos com fluxo causal direcional único, em que as medidas de cada variável conceitual são perfeitamente confiáveis. Partindo desta premissa, acredita-se que não existe erro de mensuração ou de especificação das variáveis. Isto é, cada medida é vista como exata manifestação da variável teórica. Certamente, nas ciências sociais (assim como em outras ciências), assumir que existe perfeita confiabilidade é irreal. Este fato restringiu, por muito tempo, a aplicação desta técnica de análise de dados neste campo da ciência. Uma das soluções parciais

---

<sup>4</sup> CRONBACH, L. J., MEEL, P. E.; **Construct Validity in the Psychological Literature**, Psychological Bulletin, v. 52, p. 281-302, 1955.

encontradas para este problema foi a inclusão de variáveis latentes. Estes indicadores revelam a quantidade de variância não explicada pelas variáveis exógenas (independentes) especificadas (FARIAS; SANTOS, 2000).

A análise de caminhos é uma extensão da regressão múltipla indo além no sentido que permite a análise de modelos mais complicados, pode examinar situações em que há muitas variáveis dependentes finais e aquelas em que há correntes de influência na qual a variável *a* influencia a variável *b* que por sua vez afeta a variável *c*. Apesar de seu nome ser modelagem causal, a análise de caminhos não pode ser usada para estabelecer causalidade ou mesmo para determinar quando um modelo específico é correto, pode apenas determinar quando os dados são consistentes com o modelo. Contudo, é extremamente poderosa para examinar modelos complexos e comparar diferentes modelos para determinar qual deles melhor se ajusta aos dados (STREINER, 2005). A análise de caminhos é utilizada quando existe apenas uma medida observada de cada variável teórica e o pesquisador tem hipóteses *a priori* sobre relações causais entre essas variáveis. O ponto de partida para análise de caminho é especificação de um modelo estrutural que represente as hipóteses causais (KLINE, 1998).

A análise de caminhos enfatiza três componentes: a) o diagrama de caminhos; b) a decomposição das covariâncias e correlações em termos dos parâmetros do modelo; e c) a distinção entre os efeitos: direto, indireto e total de uma variável em outra (SANTOS, 2002).

O Efeito direto é a influência de uma variável em outra que não é medida por qualquer outra variável no modelo, os efeitos indiretos de uma variável são medidos por, no mínimo, uma variável observável e finalmente, a soma dos efeitos diretos e indiretos é igual aos efeitos totais. A decomposição dos efeitos é feita com respeito a um modelo específico. Se o sistema de equações é alterado pela inclusão ou exclusão de variáveis, então as estimativas dos efeitos diretos, indiretos e totais pode mudar (SANTOS, 2002).

A análise de caminhos em sua representação gráfica possui alguns símbolos pré-definidos, os símbolos padrão que dizem respeito às variáveis e as relações entre elas e os símbolos não-padrão que dizem respeito às variâncias residuais. Os diagramas devem ser desenhados de modo que o fluxo causal seja da esquerda para a direita. Os símbolos e as suas representações gráficas passam a ser descritos nas tabelas 1 e 2.

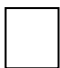


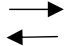

Símbolo	Descrição
 Quadrados ou retângulos	representam as variáveis observadas, variáveis medidas pelo pesquisador. Outros termos: variável manifesta ou indicador quando representada como medida de uma variável latente.
 Elipses ou círculos	representam os construtos latentes (um construto hipotético não observado). Fator é outro termo utilizado para representar variáveis latentes.
 Seta com uma ponta	Seta com uma ponta – indica o caminho ou a relação de causa entre duas variáveis e um efeito direto entre elas. Por exemplo, $X \rightarrow Y$ , X afeta Y de um modo unidirecional.
 Duas setas	representam a relação bidirecional entre duas variáveis. Por exemplo, $Y_1 \rightleftarrows Y_2$ , a influência entre $Y_1$ e $Y_2$ é bidirecional, outro termo utilizado <i>feedback loop</i> .
 Seta com duas pontas	Seta com duas pontas – representa correlação ou covariância, $X_1 \leftrightarrow X_2$ duas variáveis são assumidamente covariantes, mas não há mais uma hipótese específica de como essa correlação aparece. Outro termo: associação não analisada.

Tabela 1: Símbolos Padrão.

Símbolo	Descrição
D	representa a perturbância, por exemplo: $X \rightarrow Y \leftarrow D$ ; variância em Y não é explicada pela variável X que se presume afetá-la.
E	representa o erro de medida, por exemplo: $A \rightarrow X \leftarrow E$ , onde X é uma variável observada que presumivelmente mede A, uma variável latente; E é a variância em X não explicada por A.

Tabela 2: Símbolos não Padrão

Segundo Hair *et al.* (1998), a análise de caminhos permite calcular a intensidade das relações entre as variáveis, usando apenas uma matriz de correlação ou covariância como entrada. A correlação simples entre duas variáveis quaisquer pode ser representada como a soma dos caminhos compostos conectando esses pontos. Um caminho composto é um caminho ao longo das setas que segue três regras: a) Depois de ir adiante numa seta o caminho não pode retroceder novamente, mas pode ser revisada antes de ir adiante; b) o caminho não pode passar pela mesma variável mais de uma vez; e c) o caminho pode incluir apenas uma seta curvada (par de variáveis correlacionadas).

Quando o modelo de caminho é alterado de algum modo, as relações causais mudarão também. Tal mudança provê a base para modificar o modelo a fim de alcançar um melhor ajuste, se isso for teoricamente justificado (HAIR *et al.* 1998).

A análise de caminho pode ser estendida para qualquer sistema de relações. Com procedimentos definidos, todas as relações em qualquer diagrama de caminhos (é uma representação gráfica de um sistema de equações simultâneas) podem ser estimadas para quantificar os efeitos entre as variáveis dependentes e independentes, mesmo que as variáveis sejam inter-relacionadas. Assim, a análise de caminhos é capaz de analisar um conjunto de relações de maneira simultânea (HAIR *et al.*, 1998).

A análise de caminhos pode ser utilizada com relações recíprocas ou relações com laços de realimentação (*feedback loops* – fluxo causal em mais de uma direção) da mesma forma que é usada com modelos que não possuem essas características. A decomposição das variâncias, ou a determinação dos efeitos pode também ser feita por esses modelos, além disso, a análise de caminhos pode lidar tanto com coeficientes padronizados quanto com não padronizados. A análise de caminhos admite relações não lineares, assim como em análise de regressão, onde são feitas transformações nas variáveis para que seja possível capturar essas relações não lineares (SANTOS, 2002).

Conforme visto a análise de caminhos é uma técnica estatística para examinar relações causais entre duas ou mais variáveis em um sistema de equações lineares e o modelo de caminhos é o diagrama que relaciona essas variáveis.

### **2.3.1 Modelo de Caminho (*path models*)**

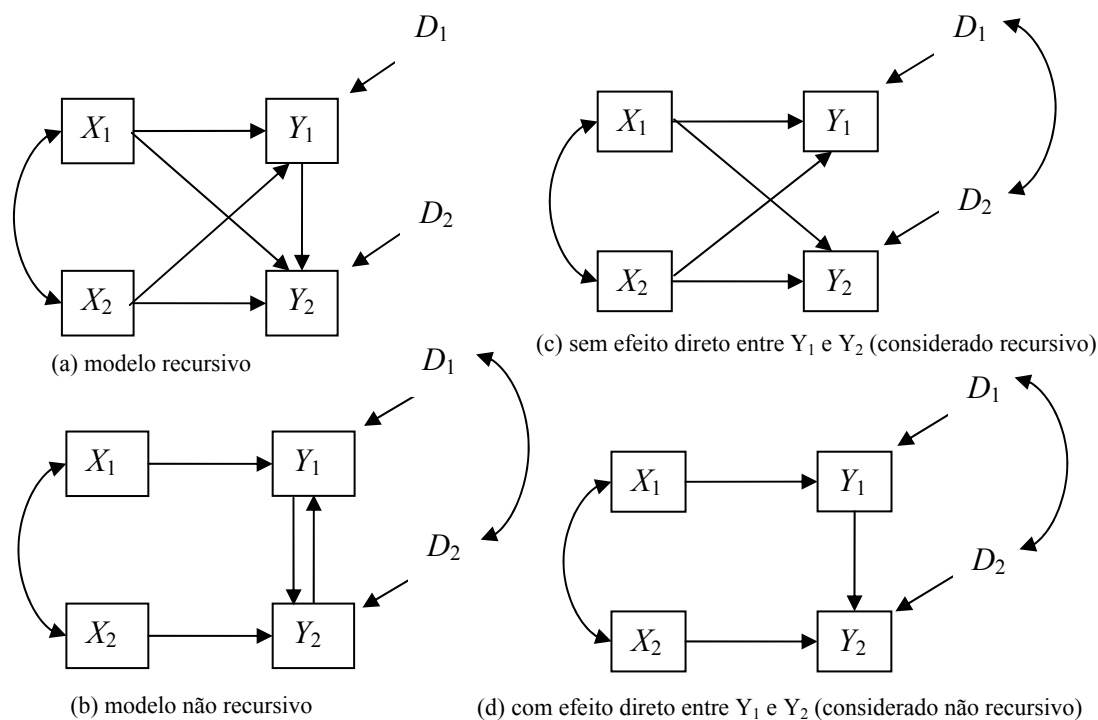
Modelo de caminho é um diagrama relacionando variáveis independentes, intermediárias e dependentes (GARSON, 1998). Há dois tipos básicos de modelos de caminhos, o recursivo e o não recursivo. Os modelos recursivos são os mais diretos e têm duas características básicas: seus erros residuais (refletem variância não explicada, isto é, o efeito de variáveis não medidas, além do erro de medida) são não correlacionados (independentes) e todos os efeitos causais são unidirecionais (KLINE, 1998). Modelos recursivos nunca são subidentificados (são modelos que são sempre solucionáveis porque têm mais parâmetros que observações) (GARSON, 1998). O modelo não recursivo tem laços de realimentação (*feedback loops*) ou podem ter erros residuais correlacionados (KLINE, 1998).

Considerando o modelo *a* e *b* da Figura 2, o modelo *a* é recursivo por que seus erros residuais são independentes e nenhuma variável é uma causa e efeito de outra variável. Por exemplo,  $Y_1$  e  $X_2$  são especificadas como causas diretas de  $Y_2$ .  $X_1$  é uma causa indireta de  $Y_2$  através de  $Y_1$ , mas  $Y_2$  não tem efeito direto sobre suas causas presumidas, em contraste o modelo *b* é não recursivo, por que ele tem um laço de realimentação direto no qual  $Y_1$  e  $Y_2$  são especificados como causas e efeitos um do outro ( $Y_1 \overset{\leftarrow}{\rightarrow} Y_2$ ). O modelo *b* também tem uma correlação de erro residual (KLINE, 1998).

Também há um outro tipo de modelo de caminho, que tem efeitos unidirecionais e erros residuais correlacionados. Alguns autores chamam esse modelo de não recursivo, mas outros o chamam de parcialmente recursivo; mais importante que o rótulo para esses modelos é a distinção feita na Figura 2, dois exemplos são mostrados nos modelos *c* e *d*. No modelo *c* tem-se um modelo parcialmente recursivo nos qual os erros residuais aparecem sem efeitos diretos entre as variáveis endógenas, pode ser tratado na sua análise como modelo recursivo; O modelo *d* é um modelo parcialmente recursivo onde os erros residuais ocorrem com efeitos diretos entre as variáveis endógenas e requerem procedimentos de estimativas mais especializados que não serão tratados aqui. Conseqüentemente todas as referências subseqüentes para modelos recursivos e não recursivos, incluem, respectivamente, modelos parcialmente recursivos com e sem efeitos diretos entre as variáveis endógenas (KLINE, 1998).

A distinção entre modelos recursivos e não recursivos tem muitas implicações, algumas conceituais e outras práticas. Os pressupostos do modelo recursivo de que todos os efeitos causais são unidirecionais e que os erros residuais são independentes quando há efeitos diretos entre as variáveis endógenas. Tal fato, em muito simplifica as demandas estatísticas para a sua análise. Especificamente a regressão múltipla pode ser usada para estimar modelos recursivos. Os modelos não recursivos não podem ser analisados com regressão múltipla, pois requerem métodos estatísticos mais especializados e também podem requerer pressupostos adicionais. A probabilidade de ocorrência de problemas na análise de um modelo não recursivo é muito maior que num modelo recursivo (KLINE, 1998).





**Figura 2: Exemplo de modelos de caminhos, recursivo, não recursivo e parcialmente recursivo. (Fonte:KLINE, 1998)**

## 2.4 Análise fatorial confirmatória

O principal objetivo em análise fatorial é explicar a covariância ou correlação entre muitas variáveis observadas por meio do relacionamento de poucas variáveis latentes subjacentes. Vista dessa forma, ela pode ser considerada uma técnica de redução (SANTOS, 2002). Há uma importante diferença entre a modelagem por análise fatorial e a modelagem SEM. Em análise fatorial as variáveis observadas podem ser armazenadas (*can load*) em um ou em todos os construtos (fatores), e o número de construtos é limitado. Por outro lado SEM usa a análise fatorial confirmatória onde as variáveis observadas são armazenadas em construtos particulares (REISINGER; TURNER, 1999).

Existem dois tipos básicos de análise fatorial: a análise fatorial exploratória (EFA – do inglês, *Exploratory Factor Analysis*) e a análise fatorial confirmatória (CFA – do inglês, *Confirmatory Factor Analysis*).

Análises Fatoriais Exploratórias (AFE) são as mais comuns. Apesar de existirem muitas variedades de AF, talvez a característica que mais a distinga seja a não exigência da especificação adiantada de um modelo que relacione variáveis latentes às variáveis observadas. Em AFE o número de variáveis latentes não é determinado antes da análise;

tipicamente todas as variáveis latentes influenciam todas as variáveis observadas, não é permitido que os erros sejam correlacionados e a subidentificação dos parâmetros é comum (SANTOS, 2002). A análise fatorial exploratória é usada quando não se tem uma conexão *a priori* entre as variáveis observadas e as variáveis latentes, por falta de conhecimento ou incerteza sobre o fator em estudo. Através da AFE, 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 de um número grande de variáveis (LEMKE, 2005).

Em contraste, em Análise Fatorial Confirmatória (AFC) o modelo é previamente construído, o número de variáveis latentes é fixado antes da análise, alguns efeitos diretos de variáveis latentes em variáveis observadas são fixados em zero ou em alguma constante, erros de medida podem ser correlacionados, a covariância das variáveis pode ser estimadas ou fixadas em qualquer valor, é necessária a identificação dos parâmetros; ou seja, análise fatorial confirmatória requer um modelo inicial detalhado e identificado (SANTOS, 2002). A AFC é apropriada quando o pesquisador já possui alguma idéia sobre as variáveis latentes em estudo. Baseado no conhecimento teórico, resultados de pesquisas, ou até mesmo de ambos, ela postula as relações entre as variáveis medidas e os fatores definidos *a priori*, e então testa estatisticamente essa estrutura hipotética. Devido ao fato da análise fatorial confirmatória focar somente a ligação entre os fatores e as variáveis observadas, ela é mais utilizada em SEM (LEMKE, 2005).


A análise fatorial confirmatória envolve a especificação e estimação de um ou mais modelos hipotéticos de estrutura fatorial, cada um dos quais propõe um conjunto de variáveis latentes (fatores) a considerar a fim de se obter covariâncias em um conjunto de variáveis observadas. A modelagem por equações estruturais linear pode ser usada para testar o ajuste de um modelo hipotético às amostras de dados (KOUFTEROS, 1999).

A análise fatorial confirmatória permite a operacionalização de um modelo de medida. Suas aplicações são particularmente apropriadas quando há um debate sobre a dimensionalidade ou estrutura fatorial de uma escala ou medida (KELLOWAY, 1998).

A análise de equações estruturais permite um teste estatístico de aderência (*goodness of fit*) para a solução fatorial confirmatória, o que não é possível com componentes principais ou análise fatorial. Análise fatorial confirmatória é particularmente útil na validação de escalas de mensuração de construtos específicos (HAIR *et al.*, 1998).

Os modelos de medida avaliados pela AFC tem uma característica particular: as variáveis latentes nos modelos AFC tem uma covariância mútua, isto é, todas as suas associações são especificadas como não analisadas. É possível testar mais hipóteses específicas sobre relações entre variáveis latentes pelas especificações de um modelo híbrido. Em modelos híbridos algumas associações não analisadas entre variáveis latentes são substituídas por efeitos causais diretos ou recíprocos. Desta maneira os modelos híbridos são como modelos de medida, mas com múltiplas medidas de cada variável teórica (KLINE, 1998).

A Figura 3 é um exemplo de um modelo padrão de medida de AFC: os indicadores são representados com X, as variáveis latentes com as letras A e B e os termos de erro de mensuração com Es. Este modelo representa a hipótese de que X<sub>1</sub> a X<sub>3</sub> avalia o construto A, X<sub>4</sub> até X<sub>6</sub> mede o construto B e a covariância dos dois construtos.



**Figura 3: Modelo padrão de medida AFC.**  
(Fonte: KLINE, 1998)

#### ***2.4.1 Requisitos para identificação de modelo AFC***

Qualquer modelo de medida de AFC tem que preencher duas condições necessárias, mas suficientes para poder ser identificado: a) o número de parâmetros livres deve ser menor ou igual que o número de observações, e b) cada fator tem que ter uma escala. O número de observações é igual ao número de variâncias e covariâncias entre as variáveis observadas ( $v(v+1)/2$ ), onde  $v$  é o número de variáveis observadas (da mesma que nos modelos de caminho) (KLINE, 1998).

Parâmetros de modelos de medida de CFA são formados da seguinte maneira: o número total de variâncias e covariâncias dos fatores e dos erros de medida, mais efeitos diretos no indicador que é igual ao número de parâmetros. Como as variáveis latentes não são diretamente medidas, elas requerem uma escala de medida para que o computador seja capaz de calcular estimativas de efeito que as envolvem. Há duas maneiras de atribuir uma escala às variáveis latentes: a) fixar a variância de um fator igual a uma constante (usualmente 1,0), que padroniza a variável latente; b) fixar a alimentação de um indicador por fator em 1, o que dá à variável latente a mesma métrica do indicador (GARSON, 1998).

## **2.5 Estimação de coeficientes em SEM e verificação do modelo**

A avaliação de um modelo de equações estruturais consiste em duas áreas distintas: a) a adequação dos parâmetros estimados; e b) a adequação do modelo em termos gerais.

Para verificar a adequação dos parâmetros estimados é necessário observar alguns pontos indicativos: a) os parâmetros estimados devem apresentar sinal e tamanho corretos; b) as estimativas devem ter amplitude admissível; c) as correlações não podem ser maiores que 1, em módulo, isso indicaria problemas de estimação, de amostra; d) variâncias negativas, e matrizes de covariâncias e ou correlações que não são positivas definidas são indícios de que o modelo está errado, ou a matriz de dados de entrada não traz informação suficiente; e) outro cuidado importante é com relação a presença de erros padrões que são excessivamente grandes ou pequenos, isso é um indicador de ajuste pobre do modelo; e f) avalia-se a significância estatística das estimativas dos parâmetros.

É importante ressaltar que se um erro padrão for próximo de zero, a estatística de teste para este parâmetro não pode ser definida (BYRNE, 2001). Erros padrões muito grandes indicam parâmetros que não podem ser determinados. Como os erros padrão são influenciados pelas unidades de medida de uma variável observada ou medida, assim como a magnitude do parâmetro estimado, não se pode determinar nenhum critério definitivo de “pequeno” ou “grande”.

Já para avaliar a significância, o teste estatístico utilizado é o chamado razão crítica (CR – *Critical Ratio*), que é apresentado na saída de alguns softwares. A estatística é obtida pela estimativa do parâmetro dividida pelo seu erro padrão,

funcionando assim como a estatística  $z$  testando a hipótese de que a estimativa é estatisticamente diferente de zero. Baseado no nível de significância 0,05, o teste estatístico precisa ser, em módulo, maior que 1,96 para que essa hipótese possa ser rejeitada. Parâmetros que não forem significantes, com exceção das variâncias, podem ser considerados não importantes ao modelo. Parâmetros não significativos podem ser um indício de que o tamanho da amostra é muito pequeno (BYRNE, 2001).

O objetivo primário do pesquisador em Modelagem de Equações Estruturais é confirmar um bom ajuste entre o modelo criado e os dados amostrais, para tanto é necessário verificar a adequação geral do modelo. Ou seja, o pesquisador especifica um modelo e então usa os dados amostrais para testá-lo. Existem diversas maneiras de avaliar se esse objetivo foi contemplado, como a razão  $\chi^2/\text{gl}$ , resíduos, índices de modificação, índices de *godness of fit*. Não é uma seqüência de indicadores, pois não segue uma ordem. Na realidade, juntamente com a plausibilidade teórica, o conjunto desses indicadores avalia se o modelo está bem ajustado. O modelo pode contemplar individualmente certos fatores (como por exemplo, ele pode ser bom com relação aos resíduos) ou atender de um modo satisfatório a todos, o que dá maior sustentação.

Inicia-se analisando o valor geral da estatística  $\chi^2$ , juntamente com os graus de liberdade e um valor de probabilidade (valor de P). Mas essa informação tem apenas a intenção de fornecer uma idéia ampla sobre o ajuste do modelo com os dados amostrais, pois a sensibilidade do teste da razão de verossimilhança ao tamanho da amostra tem sua base na distribuição central  $\chi^2$ , a qual assume que o modelo se ajusta perfeitamente a população. Como a estatística  $\chi^2$  é igual a  $(N-1)F_{\min}$  ( $F_{\min}$  serve como uma medida da extensão de quanto a matriz de covariância amostral  $S$  difere da matriz de covariância  $\Sigma(\theta)$  do modelo<sup>5</sup>, este valor tende a ser alto quando o modelo não é sustentado (modelo não confirmado pelos dados amostrais) e a amostra é grande. Como a análise de estruturas de covariâncias é baseada em teorias com grandes amostras, as quais são críticas de se obter estimativas precisas dos parâmetros, conseguir modelos hipotéticos bem ajustados onde os valores do  $\chi^2$  são próximos aos graus de liberdade é difícil para grande maioria de modelagens práticas que utilizam SEM (BYRNE, 2001). É mais comum encontrar um valor de  $\chi^2$  grande relativo aos graus de liberdade, indicando a necessidade de uma modificação no modelo para se alcançar um melhor ajuste. Se recomenda que esta razão  $\chi^2 / \text{gl}$  não exceda 5 (BYRNE, 2001). Para se contornar as

---

<sup>5</sup> Todo o processo de estimação é feito através de matrizes de correlação/covariância, como várias técnicas multivariadas.  $S$  representa a matriz amostral de covariância (dos escores das variáveis observadas),  $\Sigma$  a matriz populacional de covariância e  $\theta$  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)

limitações do teste  $\chi^2$  os pesquisadores desenvolveram os índices de aderência (*goodness-of-fit*) para avaliar o modelo, alguns desses índices serão apresentados aqui, outros menos utilizados encontram-se no anexo A.

**CMIN:** é o valor mínimo de discrepância (é o valor do qui-quadrado) (LEMKE, 2005).

**CMIN/DF:** é a razão  $\chi^2$ /graus de liberdade, que deve ser  $\leq 5$  (LEMKE, 2005).

**RMR:** (*Root Mean Square Residual*); representa o valor residual médio derivado do ajuste da matriz de variância-covariância do modelo hipotético para matriz de variância-covariância dos dados amostrais. 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 ser considerado bem ajustado, o valor deve ser pequeno, 0,05 ou menos (LEMKE, 2005). Resíduos RMR são os coeficientes que resultam da raiz quadrada da média dos resíduos ao quadrado. Os resíduos são as quantias pelas quais as variâncias e covariâncias da amostra diferem das correspondentes variâncias e covariâncias estimadas supondo que seu modelo esteja correto. Resíduos ajustados resultam subtraindo a matriz de covariância amostrada da matriz de covariância estimada ou ajustada (GARSON, 1998).

**GFI:** (*Goodness-of-Fit Index*); é a medida da quantidade relativa de variância e covariância  $S$  que é conjuntamente explicada por  $\Sigma$ . O índice tem amplitude de zero a 1, sendo que valores perto de 1 são indicativos de bom ajuste (LEMKE, 2005). O GFI é obtido conforme a expressão da equação (2).

$$GFI = 1 - \frac{\hat{F}}{\hat{F}_b} \quad (2)$$

Onde:  $\hat{F}$  é o valor mínimo da função de discrepância e  $\hat{F}_b$  é obtida na avaliação de  $F$  com  $\Sigma^{(g)} = 0, g=1, 2, \dots, G$  (LEMKE, 2005)

**AGFI:** (*Adjusted Goodness-of-Fit Index*); 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 (LEMKE, 2005). AGFI tende a ser maior conforme o aumento de tamanho de amostra; correspondentemente, GFI pode subestimar o ajuste para tamanhos de amostra pequenos (GARSON, 1998). O AGFI é obtido conforme a expressão da equação (3).

$$AGFI = 1 - (1 - GFI) \frac{d_b}{d} \quad (3)$$

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

$p^{*(g)}$  = 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  $p^{*(g)} = p^{(g)}(p^{(g)} + 3)/2$ ,

e,  $d = p - q$ , número de graus de liberdade para testar o modelo.

**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 (LEMKE, 2005). É uma variante de GFI que penaliza GFI multiplicando ele pela relação formada pelos graus de liberdade em seu modelo e graus de liberdade no modelo de independência (GARSON, 1998). O PGFI é obtido conforme a expressão da equação (4).

$$PGFI = GFI \frac{d}{d_b} \quad (4)$$

Onde:  $d$  é os graus de liberdade do modelo que está sendo avaliado e  $d_b = \sum_{g=1}^G p^{*(g)}$  é os graus de liberdade do modelo referência.

**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. O NFI é obtido conforme a expressão da equação (5).

$$NFI = \Delta_1 = 1 - \frac{\hat{C}}{\hat{C}_b} = 1 - \frac{\hat{F}}{\hat{F}_b} \quad (5)$$

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.

**CFI:** (*Comparative Fit Index*); como NFI apresenta 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 (LEMKE, 2005). Valores de CFI perto de 1 indicam excelente ajuste ( $0 \leq CFI \leq 1$ ) e é obtido conforme a equação (6).

$$CFI = 1 - \frac{\max(\hat{C} - d, 0)}{\max(\hat{C}_b - d, 0)} = 1 - \frac{NCP}{NCP_b} \quad (6)$$

Além do ajuste pelo  $\chi^2$ (qui-quadrado) e seus índices de aderência, pode-se avaliar a adequação do modelo utilizando os índices de parcimônia (*parsimony*). Uma medida de ajuste de parcimônia pode ser entendida como uma medida geral de aderência (*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” (é a inclusão de coeficientes que trazem poucos ganhos no ajuste do modelo) com coeficientes adicionais que trazem poucos ganhos no ajuste do modelo (HAIR *et al.*, 1998). Dentre os índices de parcimônia tem-se:

**PRATIO:** (*Parsimony RATIO*); índice da razão de parcimônia inicial, é a relação de parcimônia que é a relação dos graus de liberdade do modelo com os graus de liberdade no seu modelo nulo de independência. PRATIO não é um teste de *goodness-of-fit*, mas é usado em medidas de *goodness-of-fit* como PNFI e PCFI que recompensam modelos parcimoniosos (modelos com relativamente poucos parâmetros para calcular em relação ao número de variáveis e relações no modelo). O PRATIO é obtido conforme a expressão da equação (7).

$$\text{PRATIO} = d/d_i \quad (7)$$

Onde:  $d_i$  = número de graus de liberdade do modelo de independência.

**PCFI:** (*Parsimony Comparative Fit Index*); índice computado de forma relativa ao índice CFI (LEMKE, 2005). É igual a PRATIO vezes CFI (GARSON, 1998). O PCFI é obtido conforme a expressão da equação (8).

$$\text{PCFI} = (\text{CFI})(\text{PRATIO}) = \text{CFI} \frac{d}{d_b} \quad (8)$$

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

Os índices descritos a seguir, fornecem uma estimação de parâmetro com não-centralidade (NCP- *noncentrality parameter*). Na discussão inicial sobre a estatística  $\chi^2$  o foco era a extensão com que o modelo era sustentável e não podia ser rejeitado. Quando o modelo hipotético está incorreto [i.e.  $\Sigma \neq \Sigma(\theta)$ ], o  $\chi^2$  tem uma distribuição não central, com um parâmetro de não centralidade  $\lambda$ , 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  $\Sigma$  e  $\Sigma(\theta)$  e pode ser considerado como o “*badness-of-fit*” da população. Assim, quanto mais alta a discrepância entre  $\Sigma$  e  $\Sigma(\theta)$  maior o valor de  $\lambda$ . Assim fica fácil de ver que a estatística central  $\chi^2$  é um caso especial da distribuição  $\chi^2$



não central, onde  $\lambda=0$ . Com o objetivo de estabelecer a precisão da estimativa do parâmetro de não centralidade, é utilizado intervalo de confiança (LEMKE, 2005).

**NCP:** valor do parâmetro de não centralidade que representa o  $\chi^2$  menos seus graus de liberdade. O intervalo de confiança indica que com certo grau (se mantém 90%, pois a saída do software AMOS informa esse grau de confiança para o NCP) de confiança o intervalo contém verdadeiro valor (populacional) do parâmetro de não centralidade ( $\lambda$ ) (BYRNE, 2001).

**FMIN:** Função de discrepância Mínima.  $F_{\min}$  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  $\Sigma(\theta)$ .

**RMSEA:** (*Root Mean Square Error of Approximation*); também é chamado RMS ou RMSE ou discrepância por grau de liberdade (GARSON, 1998), 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. 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 (estas classificações foram estabelecidas pela literatura do assunto e em manuais do *software* AMOS em geral já que o RMSEA e o TLI (*Tucker-Lewis Index*); também com valores entre zero e um, e valores próximos a 0,95 (para amostras grandes) indicando bom ajuste) 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 RMSEA é obtido conforme as expressões das equações (9) e (10).

$$RMSEA = \sqrt{\frac{F_0}{d}} \text{ da população} \quad (9)$$

$$RMSEA = \sqrt{\frac{\hat{F}_0}{d}} \text{ estimado} \quad (10)$$

Onde:  $F_0$  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.

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:** em adição ao I.C. de RMSEA, o índice PCLOSE testa a proximidade do ajuste, ou seja, ele testa a  $H_0: RMSEA \leq 0,05$ , deve ser maior que 0,05 para aceitar esta hipótese. Ideal que seja  $> 0,50$  (BYRNE, 2001). O PCLOSE é obtido conforme a expressão da equação (11).

$$PCLOSE = 1 - \phi(\hat{C}_{0,05}^2 nd.d) \quad (11)$$

Onde:  $n = N - r$  e  $r =$  número inteiro não negativo. Por *default*  $r = G$ .

**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 se está comparando dois ou mais modelos, e o que possuir menor AIC é que apresenta melhor ajuste do modelo hipotético (LEMKE, 2005). O AIC reflete a discrepância entre modelo implícito e as matrizes de covariância observadas, pode ser usado para comparar modelos não hierárquicos como também hierárquico (GARSON, 1998). O AIC é obtido conforme a expressão da equação (12).

$$AIC = \hat{C} + 2q \quad (12)$$

Onde:  $q =$  número de parâmetros.

**CN:** (*Critical N*); também chamado índice de Hoelter 0,05 e 0,01 (níveis de significância), adequação do tamanho da amostra ao modelo postulado com 95% de confiança e 99% de confiança, respectivamente. 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  $\chi^2$ . Um valor que exceda 200 é indicativo que o modelo representa adequadamente os dados amostrais (LEMKE, 2005).

Os índices de ajuste servem para informar quão bem o modelo hipotético se ajusta com os dados amostrais. Qual índice deve-se escolher para a análise depende de cada caso, 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 que os índices de ajuste global, sozinhos, não possibilitam saber tudo que se precisa conhecer sobre o modelo para poder julgar sua adequação. Mesmo com a natureza problemática da estatística  $\chi^2$ , utilizar exclusivamente os índices de ajuste é inaceitável. Esses índices não dão garantia de que o modelo é adequado, 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, se pode concluir que a avaliação da adequação do modelo deve ser baseada em múltiplos critérios, que envolvem considerações teóricas, estatísticas e práticas.

Além dos índices de modificação, é importante procurar alguma área que possa ter falta de ajuste. Existem dois campos que podem ser explorados com o objetivo de identificar a chamada falta de especificação [*misspecification*]: a) os resíduos padronizados; e b) os índices de modificação (LEMKE, 2005).

Qualquer discrepância entre a matriz de covariância implícita pelo modelo criado e a matriz de covariância amostral é capturada pela matriz residual de covariância. Como os resíduos são dependentes da unidade de medida das variáveis observadas 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 padrão assintóticos, eles representam uma estimativa do número de desvios padrão que os resíduos observados estão do resíduo zero, que existiria caso o modelo fosse perfeitamente ajustado. Valores maiores que 2,58 são considerados grandes (LEMKE, 2005).

Já os 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 (IM), que podem ser vistos como a estatística  $\chi^2$  com um grau de liberdade.

## **2.6 Características dos três pacotes computacionais (AMOS, EQS e LISREL)**

Programas de computador são ferramentas importantes para condução de SEM, no início dos anos 80 o LISREL (*Linear Estructural Relationships*), era essencialmente o único programa de equações estruturais disponível, atualmente existem muitas outras

escolhas para programas de ajuste de modelos: AMOS (*Analysis of MOment Structures*) por Arbuckle em 1997, CALIS (*Covariance Analysis and Linear Structural Equations*) por Hartmann em 1992, EQS (*Equations*) por Bentler em 1995, LISCOMP (*Linear Structural Equations with comprehensive Measurement Model*) por Muthén em 1987, RAMONA (*Reticular Action Model or Near Approximation*) por Brownie, Mels e Cowan em 1994, SEPATH (*SEM and Path Analysis*) por Steiger em 1995; entre outros.

O LISREL popularizou SEM em sociologia e ainda é o pacote de referência na maioria dos artigos sobre Modelagem de Equações Estruturais. O AMOS é um dos mais recentes pacotes que, por causa de sua interface gráfica amigável ao usuário, ficou popular como um modo mais fácil de especificar SEM (GARSON, 1998).

O LISREL é um programa de computador originalmente desenvolvido para a estimativa de um modelo geral de equação estrutural, por Jöreskog em 1973. É um programa estatístico avançado para análise multivariada de sistemas lineares com construtos latentes, sistemas de equações estruturais econométricas e uma variedade de métodos de fator analítico e modelos de estruturas de covariância, incluindo também poderosas ferramentas para análise com variáveis não métricas incluindo modelos de construtos latentes com indicadores ordinais. (CZIRAKY, 2004).

O software AMOS distingue-se por ter uma interface gráfica amigável ao usuário, incluindo ferramentas de desenho do modelo, e suporta estimativas de *bootstrapped*. Já o pacote LISREL tem um conjunto mais compreensivo de opções, incluindo restrições não lineares em estimativas de parâmetro, o módulo PRELIS2 (incluso no LISREL) pode ser usado para gerar uma matriz de covariância usando variáveis dicotômicas ou ordinais, ou amostras de *bootstrapped*.

O EQS por sua vez, é notável para lidar com grande número de dados, opções flexíveis para testes associados com modelos de reespecificação, e procedimentos de estimação para dados não normais. Também existem outras diferenças nos resultados obtidos (*output*). Por exemplo, a parte de diferenças em amigabilidade do usuário e características de resultado, note que o AMOS aplica a correção de Bartlett para qui-quadrado enquanto que LISREL não o faz, respondendo por diferenças no resultado estatístico para os mesmos dados (a partir de 1997) (GARSON, 1998).

Os três pacotes LISREL, AMOS, e EQS são os três pacotes estatísticos mais populares para análise de SEM, e têm em comum o fato de utilizarem modelos de regressão linear nas análises efetuadas para verificar as relações hipotetizadas entre variáveis (FARIAS; SANTOS, 2000). O pacote AMOS será apresentado de forma detalhada, porque este será o pacote utilizado na análise dos dados da aplicação prática

a ser apresentado no capítulo 4. A escolha por esse *software* foi devido a sua disponibilidade e também por sua facilidade na análise de SEM, as versões do LISREL apresentam uma interface complicada no seu uso, o que não acontece no AMOS. Já o *software* EQS não foi encontrado para sua avaliação.

### 2.6.1 AMOS

O programa estatístico considerado para discussão do estudo é o AMOS. É um programa compatível com a plataforma Windows e é um módulo opcional do SPSS, desde 1998 até o presente momento (2006), para este tipo de análise. Anteriormente a 1998 o LISREL era o programa comercializado por esta empresa (FARIAS; SANTOS, 2000). Apesar de o próximo capítulo estar embasado nos passos para a utilização de Modelagem de Equações Estruturais sugeridos por Hair *et al.* (1998), o qual em seu estudo utiliza o software LISREL, as análises feitas nesse presente trabalho serão realizadas com o software AMOS por sua maior facilidade de compreensão e por que o software LISREL foi encontrado apenas na versão estudante o que não viabilizava essa análise..

Segundo Arbuckle (1982), o desenho das variáveis no diagrama de caminhos a ser reconhecido pelo AMOS segue o especificado: os retângulos representam as variáveis observáveis; as elipses representam as variáveis latentes ou os erros; uma seta reta com uma única ponta indica o caminho ou a relação de causa entre duas variáveis; e uma seta curva com duas pontas entre duas variáveis representa uma covariância. Os diagramas devem ser desenhados de modo que o fluxo causal seja da esquerda para a direita.

Este programa possui dois métodos de programação: um com linhas de comando (AMOS *Basic*) e outro com a interface gráfica (AMOS *Graphics*). Com o AMOS *Graphics* é possível realizar as análises a partir do diagrama de caminhos, sem a necessidade de indicar as equações, isto é, fornece as estimativas graficamente em um diagrama de trajeto (LEMKE, 2005). Este tipo de interface é que será utilizada nesse trabalho.

No AMOS para cada parâmetro especificado, fixo, o software fornece um MI (índice de modificação), valor que representa a queda esperada no valor do  $\chi^2$  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 (LEMKE, 2005).

Os valores MI's e os EPCs são primeiramente calculados para possíveis covariâncias, depois para os pesos de regressão. Os únicos parâmetros do modelo para os quais os MI's são aplicáveis são esses que foram fixados com valor zero.

Cabe ressaltar que o software AMOS apresenta vários índices para verificar a adequação do modelo, outros índices, além dos apresentados no item 2.6, encontram-se no anexo A. Para maiores detalhes sobre as funções do AMOS, sugere-se a leitura de Byrne (2001) e Lemke (2005).

### 3 ESTÁGIOS PARA A UTILIZAÇÃO DA MODELAGEM DE EQUAÇÕES ESTRUTURAIS

A utilização da técnica de Modelagem de Equações Estruturais é um processo difícil e muitas vezes trabalhoso, pois exige o uso de técnicas que devem ser conduzidas de forma ordenada: é necessário que se utilize um mecanismo de como estruturar a SEM.

Alguns autores: Hair *et al.* (1998); Kline, (1998); Iriondo *et al.*, (2003); Kelloway, (1998), mostram os passos para se conduzir a Modelagem de Equações Estruturais. Aqui serão apresentados os sete estágios sugeridos por Hair *et al.*(1998). Kline (1998) e Iriondo *et al.* (2003) sugerem seis estágios para a aplicação da SEM e Kelloway (1998) sugere cinco estágios.

Os seis estágios sugeridos por Kline (1998): a) especificação do modelo; b) determinar se o modelo é identificado (um modelo é identificado se ele é teoricamente possível para derivar uma única estimativa de cada parâmetro do modelo de parâmetro); c) seleção das medidas das variáveis representadas no modelo e coleta de dados; d) análise do modelo; e) avaliação do ajuste do modelo; e f) reespecificação do modelo. Esses são os mesmos estágios sugeridos por Iriondo *et al.* (2003). Já para Kelloway (1998) os cinco estágios sugeridos são: a) especificação do modelo; b) identificação; c) estimação; d) teste do ajuste; e e) reespecificação.

Apesar de existir uma concordância entre esses poucos autores, todos sugerem que alguma metodologia de aplicação da Modelagem de Equações Estruturais seja usada. Para esse trabalho optou-se pela utilização dos estágios sugeridos por Hair *et al.* (1998) por serem os estágios mais detalhados e completos encontrados na literatura. Esse trabalho visa divulgação dos passos sugeridos por Hair de forma mais clara e com uma aplicação mais próxima da realidade da engenharia, um resumo prático para ser utilizado como guia em aplicações práticas. Os sete estágios são os seguintes:

a) Estágio 1: *Desenvolver um modelo teórico*, onde se avalia o papel na estratégia de modelagem confirmatória, se especificam as relações causais e tenta se evitar o erro de especificação.

b) Estágio 2: *Construir um diagrama de caminhos*, onde se definem os construtos endógenos e exógenos, se faz a conexão das relações no diagrama de caminhos.

c) Estágio 3: *Converter o diagrama de caminhos*, onde se traduzem as equações estruturais, se especifica o modelo de medidas, se determina o número de indicadores, se explica a confiabilidade do construto (medidas de itens isolados, uso de escalas validadas e análise de dois estágios) e se identificam as correlações de construtos (fatores) e variáveis observadas (indicadores).

d) Estágio 4: *Escolher o tipo de matriz de entrada de dados*, onde se verificam as suposições de SEM, normalidade dos dados, remoção de *outliers*; se avalia a adequação do tamanho da amostra, má especificação do modelo; se seleciona o método de estimação do modelo (*bootstrapping*, simulações, *jackknifing*)

e) Estágio 5: *Avaliar a identificação do modelo*, onde se determinam os graus de liberdade e se verificam e se corrigem problemas de identificação.

f) Estágio 6: *Avaliar as estimativas do modelo e qualidade do ajuste*, onde se identificam e corrigem estimativas transgressoras, se faz o ajuste no modelo estrutural e se pode comparar com modelos concorrentes.

g) Estágio 7: *Interpretação e modificação do modelo*, onde se verificam as modificações são indicadas caso haja justificativa teórica para as mudanças do modelo proposto

Na Figura 4 encontra-se o fluxograma resumido com os sete estágios para aplicação da Modelagem de Equações Estruturais. Cada um dos estágios será abordado detalhadamente.

### **3.1 Estágio 1: Desenvolvendo um modelo teórico**

A Modelagem de Equações Estruturais é baseada em relações causais, nas quais assume-se que a mudança em uma variável resulta em uma mudança em outra. Encontra-se esse tipo de afirmação quando se define uma relação de dependência como na análise de regressão. A intensidade e convicção com que o pesquisador pode assumir causalidade entre duas variáveis não repousam nos métodos analíticos escolhidos, mas na justificativa teórica fornecida para apoiar as análises (HAIR *et al.*, 1998). As proposições que compõem o modelo são frequentemente obtidas de pesquisas prévias ou da teoria (KELLOWAY, 1998).

Segundo Kline (1998) existem três critérios requeridos para que uma relação causal entre duas variáveis, X e Y, seja comprovada:



a) existência de precedência cronológica, ou seja, X precede Y no decorrer do tempo;

b) a direção da relação causal deve ser corretamente especificada, ou seja, ao invés de Y causar X ou de ambos exercerem mútua causalidade, X deve ser a causa de Y;

c) a relação entre X e Y não desaparece quando variáveis externas tais como as de causa comum de ambas as variáveis mantêm-se constantes.

Além dos critérios estabelecidos por Kline (1998), Hair *et al.* (1998) acrescenta mais o seguinte critério: d) uma base teórica para a relação.

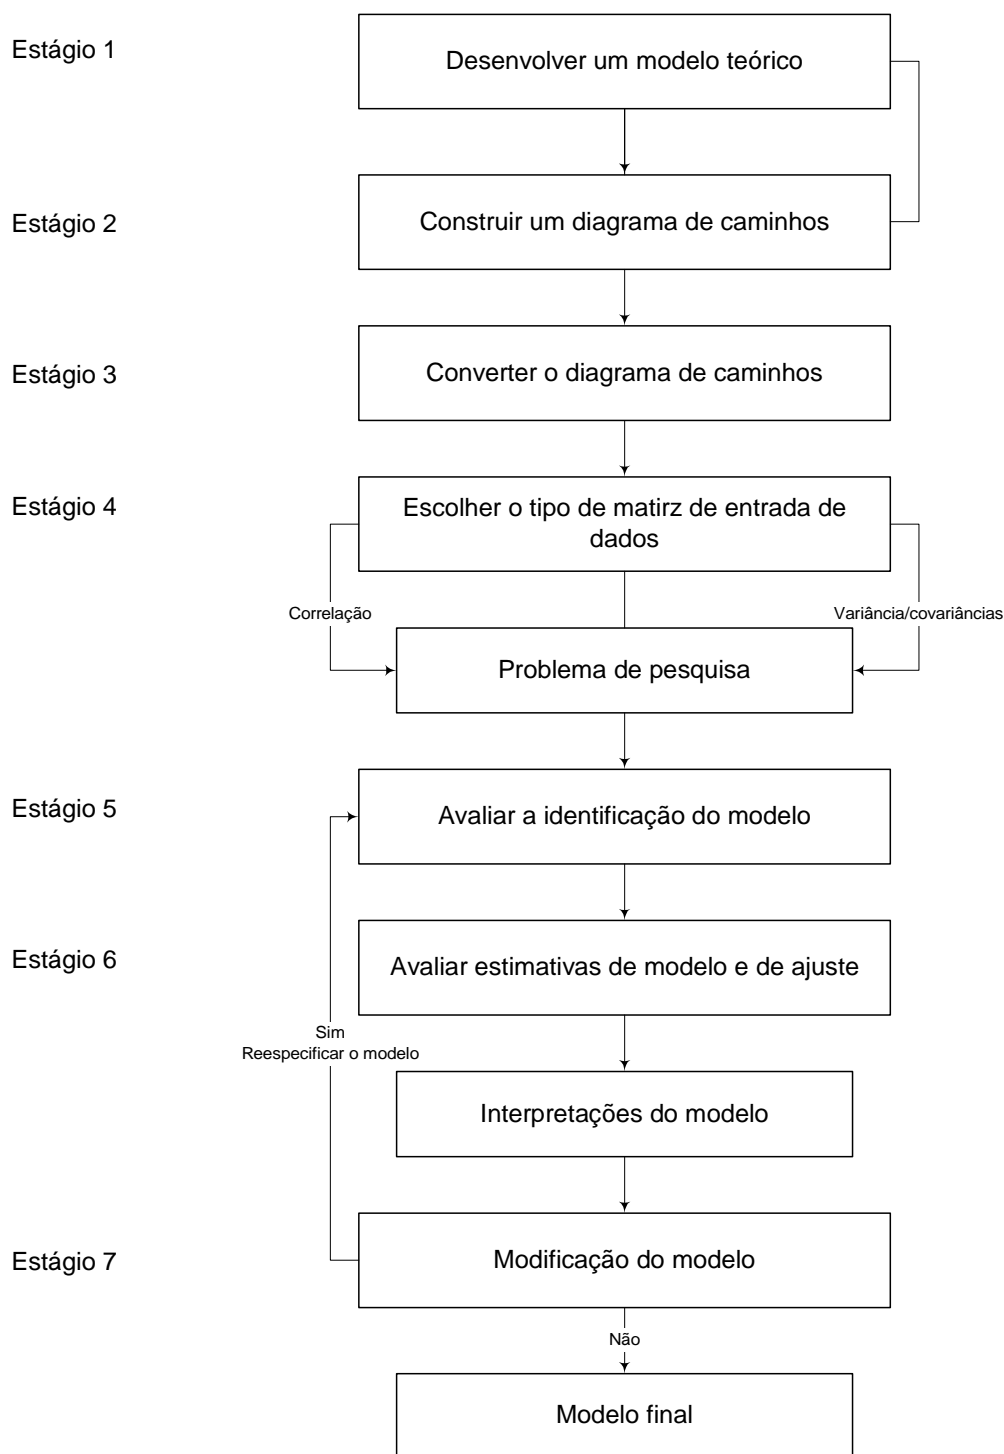
Variáveis observadas não podem ser combinadas arbitrariamente para formar variáveis latentes no modelo teórico. Pode-se utilizar a análise fatorial confirmatória para essa decisão, mas o pesquisador pode desejar aplicar testes tradicionais (ex., o alfa de Cronbach) ou conduzir análise fatorial exploratória tradicional (GARSON, 1998).

A exigência para qualquer forma de Modelagem de Equações Estruturais é a especificação *a priori* de um modelo (KELLOWAY, 1998). O erro mais crítico no desenvolvimento de modelos teóricos é a omissão de uma ou mais variáveis preditoras fundamentais, um problema conhecido como erro de especificação (*misspecification* – a omissão de uma variável significativa é a indução na avaliação da importância de outras variáveis). O desejo de incluir todas as variáveis, porém, deve ser equilibrado com as limitações práticas de SEM (tamanhos de amostra muito grandes com o aumento do número de variáveis). Apesar de não haver limite teórico no número de variáveis nos modelos, é preciso tomar cuidado com este fato, mesmo antes de os limites dos programas de computador serem atingidos. Mais frequentemente, a interpretação dos resultados, particularmente de significância estatística, se torna muito difícil à medida que o número de construtos se torna grande (excedendo 20) (HAIR *et al.*, 1998).

### **3.2 Estágio 2: Construção de diagrama de caminhos de relações causais**

A especificação do modelo consiste na tradução das hipóteses verbais em uma série de equações previamente representadas na forma de um diagrama de caminhos (IRIONDO *et al.*, 2003). Tipicamente, são especificados modelos por um desenho; ligações entre construtos são especificadas (KEYTON *et al.*, 2006). Um diagrama de caminhos é mais do que apenas uma descrição visual das relações, pois ele permite ao pesquisador apresentar não somente as relações preditoras entre construtos (ou seja, as

relações entre variáveis dependentes e independentes), mas também relações associativas (correlações) entre construtos e até mesmo indicadores (HAIR *et al.*, 1998).



**Figura 4: Fluxograma resumido com os sete estágios sugeridos por Hair *et al.* (1998). (Fonte: Hair *et al.* 1998)**

Além de mostrar as variáveis representadas por símbolos, o diagrama de caminhos também é capaz de mostrar processos hipotéticos envolvendo todo o sistema de variáveis (LEMKE, 2005). Assim sendo, o diagrama de caminho mostra as relações causais entre todas as variáveis no modelo. O diagrama deveria ser baseado em um

conhecimento *a priori* das relações causais que são, no final das contas, relacionadas a experiência prévia ou base teórica do pesquisador (BATISTA; COENDERS<sup>6</sup>, (2000) *apud* IRIONDO *et al.* 2003). Assim, o diagrama de caminhos representa a hipótese de funcionamento sobre as relações causais entre variáveis (IRIONDO *et al.*, 2003).

Antes de examinar diagramas de caminhos, deve-se rever dois elementos básicos utilizados em sua construção. O primeiro é a noção de construto, que é um conceito teórico que atua como “bloco de construção” usado para definir relações. Um construto pode representar um conceito tão simples como idade, renda, sexo, ou tão complexo quanto status socioeconômico, conhecimento, preferência ou atitude. Um pesquisador define diagramas de caminhos em termos de construtos e então busca por variáveis para medir cada construto. O segundo elemento básico é a seta, usada para representar relações específicas entre construtos. Uma seta retilínea indica uma relação causal direta de um construto a outro. Uma seta curvilínea (ou uma linha sem as pontas das setas) entre construtos indica simplesmente uma correlação entre os mesmos. Finalmente, uma seta retilínea com dois sentidos indica uma relação não recursiva ou recíproca entre construtos, conforme já visto (HAIR *et al.*, 1998).

Todos os construtos de um diagrama de caminhos podem ser colocados em uma de duas classes: exógenos ou endógenos. Construtos exógenos, também conhecidos como variáveis fonte ou variáveis independentes, não são “ocasionados” ou previstos por quaisquer outras variáveis no modelo. E construtos exógenos são aqueles preditos por um ou mais construtos. Construtos exógenos podem prever outros construtos endógenos (nesse caso, vêm-se as inter-relações que apontam para a necessidade de modelos estruturais), mas um construto exógeno pode estar causalmente relacionado apenas com construtos endógenos. Portanto, a diferença entre exógenos e endógenos é determinada exclusivamente pelo pesquisador, como é feito na distinção entre variáveis independentes e dependentes na regressão (HAIR *et al.*, 1998).

Duas suposições são assumidas em diagramas de caminhos. Primeiro todas as relações causais são indicadas, inclusão ou omissão de qualquer relação é baseada na teoria. É tão importante justificar por que uma relação causal não existe entre dois construtos quanto justificar a existência de uma outra relação. Também é importante lembrar que o objetivo é modelar as relações entre construtos com o menor número de caminhos causais ou correlações entre construtos que possam ser teoricamente justificados. A segunda suposição tem a ver com a natureza das relações causais que são assumidas como lineares. Como constatado com outras técnicas multivariadas, relações

---

<sup>6</sup> BATISTA, J. M. E COENDERS, G., **Modelos de Ecuaciones Estructurales**, La Muralla, S. A., Hespérides, Madrid, 2000.

não lineares não podem ser estimadas diretamente em Modelagem de Equações Estruturais, mas modelos estruturais modificados podem se compatibilizar com relações lineares (HAIR *et al.*, 1998).

### **3.3 Estágio 3: Conversão do diagrama de caminhos em um conjunto de modelos estrutural e de mensuração**

Depois de desenvolver o modelo teórico e representá-lo em um diagrama de caminhos, o pesquisador está pronto para especificar o modelo em termos mais formais. Isso é obtido por meio de uma série de equações que definem: a) as equações estruturais que conectam os construtos; b) o modelo de mensuração que especifica quais variáveis mede, quais construtos; e c) um conjunto de matrizes que indicam quaisquer correlações teorizadas entre construtos ou variáveis. O objetivo é conectar definições operacionais dos construtos com a teoria para o teste empírico apropriado (HAIR *et al.*, 1998). Resumindo, estas equações definem os parâmetros do modelo que correspondem a relações causais entre as variáveis observadas e as variáveis latentes que o *software* de SEM eventualmente calcula com dados amostrais (KLINE, 1998).

Traduzir um diagrama de caminhos em uma série de equações estruturais é um procedimento direto. Cada construto endógeno (qualquer construto com uma ou mais setas retilíneas que vão até ele) é a variável dependente em uma equação separada. Então as variáveis preditoras são todas construtos nos extremos terminais das setas retilíneas conduzindo até a variável endógena. Cada variável endógena pode ser prevista por variáveis exógenas ou por outras endógenas (HAIR *et al.*, 1998).

Para a especificação do modelo de mensuração, se faz a transição da análise fatorial, onde não se tem controle sobre quais variáveis descrevem cada fator para um modelo confirmatório, onde se deve especificar quais variáveis definem cada construto latente (fator). As variáveis observadas que são coletadas dos respondentes são chamadas de indicadores no modelo de mensuração, pois elas são usadas para medir, ou “indicar” os construtos latentes ou fatores (HAIR *et al.*, 1998). A análise fatorial é então utilizada para estabelecer quais variáveis observadas parecem medir as correspondentes variáveis latentes (GARSON, 1998).

O número mínimo de indicadores para um construto é um, mas o uso de apenas um indicador exige que se forneçam estimativas de confiabilidade. Um construto pode ser representado com dois indicadores, mas três é o número mais usual de indicadores,

pois usar somente dois indicadores aumenta as chances de se obter um modelo não adequado (HAIR *et al.*, 1998). Segundo Garson (1998), o uso de dois indicadores é problemático, pois são mais prováveis de não serem identificados e/ou não convergirem, e as estimativas de erro podem não ser confiáveis, e com uma medida o erro não pode ser modelado. Independentemente da base teórica que deve ser usada para selecionar variáveis como indicadores de um construto, não há limite superior para o número de indicadores. Como questão prática, porém, cinco a sete indicadores devem representar a maioria dos construtos (HAIR *et al.*, 1998).

Após o modelo de mensuração ser especificado procede-se com a verificação da confiabilidade dos indicadores. Há dois métodos principais para estabelecer a confiabilidade: a) estimação empírica ou b) especificação pelo pesquisador. A estimação empírica de confiabilidade só é possível se o construto tiver dois ou mais indicadores. Quando os modelos estruturais e de mensuração são estimados, os coeficientes de cargas fornecem estimativas das confiabilidades dos indicadores e do construto geral. No caso de especificação das confiabilidades o pesquisador especifica ou “fixa” as confiabilidades. Essa especificação se justifica em pelo menos três situações: a) quando a estimação empírica não é possível, mas se pode saber que ainda existe erro de mensuração, b) os indicadores podem ter sido usados extensivamente, portanto, as confiabilidades são conhecidas antes do uso, c) uma abordagem de dois passos na qual as confiabilidades primeiro são avaliadas e em seguida especificadas no processo de estimação (HAIR *et al.*, 1998).

#### **3.4 Estágio 4: Escolha do tipo de matriz de entrada e estimação do modelo proposto**

Como mostrado nos estágios anteriores para o uso de SEM é exigido muito mais em termos de especificação do modelo a ser estimado do que com qualquer outra técnica multivariada, com a possível exceção da análise conjunta. As decisões tomadas a respeito da estimação do modelo especificado, as questões de entrada (*input*) e a seleção do procedimento têm impacto sobre os resultados alcançados (HAIR *et al.*, 1998).

Outras técnicas multivariadas diferem de SEM no sentido de que ela usa apenas a matriz de variância /covariância ou de correlação como dados de entrada. O foco de SEM não é sobre observações individuais, mas sobre o padrão de relações entre os respondentes (HAIR *et al.*, 1998).

SEM compartilha três suposições com outros métodos multivariados: observações independentes, amostragem aleatória de respondentes e a linearidade de todas as relações. Além disso, SEM é mais sensível às características de distribuição dos dados, particularmente ao desvio de normalidade multivariada ou a uma forte curtose nos dados (HAIR *et al.*, 1998).

Uma falta de normalidade multivariada nos dados é particularmente problemática por que ela substancialmente inflaciona a estatística qui-quadrado e cria um viés ascendente em valores críticos para determinar significância de coeficientes (HAIR *et al.*, 1998). O uso de variáveis ordinais ou dicotômicas é uma das causas de violação da normalidade multivariada (GARSON, 1998).

Uma questão importante também na interpretação dos resultados é o uso da matriz de variância e covariância versus a matriz de correlação. A matriz de covariância tem a vantagem de fornecer comparações válidas entre diferentes populações ou amostras, uma característica não possível quando modelos são estimados com uma matriz de correlação. A interpretação dos resultados, porém, é de algum modo mais difícil quando se usam covariâncias, pois os coeficientes devem ser interpretados em termos das unidades de medida dos construtos (HAIR *et al.*, 1998).

A matriz de correlação ganhou amplo uso em muitas aplicações. Matrizes de correlação têm amplitude comum que torna possível fazer comparações diretas dos coeficientes dentro de um modelo, pois tal matriz é simplesmente uma matriz de variância e covariância “padronizada” na qual a escala de mensuração de cada variável é removida pela divisão das variâncias ou covariâncias pelo produto dos desvios padrão. O uso de correlações é adequado quando o objetivo é apenas compreender o padrão de relações entre os construtos, mas não explicar a variância total de um construto (HAIR *et al.*, 1998).

Recomenda-se o uso de covariâncias, especialmente quando se pretende testar uma teoria. O uso de correlações é indicado quando o objetivo da pesquisa é compreender o padrão das relações existentes entre os construtos ao invés de procurar explicar a sua variância total, quando se deseja comparar variáveis diferentes, ou ainda quando as covariâncias não satisfazem às suposições metodológicas necessárias. Os resultados e suas generalizações devem ser interpretados com maior cautela sempre que se utilizarem as correlações (MÜCKENBERGER, 2000)

Quanto ao tamanho da amostra, a questão crítica de SEM envolve o quão grande uma amostra se faz necessária. Apesar de não haver um critério único para ditar o tamanho amostral necessário, existem pelo menos quatro fatores que provocam impacto

sobre as exigências de tamanho de amostra: a) má especificação do modelo; b) tamanho do modelo; c) desvios da normalidade; e d) procedimento de estimação. Recomendam-se tamanhos de amostra entre 200 e 400 para modelos com 10 a 15 indicadores (HAIR *et al.*, 1998).

Segundo Garson (1998), considera que tamanhos de amostra menores que 100 são insustentáveis em SEM. Uma amostra de 150 é considerada muito pequena a menos que os coeficientes de covariância sejam relativamente grandes. Loehlin<sup>7</sup> (1992) *apud* GARSON (1998) recomenda pelo menos 100 casos, preferivelmente 200. Com mais de dez variáveis, tamanho de amostra inferior a 200, pode gerar estimativas de parâmetro instáveis e testes significância sem força. Para Garson, (1998) a regra básica, é que o tamanho de amostra deveria ser pelo menos 8 vezes o número de variáveis no modelo mais 50 amostras. Outra regra, baseada em Stevens (1996), é ter 15 casos por variável observável. Bentler e Chou<sup>8</sup> (1987) *apud* GARSON (1998) recomenda pelo menos 5 casos por estimativa de parâmetro (inclusive condições de erro como também coeficientes de caminho). Hair *et al.* (1998) sugere de 5 a 10 casos por parâmetro estimado. O pesquisador deve ir além destas recomendações de tamanho de amostra mínima quando os dados forem não normais ou incompletos (GARSON, 1998).

A SEM é uma técnica para grandes amostras. Embora existam várias regras, como por exemplo, 200 é o tamanho da amostra “piso”, tamanhos de amostra maiores são mais apropriados. A complexidade do modelo e o tamanho do efeito antecipado devem ser considerados (KEYTON *et al.*, 2006).

Quando os dados violam as suposições de normalidade multivariada, a proporção de respondentes por parâmetros precisa aumentar para uma razão geralmente aceita de 15. Embora alguns procedimentos de estimação sejam especificamente delineados para lidar com dados não normais, o pesquisador é sempre encorajado a fornecer suficiente tamanho amostral para permitir que o impacto do erro de amostragem seja minimizado, especialmente para dados não normais (HAIR *et al.*, 1998).

A estimativa de máxima verossimilhança (MLE - *Maximum Likelihood Estimation*), o procedimento de estimação mais comum, tem fornecido resultados válidos com amostras tão pequenas quanto de 50 casos, mas tal diminuto tamanho não é recomendado. Geralmente se aceita que o tamanho mínimo de amostra para garantir uso

---

<sup>7</sup> LOEHLIN, J. C.; **Latent variable models: An introduction to factor, path, and structural analysis**. Hillsdale, NJ: Lawrence Erlbaum. 2<sup>a</sup> ed., 1992.

<sup>8</sup> BENTLER, P. M. e CHOU, C. P.; **Practical issues in Structural Modeling**. Sociological Methods and Research. v.16 p.78-117, 1987.

apropriado de MLE seja de 100 a 150. Quando se aumenta o tamanho amostral acima desse valor, o método MLE aumenta em sua sensibilidade na detecção de diferenças entre os dados. Quando o tamanho amostral se torna grande (excedendo de 400 a 500), o método se torna “muito sensível” e quase qualquer diferença é detectada, fazendo com todas as medidas de qualidade de ajuste indiquem ajuste ruim (LEMKE, 2005).

Assim que os modelos estruturais e de mensuração são especificados e o tipo de dados de entrada é selecionado, deve-se escolher como o modelo será estimado. No caso de SEM, se tem diversas opções tanto para o procedimento de estimação quanto para o programa de computador a ser usado (HAIR *et al.*, 1998).

As primeiras tentativas de estimação do modelo de equações estruturais foram realizadas com regressão de mínimos quadrados ordinários (OLS - *Ordinary Least Squares*). Mas esses esforços foram rapidamente suplantados por estimação de máxima verossimilhança, a qual é eficiente e não viesada quando a suposição de normalidade multivariada é atendida. Essa se tornou a técnica mais usada em quase todos os programas de computador específicos de SEM. A sensibilidade da estimativa de máxima verossimilhança (MLE) à não normalidade, entretanto, criou uma necessidade para técnicas de estimação alternativas, e métodos tais como mínimos quadrados ponderados (WLS - *Weighted Least Squares*), mínimos quadrados generalizados (GLS - *Generalized Least Squares*) e estimação assintoticamente livre de distribuição (ADF - *Asymptotically Distribution-Free*), se tornaram disponíveis (HAIR *et al.*, 1998). Essas técnicas serão explicadas posteriormente.

Além da técnica de estimação empregada, se pode também escolher entre diversos processos de estimação. Esses procedimentos variam de estimação direta do modelo, que é semelhante ao que é feito em técnicas multivariadas anteriores a SEM, há métodos que geram milhares de estimações de modelo a partir das quais os resultados finais do modelo são obtidos. Existem quatro métodos básicos: estimação direta, *bootstrapping*, simulação e *jackknifing*. Estimação direta onde um modelo é diretamente estimado com um procedimento selecionado; *bootstrapping* onde estimativas finais de parâmetro são calculadas ao longo de todas as amostras geradas, o intervalo de confiança não é estimado por erro amostral, mas diretamente observado; simulação onde o programa de simulação pode mudar certas características da amostra para atender aos objetivos do pesquisador e *jackknifing* onde cada vez que uma amostra nova é criada, uma observação diferente é omitida.



### 3.5 Estágio 5: Avaliação da identificação do modelo estrutural

Após a escolha do tipo de matriz de entrada do modelo passa-se a identificação do modelo proposto. Um problema de identificação, em termos simples, é a falta de habilidade do modelo proposto para gerar as estimativas. Baseia-se no princípio de que se deve ter uma equação separada e única para estimar cada coeficiente. No entanto, à medida que modelos estruturais se tornam mais complexos, não há garantia para assegurar que o modelo seja identificado (HAIR *et al.*, 1998).

Na prática isto significa criar termos de erro para toda variável endógena e especificando o peso da regressão para cada termo de erro e ao usar variáveis ocultas com mais de um indicador, fixar o peso de regressão de pelo menos um caminho igual a 1 (JAKSON *et al.*, 2005).

Para fins de identificação, o pesquisador está preocupado com o tamanho da matriz de covariância ou de correlação relativamente ao número de coeficientes estimados. A diferença do número de correlações ou covariâncias e o número real de coeficientes no modelo proposto, é chamado de graus de liberdade. O número de graus de liberdade para um modelo proposto é calculado conforme a equação (13):

$$gl = \frac{1}{2}[(p + q)(p + q + 1)] - t \quad (13)$$

Onde:  $p$  = número de indicadores endógenos;  $q$  = número de indicadores exógenos e  $t$  = número de coeficientes estimados no modelo proposto.

Os programas computacionais de equações estruturais também executam testes empíricos para diagnosticar problemas de identificação. O LISREL executa um teste simples para identificação durante o processo de estimação pelo exame da matriz de informação, enquanto o EQS realiza o teste de ordenamento de Wald (HAIR *et al.*, 1998).

Pode-se também procurar por possíveis sintomas de problemas de identificação. Entre eles estão: (i) erros padrão muito grandes para um ou mais coeficientes, (ii) a falta de habilidade do programa para inverter a matriz de informação, (iii) estimativas exorbitantes ou impossíveis como variâncias negativas de erro ou (iv) elevadas correlações ( $\pm 0,90$  ou mais) entre os coeficientes estimados (HAIR *et al.*, 1998).

A única solução para um problema de identificação é definir mais restrições sobre o modelo, ou seja, eliminar alguns coeficientes estimados. Deve-se gradualmente acrescentar mais restrições (eliminando caminhos do diagrama de caminhos) até que o

problema seja resolvido. Fazendo isso se está tentando conseguir um modelo superidentificado que tem graus de liberdade disponíveis para avaliar, se possível, a quantia de erro amostral e de mensuração e assim fornecer melhores estimativas das “reais” relações causais (HAIR *et al.*, 1998).

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 ser estimados. Entretanto, apesar da capacidade do modelo em identificar uma única solução para todos os parâmetros, o modelo *just-identified* não é cientificamente interessante por que não possui graus de liberdade e jamais poderá ser rejeitado, ou seja, como o modelo *just-identified* é aquele em que existe apenas uma única solução para cada parâmetro estimável em um sistema de equações estruturais, não existindo assim graus de liberdade, alternativas para serem testadas, e por isso nunca 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 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* (LEMKE, 2005).

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 saber se o modelo que se está testando é ou não estatisticamente identificável (LEMKE, 2005).

### **3.6 Estágio 6: Avaliação de critérios de bondade de ajuste**

O primeiro passo na avaliação dos resultados é a inspeção inicial em busca de “estimativas transgressoras”. Logo que o modelo é estabelecido como fornecendo estimativas aceitáveis, a qualidade de ajuste deve então ser avaliada em diversos níveis: primeiro para o modelo geral e então para os modelos de mensuração e estrutural separadamente (HAIR *et al.*, 1998).

Os resultados são primeiramente examinados quanto a estimativas transgressoras. Elas são coeficientes que excedem limites aceitáveis. Os exemplos mais comuns são: a) variâncias negativas ou não significantes de erros para qualquer construto, b) coeficientes padronizados excedentes ou muito próximos de 1,0 ou c) erros padrão muito grandes associados com qualquer coeficiente estimado (HAIR *et al.*, 1998).

Logo que se estabelece que não existem estimativas transgressoras, o próximo passo é avaliar o ajuste geral do modelo com uma ou mais medidas de bondade de ajuste. A qualidade do ajuste mede a correspondência da matriz de dados de entrada observados (covariância ou correlação) com aquela prevista pelo modelo proposto (HAIR *et al.*, 1998).

Assim que o ajuste geral do modelo tenha sido avaliado, a mensuração de cada construto pode então ser avaliada quanto a unidimensionalidade e confiabilidade. A unidimensionalidade é uma suposição inerente ao cálculo de confiabilidade e é demonstrada quando os indicadores de um construto têm ajuste aceitável sobre um modelo unidimensional, ou seja, de um só fator (HAIR *et al.*, 1998).

O mais óbvio exame do modelo estrutural envolve a significância dos coeficientes estimados. Métodos de Modelagem de Equações Estruturais fornecem não somente coeficientes estimados, mas também erros padrão e valores da estatística *t* calculados para cada coeficiente. Ao se especificar um nível de significância adequado (por exemplo, 0,05), cada coeficiente estimado pode ser testado quanto à significância estatística para a relação causal teorizada. No entanto, dado às propriedades estatísticas da estimativa de máxima verossimilhança e suas características em amostras menores, é necessário ser moderado na especificação do nível de significância, escolhendo níveis menores (0,025 ou 0,01) no lugar do tradicional 0,05 (HAIR *et al.*, 1998).

Vários métodos de estimação estão disponíveis como abordado no item 3.4. O mais frequentemente usado é a estimativa de máxima verossimilhança (MLE), embora os mínimos quadrados generalizados (WLS) sejam tecnicamente superiores porque independem de algumas exigências como a suposição de normalidade, o que em muitos casos pode ser difícil de encontrar. Não obstante, o WLS não é aplicável para modelos que contêm muitas variáveis (mais de 10 variáveis) ou para amostras de tamanho pequeno ( $n < 1000$ ) (IRIONDO *et al.*, 2003).

Como uma medida da equação estrutural total, um coeficiente geral de determinação ( $R^2$ ) é calculado, semelhante àquele encontrado na regressão múltipla. A despeito de que nenhum teste de significância estatística possa ser executado, ele

fornece uma medida relativa de ajuste para cada equação estrutural. Os resultados de SEM podem ser afetados por multicolinearidade, como se observa na regressão. Programas de computador fornecem uma matriz de correlação dos valores estimados para os construtos latentes. Se valores altos aparecem, então uma ação corretiva deve ser tomada. Essa ação pode incluir a eliminação de um construto ou reformulação de relações causais (HAIR *et al.*, 1998).

Apesar de nenhum limite ter sido estabelecido para definir o que se considera como altas correlações, valores superiores a 0,90 sempre devem ser examinados, e muitas vezes correlações que ultrapassem 0,80 podem ser indicativas de problemas (HAIR *et al.*, 1998).

### **3.7 Estágio 7: Interpretação e modificação do modelo**

Os modelos especificados normalmente são rejeitados pelos testes de excelência de adequação devido à sua complexidade e um número grande de restrições existentes. Neste estágio o modelo necessita ser modificado para melhorar o ajuste ou sua simplicidade. Obter coeficientes de caminho não significantes de acordo com o teste de Wald<sup>9</sup> pode indicar caminhos que são suscetíveis de serem eliminados do modelo. Os testes dos multiplicadores de Lagrange<sup>10</sup> também podem prover pistas de como melhorar a consistência do modelo de dados. Este teste fornece uma estimação da redução que seria obtido na estatística de qui-quadrado do modelo se um caminho particular fosse acrescentado ao modelo. Os caminhos que poderiam reduzir significativamente o qui-quadrado do modelo podem ser considerados pelo investigador, embora estes não deveriam ser incluídos a menos que haja um auxílio teórico para tal relação (IRIONDO *et al.*, 2003).

Assim que o modelo é considerado aceitável, se deve primeiro examinar os resultados quanto a sua correspondência com a teoria proposta. Deve-se perguntar se as principais relações na teoria são mantidas e consideradas estatisticamente significativas, se os modelos concorrentes acrescentam alguma visão quanto a formulações alternativas da teoria possam ser sustentadas e se todas as relações estão na direção teorizada (positiva ou negativa). Todas essas e muito mais questões podem ser formuladas a partir dos resultados empíricos. Enquanto se abordam essas questões, se

---

<sup>9</sup> O teste de Wald é uma alternativa a testes de índice de modificação ao determinar quais setas compõem um modelo.

<sup>10</sup> Também conhecido como Índice de modificação (MI - *Modification indexes*)

pode achar necessário considerar dois aspectos da interpretação: o uso das soluções padronizadas versus não-padronizadas e reespecificação do modelo (HAIR *et al.*, 1998).

Quando modificações no modelo são feitas, se deve retornar ao estágio 5 do processo de sete estágios e reavaliar os modelos modificados. Se extensas modificações são antecipadas, os dados devem ser divididos em duas amostras, uma fornecendo a base para estimação e modificação e a outra fornecendo validação do modelo final (HAIR *et al.*, 1998).

## 4 APLICAÇÃO DE SEM EM UM ESTUDO PRÁTICO

Para os dados dessa análise foi utilizado um questionário que foi elaborado e aplicado por Milan (2006) para medir a opinião de clientes com relação a um provedor de serviços. O questionário utilizado encontra-se no anexo B. A pesquisa foi realizada por Milan (2005) com uma amostra de 274 usuários. Nesse trabalho serão utilizados esses dados para exemplificar os sete estágios abordados no capítulo 3.

No questionários elaborado por Milan (2006) primeiramente foi realizada uma pesquisa qualitativa em profundidade embasadas num roteiro pré-definido, realizada com 4 clientes da empresa. A população considerada para esta pesquisa compreende os clientes de uma empresa do Estado do Rio Grande do Sul, localizados, mais especificamente, na Grande Porto Alegre e na região Nordeste do Estado, devido à representatividade em sua carteira de clientes, tanto em relação ao número de clientes nestas duas regiões quanto ao volume de negócios gerado. A partir disso, foi definida a amostra, utilizando-se a técnica de amostragem não probabilística por conveniência, a qual não utiliza a seleção aleatória de unidades amostrais dentre os componentes da população, baseando-se no julgamento pessoal do pesquisador. A coleta de dados foi realizada pelo método de levantamento, com base em um questionário estruturado e formal, uma parte dos questionários foi entregue pelo próprio pesquisador nas empresas, auxiliado por mais quatro pessoas devidamente capacitadas, direcionando-os ao respondente mais adequado ao estudo, e outra parte enviada pelo correio. O processo de coleta aconteceu entre novembro de 2005 e janeiro de 2006, resultando em um retorno de 278 entrevistas e considerados 274 questionários válidos.

Quanto aos *outliers*, foram avaliados se existiam casos com escores muito diferentes em comparação ao restante dos casos. Desse modo, foram calculados os *z scores*, verificando-se a existência de escores extremos. Escores maiores do que três desvios padrão em relação às médias ou valores superiores a  $|3|$  para cada variável (HAIR *et al.*, 1998) podem caracterizar um *outlier*. Com base no teste de padronização das variáveis e em sua respectiva análise, foram identificados onze *outliers*, os quais foram eliminados, finalizando a amostra em 263 casos.

#### 4.1 Desenvolvimento de um modelo teórico

O modelo teórico pretende descrever fatores sobre a visão do usuário em relação ao provedor. Para tanto foi utilizado o questionário anteriormente citado, composto por 30 questões, cujas respostas, inicialmente, pretendem ser explicadas por cinco fatores: a) satisfação com o provedor (SAT); b) valor do provedor (VAL); c) reputação do provedor (REPU); d) confiança depositada no provedor (CONF); e e) fidelidade (FIDE) do usuário para com o provedor de serviços.

Como o questionário não é um instrumento de medida validado. Partiu-se de um modelo explicado e se foi testando o melhor modelo possível, já que este não é um caso unicamente confirmatório (onde se testa se um único modelo teórico é validado ou não) neste caso não se tem tal modelo em estudos anteriores ou um questionário construído para esse modelo.

O modelo inicial é assim postulado:

- Fator SAT → medido pelas questões 1 até 6;
- Fator VAL → medido pelas questões 7 até 10;
- Fator REPU → medido pelas questões 11 até 15;
- Fator CONF → medido pelas questões 16 até 24;
- Fator FIDE → medido pelas questões 25 até 30 e

todos os fatores são intercorrelacionados.

#### 4.2 Construção de diagrama de caminhos de relações causais

Após estabelecer o modelo teórico, no estágio 2 se estabelece o diagrama de caminhos. O diagrama de caminhos para o modelo construído encontra-se na Figura 5. Ele foi obtido utilizando o software AMOS versão 4.0, na interface gráfica, nos estudos efetuados por Hair et al. (1998) se utiliza o software LISREL, mas como já defendido anteriormente esse trabalho utiliza o pacote AMOS por sua maior facilidade e interface gráfica mais amigável.

O diagrama é derivado diretamente da formulação do questionário, que apresenta os cinco fatores (SAT, VAL, REPU, CONF, FIDE) com suas perguntas atribuídas. O fator SAT é medido pelas perguntas 1 a 6; o fator VAL é medido pelas

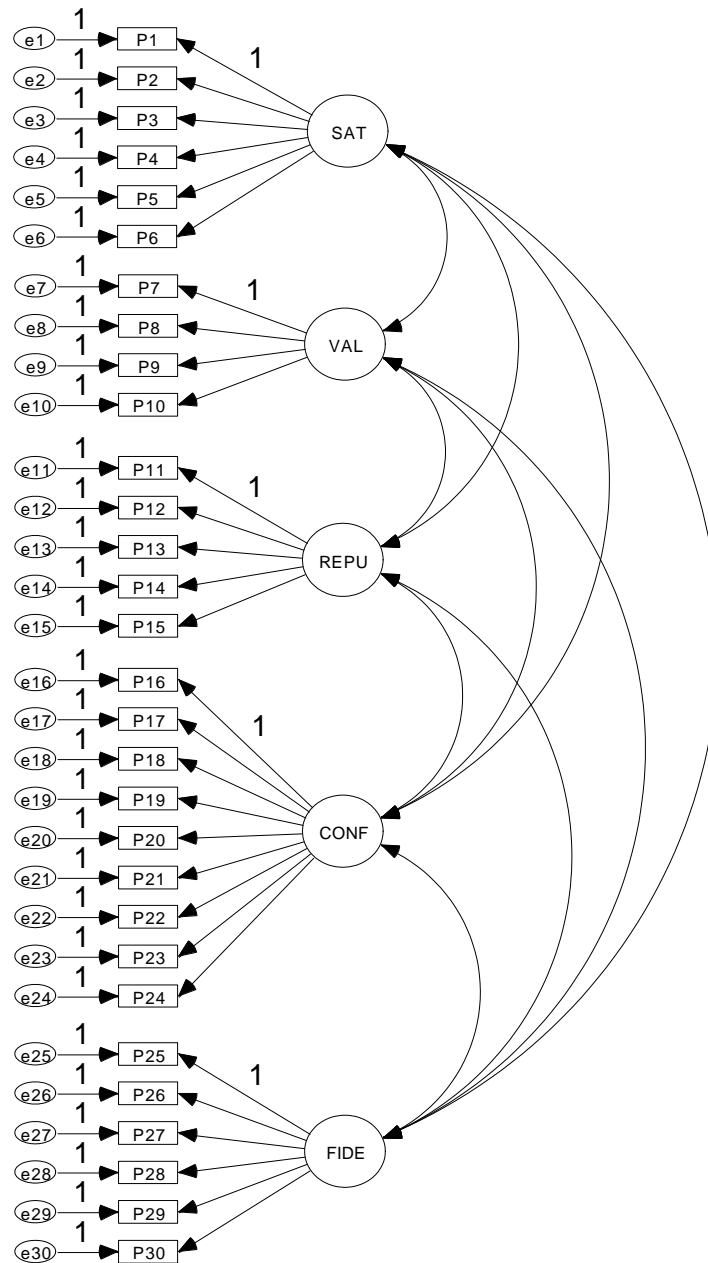
perguntas 7-10 e assim por diante, conforme o modelo postulado no item 4.1. Cada item, que é uma variável observada tem um termo de erro associado, que representa o erro de medida. Os cinco fatores são correlacionados, como mostram as setas bidirecionais entre todos os fatores.

O diagrama da Figura 5 apresenta o modelo hipotético do modelo postulado no estágio 1, onde se tem 5 fatores (ou variáveis latentes), que são representados por círculos (ou elipses). Estes fatores estão, cada qual, associados as suas variáveis indicadoras, isto é, variáveis observadas, que são perguntadas diretamente no questionário e que são representadas por retângulos. A cada pergunta está associado um termo de erro, que pode ser proveniente de duas fontes: erro aleatório de medida e erro derivado de alguma característica específica particular da variável observada, conhecido na literatura também como erro único, que não é aleatório. Os termos de erro são apresentados em forma de círculos ou elipses, pois são sempre não observados.

As setas apontando para um sentido único representam coeficientes de regressão estrutural, que indicam o impacto de uma variável na outra. Na Figura 5, as setas unidirecionais que apontam dos fatores em direção as suas variáveis observadas sugerem que seus valores são influenciados pelos seus respectivos fatores. As setas unidirecionais vindas dos erros indicam o impacto do erro de medida nas variáveis observadas. As setas bidirecionais representam as covariâncias ou correlações entre os pares de variáveis.

O *software* AMOS permite que seus resultados sejam apresentados, além da forma gráfica no diagrama de caminhos, na forma tabular e na forma textual. Essa tabela tem a utilidade de apresentar a lista de variáveis do modelo, discriminadas como sendo endógenas, exógenas, observadas e não observadas. Apresentando ao final um sumário dos parâmetros, e a informação de que o modelo é recursivo, ou seja, não tem efeito *feedback loops*. A forma tabular retirada da saída do AMOS encontra-se no apêndice A. Essa saída com todas as informações para avaliação do modelo, a escolha do tipo de saída – tabular, textual ou gráfica – é simplesmente pela preferência de exposição e /ou visualização





**Figura 5: Diagrama de caminhos AFC do MODELO realizado no software AMOS**  
 {Fonte: elaborada pela autora com o software AMOS}

### 4.3 Estágio 3: Conversão do diagrama de caminhos em um conjunto de modelos estrutural e de mensuração

O modelo hipotético não possui efeitos entre os construtos, apenas correlações (isso serve para todos os modelos hipotéticos). O modelo estrutural é formado pelas relações entre os construtos, ele especifica como uma variável latente particular causa mudanças em outras variáveis latentes no modelo (isso é específico deste modelo). Isso

não acontece na análise fatorial confirmatória do modelo proposto, pois nela se tem apenas o modelo de medida, ou seja, o modelo rege as relações das variáveis observadas com os construtos, já o modelo estrutural rege as relações entre os fatores, o que não acontece na AFC. Caso acontecesse, o modelo não seria de AFC e se tornaria de *path analysis* ou de regressão, por exemplo.

No modelo de medida estão definidas as relações entre as variáveis observadas e as variáveis não observadas. É a ligação entre os escores do instrumento de medida (variáveis indicadoras) e o construto teórico a que foram designadas para medir (variáveis latentes não observadas). Esse é o caso da análise fatorial confirmatória que está sendo avaliada.

Para se traduzir o modelo em equações estruturais, cada variável que possui uma ou mais setas unidirecionais apontando para ela, forma uma equação. Observando-se a Figura 5 pode-se notar que as 30 variáveis indicadoras estão presentes e com base nas informações da figura pode-se montar as equações estruturais, expressas pela equações de (14) a (18):

- Para o construto “satisfação” (SAT):

$$P_i = \lambda_i \text{SAT} + e_i \quad (14)$$

Onde:  $P_i$  é ....  $\lambda_i$  é .... e  $e_i$  é .... para  $i=1, \dots, 6$

- Para o construto “valor” (VAL):

$$P_i = \lambda_i \text{VAL} + e_i \quad i=7, \dots, 10 \quad (15)$$

- Para o construto “reputação” (REPU):

$$P_i = \lambda_i \text{REPU} + e_i \quad i=11, \dots, 15 \quad (16)$$

- Para o construto “confiança” (CONF):

$$P_i = \lambda_i \text{CONF} + e_i \quad i=16, \dots, 24 \quad (17)$$

- Para o construto “fidelidade” (FIDE):

$$P_i = \lambda_i \text{FIDE} + e_i \quad i=25, \dots, 30 \quad (18)$$

#### 4.4 Estágio 4: Escolha do tipo de matriz de entrada e estimação do modelo proposto

Neste estágio se mantém as mesmas equações do modelo, apenas se decide se a estimação será padronizada (matriz de correlação) ou se será na unidade original (matriz de covariância). A matriz de entrada utilizada no modelo é a matriz de correlação, que permite comparações diretas dos coeficientes dentro do modelo, pelo fato de estar padronizada (aqui não serão feitas comparações entre diferentes amostras e populações, se quer facilitar a comparação entre as variáveis, que por estarem na forma padronizada se utiliza a correlação). A Figura 6 apresenta a matriz de correlação utilizada como entrada de dados.

Para o número de parâmetros estimados, a amostra que é composta por 263 entrevistados é considerada de tamanho pequeno, conforme citado por alguns autores no trabalho de Garson (1998). Hair *et al.* (1998) sugere de 5 a 10 casos por parâmetro estimado. Isso significa que para este modelo se precisaria de, no mínimo,  $70 \times 5 = 350$  casos. A análise continuará sendo realizada, com o objetivo de mostrar a técnica de Modelagem de Equações Estruturais no *software* AMOS, até por que autores como Lohelin (1992) *apud* Garson (1998) sugerem amostras maiores que 200.

Os 70 parâmetros livremente estimados são divididos em 25 coeficientes de regressão (cargas fatoriais), ou seja, igual as 30 questões menos as 5 fixadas (com o valor 1, são contrastes para fornecer ao fator associado uma referência de medida, já que são não observados, e também às vezes para identificar o modelo diminuindo os graus de liberdade); 30 variâncias residuais; 5 variâncias dos fatores; 10 covariâncias. Para esse passo é interessante se observar respectiva figura do diagrama. Conforme mostra a Figura 5 tem-se 70 parâmetros especificados pelo modelo para serem estimados. Que são assim distribuídos:

- a) Tem-se 30 itens do questionário, que são as variáveis observadas, representadas pelos retângulos. Como uma variável em cada fator é fixada com um número 1, ficando então 25 cargas fatoriais ou coeficientes de regressão.
- b) O AMOS estima também a variância de cada variável não observada, que são representadas em forma de círculos (ou elipses). Que são as 30 variâncias dos erros de medida mais as 5 variâncias dos fatores.
- c) Finalmente, através do modelo postulado conforme a Figura 5, o AMOS estima também as covariâncias entre os fatores. Como se tem 5 fatores, 5 combinação dois a dois, isto é, 10 combinações, fechando assim os 70 parâmetros estimáveis.

rowtype_	varname_	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12	p13	p14	p15
n		263	263	263	263	263	263	263	263	263	263	263	263	263	263	263
corr	p1	1,000														
corr	p2	0,952	1,000													
corr	p3	0,838	0,836	1,000												
corr	p4	0,715	0,753	0,709	1,000											
corr	p5	0,849	0,814	0,756	0,671	1,000										
corr	p6	0,895	0,876	0,827	0,746	0,871	1,000									
corr	p7	0,838	0,800	0,776	0,662	0,739	0,794	1,000								
corr	p8	0,699	0,684	0,664	0,551	0,703	0,730	0,654	1,000							
corr	p9	0,772	0,747	0,703	0,640	0,756	0,773	0,700	0,847	1,000						
corr	p10	0,828	0,805	0,724	0,670	0,781	0,812	0,779	0,756	0,878	1,000					
corr	p11	0,680	0,660	0,592	0,595	0,594	0,661	0,622	0,492	0,576	0,633	1,000				
corr	p12	0,766	0,781	0,709	0,683	0,702	0,730	0,699	0,585	0,706	0,765	0,721	1,000			
corr	p13	0,692	0,691	0,617	0,620	0,629	0,692	0,591	0,512	0,614	0,665	0,769	0,671	1,000		
corr	p14	0,702	0,675	0,574	0,524	0,633	0,622	0,607	0,544	0,614	0,654	0,649	0,687	0,666	1,000	
corr	p15	0,743	0,738	0,661	0,566	0,680	0,741	0,712	0,628	0,647	0,695	0,638	0,711	0,653	0,707	1,000
corr	p16	0,690	0,682	0,669	0,577	0,673	0,695	0,669	0,594	0,690	0,683	0,658	0,714	0,693	0,634	0,692
corr	p17	0,577	0,576	0,605	0,606	0,564	0,589	0,593	0,499	0,590	0,617	0,729	0,651	0,756	0,593	0,594
corr	p18	0,763	0,773	0,668	0,562	0,635	0,686	0,684	0,521	0,615	0,691	0,710	0,780	0,683	0,680	0,690
corr	p19	0,748	0,736	0,657	0,592	0,630	0,689	0,689	0,500	0,624	0,701	0,705	0,759	0,717	0,680	0,665
corr	p20	0,730	0,709	0,644	0,617	0,625	0,698	0,690	0,558	0,686	0,751	0,716	0,766	0,732	0,699	0,716
corr	p21	0,654	0,647	0,548	0,517	0,526	0,601	0,628	0,445	0,558	0,634	0,660	0,659	0,667	0,636	0,664
corr	p22	0,755	0,748	0,651	0,605	0,632	0,706	0,696	0,515	0,601	0,698	0,731	0,748	0,711	0,721	0,712
corr	p23	0,771	0,757	0,645	0,617	0,680	0,744	0,687	0,554	0,656	0,740	0,784	0,767	0,796	0,721	0,709
corr	p24	0,667	0,685	0,636	0,575	0,576	0,639	0,643	0,510	0,567	0,649	0,731	0,693	0,723	0,665	0,692
corr	p25	0,723	0,710	0,646	0,573	0,644	0,708	0,681	0,519	0,621	0,678	0,691	0,719	0,729	0,714	0,672
corr	p26	0,670	0,664	0,654	0,616	0,611	0,680	0,655	0,530	0,602	0,654	0,666	0,647	0,710	0,655	0,597
corr	p27	0,450	0,438	0,401	0,402	0,412	0,434	0,449	0,268	0,411	0,514	0,369	0,464	0,411	0,343	0,405
corr	p28	0,654	0,625	0,591	0,521	0,671	0,679	0,648	0,667	0,690	0,714	0,507	0,573	0,557	0,576	0,635
corr	p29	0,619	0,593	0,583	0,501	0,628	0,626	0,593	0,617	0,625	0,655	0,429	0,488	0,488	0,559	0,559
corr	p30	0,681	0,668	0,637	0,526	0,688	0,684	0,651	0,621	0,642	0,699	0,559	0,659	0,595	0,664	0,699
stddev		1,203	1,130	1,174	0,954	1,048	1,038	1,609	1,137	1,130	1,241	0,729	0,996	0,621	1,183	1,128
mean		5,753	5,844	5,894	6,430	5,992	6,103	7,289	8,757	8,905	8,586	6,449	6,008	6,635	5,886	5,403

rowtype_	varname_	p16	p17	p18	p19	p20	p21	p22	p23	p24	p25	p26	p27	p28	p29	p30
n		263	263	263	263	263	263	263	263	263	263	263	263	263	263	263
corr	p1															
corr	p2															
corr	p3															
corr	p4															
corr	p5															
corr	p6															
corr	p7															
corr	p8															
corr	p9															
corr	p10															
corr	p11															
corr	p12															
corr	p13															
corr	p14															
corr	p15															
corr	p16	1,000														
corr	p17	0,750	1,000													
corr	p18	0,733	0,638	1,000												
corr	p19	0,736	0,652	0,846	1,000											
corr	p20	0,754	0,683	0,833	0,913	1,000										
corr	p21	0,693	0,633	0,776	0,782	0,809	1,000									
corr	p22	0,781	0,656	0,848	0,801	0,805	0,812	1,000								
corr	p23	0,755	0,703	0,848	0,819	0,802	0,752	0,889	1,000							
corr	p24	0,755	0,760	0,806	0,759	0,786	0,752	0,833	0,814	1,000						
corr	p25	0,727	0,625	0,777	0,766	0,773	0,694	0,790	0,796	0,750	1,000					
corr	p26	0,676	0,659	0,711	0,698	0,707	0,618	0,740	0,730	0,769	0,825	1,000				
corr	p27	0,440	0,364	0,453	0,493	0,515	0,464	0,466	0,487	0,440	0,546	0,535	1,000			
corr	p28	0,553	0,516	0,598	0,593	0,627	0,583	0,584	0,620	0,575	0,665	0,632	0,409	1,000		
corr	p29	0,535	0,436	0,502	0,510	0,532	0,484	0,518	0,524	0,526	0,551	0,574	0,386	0,789	1,000	
corr	p30	0,624	0,573	0,674	0,662	0,661	0,592	0,698	0,702	0,675	0,741	0,703	0,510	0,785	0,670	1,000
stddev		0,943	0,859	1,053	1,363	1,281	1,042	0,911	0,902	1,233	1,309	1,296	1,768	1,498	1,377	1,560
mean		6,106	6,529	5,833	5,437	5,483	5,844	6,118	6,247	6,000	5,783	6,163	4,563	5,008	5,316	5,300

**Figura 6: Matriz de correlação realizada pelo AMOS  
{Fonte: elaborada pela autora com o software AMOS}**

O método de estimação utilizado é o da máxima verossimilhança (MLE), padrão do *software* AMOS, que mostra bons resultados com amostras pequenas (BYRNE, 2001). A menos que o pesquisador tenha uma boa razão, esta forma de estimar deve ser usada como *default* mesmo que outros métodos sejam oferecidos pelos programas de

modelagem. MLE faz estimativas baseada na maximização da probabilidade (verossimilhança) onde as covariâncias observadas são obtidas de uma população assumida ser a mesma que a que reflete nos coeficientes estimados. MLE escolhe estimativas que têm a maior chance de reproduzir os dados observados (GARSON, 1998).

#### 4.5 Estágio 5: Avaliação da identificação do modelo estrutural

O interesse na especificação do modelo está diretamente centrado na transposição da matriz 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. A idéia é que o modelo seja super-identificado, onde o número de parâmetros a serem estimados é menor que o número de variâncias e covariâncias das variáveis observadas. Esta situação resulta em graus de liberdade positivos, que permitem o teste do modelo, conforme mostrado na saída do AMOS mostrado na Figura 7.

```

Sample size: 263

Model: Default model

Computation of degrees of freedom

      Number of distinct sample moments: 465
      Number of distinct parameters to be estimated: 70
      -----
      Degrees of freedom: 395

Chi-square = 1592,829
Degrees of freedom = 395
Probability level = 0,000

```

**Figura 7: Cálculo de graus de liberdade do modelo, saída do AMOS.**  
{Fonte: elaborada pela autora com o software AMOS}

O número de momentos amostrais distintos (número de variâncias e covariâncias das variáveis observadas) pode ser obtido pela equação (19):

$$\frac{p(p+1)}{2} \tag{19}$$

Onde:  $p$  é igual ao número de variáveis observadas do modelo.

Para o estudo obtém-se  $30(30+1)/2 = 465$  momentos amostrais distintos, que subtraindo dos 70 parâmetros livremente estimados resulta nos 395 graus de liberdade. O modelo hipotético é então super-identificado com 395 graus de liberdade, conforme mostrado na Figura 7.

Ainda com relação à identificação do modelo existe 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 o valor 1 é utilizado segundo Byrne (2001)) em uma das cargas fatoriais que são designadas para medir o mesmo fator. Pode-se observar o peso de regressão fixado em 1,0 na primeira variável indicadora de cada fator. Isso vale tanto para variáveis latentes dependentes como para variáveis independentes. A variável com parâmetro fixado é chamada de variável referência. A decisão de qual parâmetro se deve fixar é arbitrária. A medida que tiver maior confiança é recomendada, caso essa informação seja conhecida. O valor a ser especificado do parâmetro também é arbitrário. No modelo apresentado foi escolhida a primeira variável de cada fator, e isso não tem verificação, a estimativa dessa variável será 1 para a carga fatorial.

#### 4.6 Estágio 6: Avaliação de critérios de qualidade do ajuste

São vários os critérios de ajuste do modelo. O primeiro a ser apresentado 1592,829 é a estatística  $\chi^2$ , que aparece no final da Figura 7 e tem o objetivo de mostrar uma visão geral sobre o ajuste do modelo. A razão entre o valor  $\chi^2$  e os graus de liberdade deve ser menor do que 5. No caso, é 4,03, conforme mostra a Figura 8, na coluna **CMIN/DF**. O valor de probabilidade associado ao teste  $\chi^2$  geralmente (se observa na literatura) rejeita a hipótese de que o modelo esteja bem ajustado, pois o teste  $\chi^2$  tem se mostrado sensível a amostras grandes. Por isso a razão acima obtida é tomada em consideração ao invés do *p-value*.

Na Figura 8 são apresentados os índices de ajuste para o exemplo em estudo, e que foram abordadas no capítulo anterior. Pode-se notar que o AMOS fornece muitos critérios para avaliação do modelo. Não são todos reportados quando se está avaliando um modelo de equações estruturais. Outro ponto importante é o fato de que mesmo que

um modelo apresente bons índices de ajuste, ele pode não ser plausível. É preciso que ele seja sustentado teoricamente, e que o teste  $\chi^2$ , deve também ser levado em conta.

	<b>CMIN</b>	<b>DF</b>	<b>P</b>	<b>NPAR</b>	<b>CMINDF</b>	<b>RMR</b>	<b>GFI</b>
<b>Default Model</b>	1592,83	395,00	0,00	70,00	4,03	0,07	0,69
<b>Saturated</b>	0,00	0,00		465,00		0,00	1,00
<b>Independence</b>	10615,59	435,00	0,00	30,00	24,40	0,88	0,07

	<b>AGFI</b>	<b>PGFI</b>	<b>NFI</b>	<b>RFI</b>	<b>IFI</b>	<b>TLI</b>	<b>CFI</b>
<b>Default Model</b>	0,63	0,59	0,85	0,83	0,88	0,87	0,88
<b>Saturated</b>			1,00		1,00		1,00
<b>Independence</b>	0,01	0,07	0,00	0,00	0,00	0,00	0,00

	<b>PRATIO</b>	<b>PNFI</b>	<b>PCFI</b>	<b>NCP</b>	<b>NCPLO</b>	<b>NCPHI</b>
<b>Default Model</b>	0,91	0,77	0,80	1197,83	1078,67	1324,52
<b>Saturated</b>	0,00	0,00	0,00	0,00	0,00	0,00
<b>Independence</b>	1,00	0,00	0,00	10180,59	9848,33	10519,22

	<b>FMIN</b>	<b>F0</b>	<b>F0LO</b>	<b>F0HI</b>	<b>MECVI</b>
<b>Default Model</b>	6,08	4,57	4,12	5,05	6,69
<b>Saturated</b>	0,00	0,00	0,00	0,00	4,03
<b>Independence</b>	40,52	38,86	37,59	40,15	40,78

	<b>RMSEA</b>	<b>RMSEALO</b>	<b>RMSEAH</b>	<b>PCLOSE</b>	<b>HFIVE</b>	<b>HONE</b>
<b>Default Model</b>	0,11	0,12	0,13	0,00	73,00	77,00
<b>Saturated</b>						
<b>Independence</b>	0,30	0,24	0,30	0,00	12,00	13,00

	<b>AIC</b>	<b>BCC</b>	<b>BIC</b>	<b>CAIC</b>	<b>ECVI</b>	<b>ECVILO</b>	<b>ECVIHI</b>
<b>Default Model</b>	1732,83	1751,62	2220,94	2052,80	6,64	6,16	7,10
<b>Saturated</b>	930,00	1054,85	4172,61	3056,02	3,50	3,50	3,50
<b>Independence</b>	10675,50	10683,64	10884,70	10812,74	40,75	39,48	42,04

**Figura 8: Estatísticas de ajuste obtidas no AMOS**  
{Fonte: elaborada pela autora com o software AMOS}

Das estatísticas de ajuste da Figura 8, apenas algumas serão citadas (de acordo com os critérios estabelecidos pelo pesquisador) para a avaliação inicial deste modelo. Analisando o valor  $CFI = 0,88$ ,  $RMSEA = 0,11$ ,  $RMR = 0,07$ , já mostram um ajuste muito pobre do modelo aos dados amostrais, indicando que o modelo deve ser diferentemente especificado.

A Figura 8 apresenta parcialmente os índices de modificação que auxiliam a detectar mudanças na especificação do modelo que o melhorariam. Eles indicam a queda mínima do valor do  $\chi^2$  caso o parâmetro listado fosse incluído no modelo, ou seja, fosse livremente estimado. A coluna, chamada “*par change*” informa o valor da estimativa desse novo parâmetro incluso no modelo. A tabela com todos os índices de modificação encontram-se no apêndice B e foi orientada em forma decrescente de

índice de modificação (MI), já que o interesse concentra-se nos maiores índices, os quais diminuem o valor do  $\chi^2$ .

Na Figura 9, o valor marcado em negrito (84,43), significa que se for atribuída uma covariância entre os termos de erro das questões P20 e P19 reduziria em pelo menos 84,43 do valor o  $\chi^2$ , e a estimativa desse novo parâmetro incorporado ao modelo seria de aproximadamente 0,195. Os mais vantajosos seriam principalmente os 4 primeiros, do 84,43 até o 49,046 que são valores significativos, principalmente os dois primeiros (84,43, e 77, 219).

Modification Indices				
Covariances:			M.I.	Par Change
e20	<-->	e19	<b>84,43</b>	0,195
e28	<-->	e29	77,219	0,488
e9	<-->	e8	51,379	0,147
e7	<-->	VAL	49,046	-0,248
e7	<-->	SAT	34,272	0,167
e13	<-->	e17	32,867	0,072
e6	<-->	e5	30,385	0,072
e9	<-->	e7	28,814	-0,156

**Figura 9: Índices de modificação fornecidos pelo AMOS**  
{Fonte: elaborada pela autora com o software AMOS}

#### 4.7 Estágio 7: Interpretação e modificação do modelo

O modelo precisa de ajustes, como observado nos índices anteriores. Os IM indicam que o modelo pode ser melhor especificado. Ressalta-se que, as possíveis mudanças precisam ser plausíveis, enfim, que tenham sentido teórico.

Analisando o questionário, pode-se perceber que existem algumas questões redundantes. Um exemplo claro pode ser visto nos itens 1 e 2.

- a) Item 1: “Estamos muito contentes com o que o provedor de serviços faz por nós?”
- b) Item 2: “De forma geral, nós estamos muito satisfeitos com este provedor de serviços”.

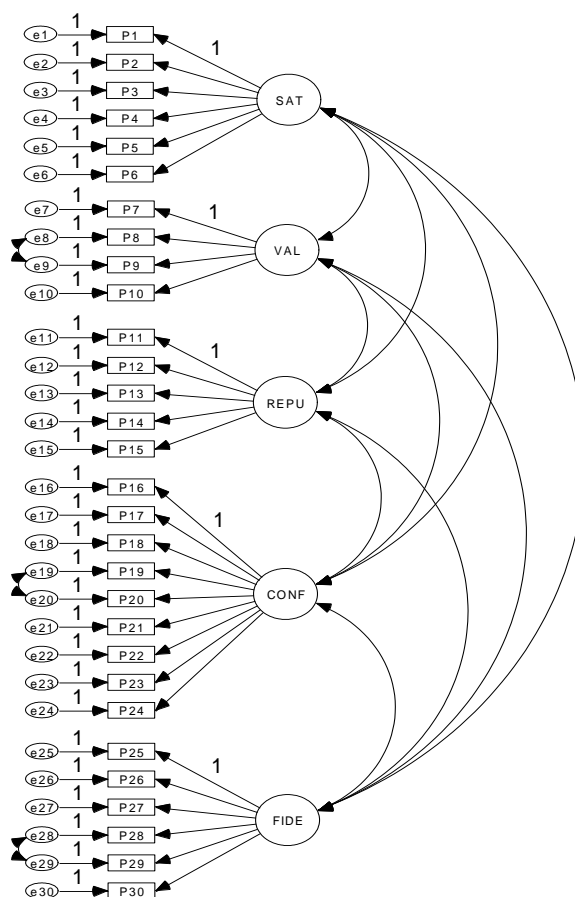
Provavelmente os escores dessas questões apontem, através dos índices de modificação, correlação entre elas. O questionário todo possui situações deste tipo, ou questões que podem medir dois fatores, como os fatores Reputação e Confiança. Então para situações deste tipo correlações ou covariâncias (significativas, como mostram os MI) são esperadas. Como se tem pouca sustentabilidade teórica para este instrumento de



medida pelo fato de ele não ter sido validado, as justificativas para mudanças no modelo, como inclusão de covariâncias entre os erros de medida, serão por além dos resultados práticos dessa análise apontarem tais mudanças, pela plausibilidade, mesmo que um tanto subjetiva. Em outras palavras, os MI indicam onde colocar essas correlações, caso faça sentido teórico, se tais questões tem “ligação”, se são parecidas.

Considerando a Figura 9, inicialmente três IM chamam a atenção por seu valor elevado. São eles as covariâncias entre os erros  $e_{20} \leftrightarrow e_{19}$ ;  $e_{28} \leftrightarrow e_{29}$ ;  $e_9 \leftrightarrow e_8$ . O modelo será então reespecificado com a inclusão desses parâmetros para serem livremente estimados. O novo modelo é apresentado na Figura 10.

Nesse momento se retorna ao estágio 5, sugerido por Hair *et al* (1998), e se percorrem os demais estágios até a interpretação final. Esse trabalho irá diretamente às alterações e a avaliação do modelo, pois a estrutura do modelo não foi modificada.



**Figura 10: Diagrama de caminhos do MODELO modificado realizado no software AMOS**  
 {Fonte: elaborada pela autora com o software AMOS}

Com a inclusão desses novos parâmetros, o valor  $\chi^2$  baixou para 1.348,86, com 392 graus de liberdade. Alguns índices de ajuste melhoraram, como CFI = 0,906; PGFI = 0,614, GFI = 0,718. Analisando todos os IM desse novo modelo, que encontram-se no apêndice B, observa-se na Figura 11, os que se destacam.

Covariances:		M.I.	Par Change	
e13	<-->	e17	32,349	0,070
e6	<-->	e5	31,014	0,073
e10	<-->	e9	27,643	0,075
e2	<-->	e1	27,190	0,036
e28	<-->	e30	27,080	0,228
e17	<-->	e16	25,866	0,092
e4	<-->	e1	22,506	-0,061
e24	<-->	e26	22,359	0,120
e17	<-->	e24	20,100	0,091

**Figura 11: Índices de modificação fornecidos pelo AMOS**  
{Fonte: elaborada pela autora com o software AMOS}

Com a inclusão desses novos parâmetros, a reespecificação no modelo apresentou melhoras nos índices de ajuste, conforme mostra a Figura 12. O modelo reespecificado encontra-se na Figura 13.

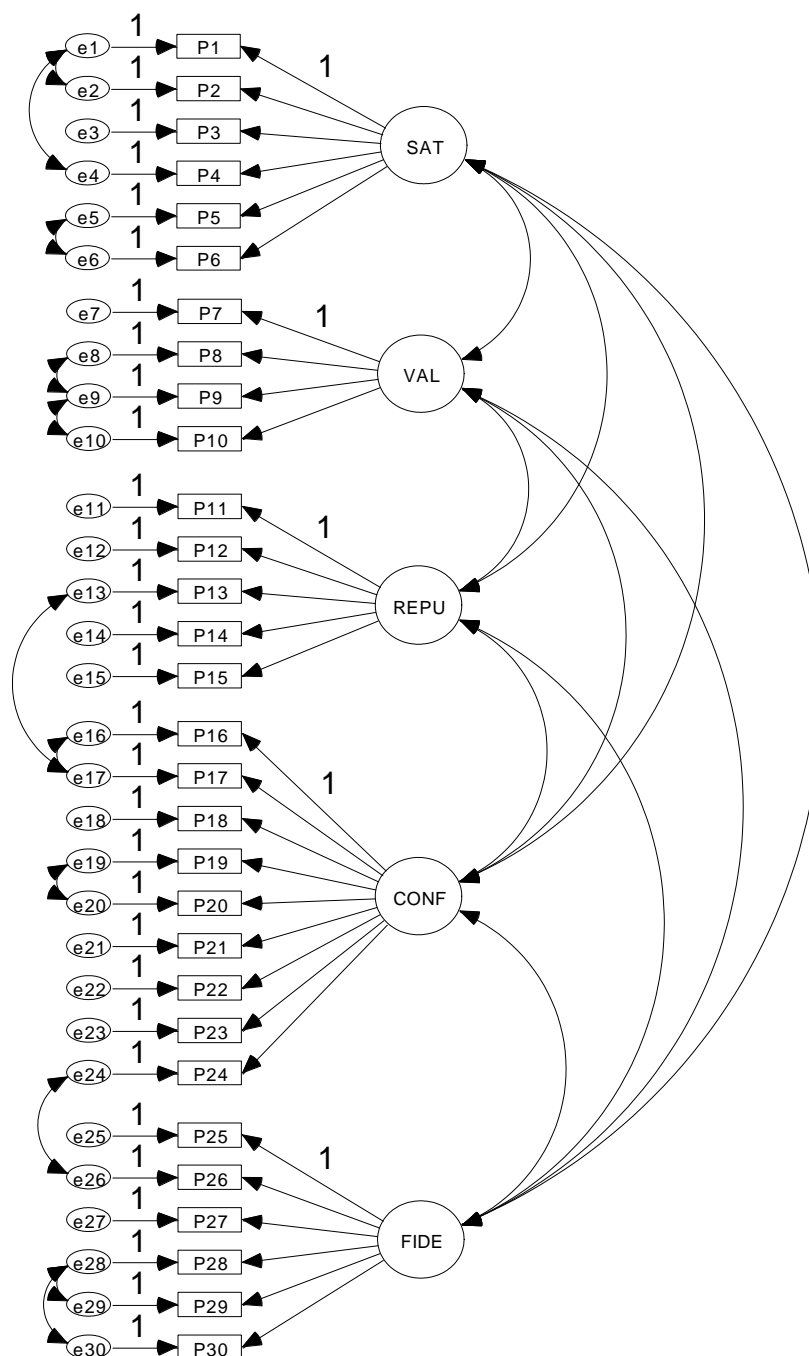
	DF	NPAR	CMINDF	RMR	GFI	PGFI	NFI	IFI
<b>Default Model</b>	383,00	82,00	2,80	0,04	0,78	0,65	0,90	0,93
<b>Saturated</b>	0,00	465,00			1,00		1,00	1,00
<b>Independence</b>	435,00	30,00	24,40		0,07	0,07	0,00	0,00

	CFI	PNFI	PCFI	RMSEA
<b>Default Model</b>	0,93	0,79	0,82	0,08
<b>Saturated</b>	1,00	0,00	0,00	
<b>Independence</b>	0,00	0,00	0,00	0,30

**Figura 12: Estatísticas de ajuste obtidas no AMOS**  
{Fonte: elaborada pela autora com o software AMOS}

O modelo reespecificado agora tem 383 graus de liberdade (gl), a razão  $\chi^2/\text{gl}$  baixou para 2,8045; CFI está 0,93, o RMSEA é 0,08, valor ainda não satisfatório para este índice (o RMSEA). De acordo com esses índices, se pode considerar o modelo razoavelmente adequado, pois apresentando valores bons para o CMINDF, e para o CFI, mas ruim nos demais. O modelo na verdade ainda não está satisfatório. Mas existem outros critérios de avaliação importantes, como a análise das estimativas dos parâmetros.



**Figura 13: Diagrama de caminhos AFC do MODELO REESPECIFICADO realizado no software AMOS**

{Fonte: elaborada pela autora com o software AMOS}

A análise das estimativas dos parâmetros, no software AMOS, funciona da seguinte maneira, 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 o parâmetro estimado seja igual a zero possa ser rejeitada. Parâmetros que não forem significantes, com exceção das variâncias, podem ser considerados não importantes ao

modelo (BYRNE, (2001) *apud* LEMKE, 2005) . Esse teste pode ser visto na coluna chamada C.R. (*Critical Ratio*) da Figura 14. Nesta figura é apresentada parte da saída do AMOS, os demais elementos desta saída encontram-se no apêndice C.

Regression Weights			Estimate	S.E.	C.R.	P
<b>P6</b>	←	<b>SAT</b>	<b>0,84</b>	<b>0,026</b>	<b>32,763</b>	<b>0,000</b>
P5	←	SAT	0,796	0,031	25,348	0,000
P4	←	SAT	0,654	0,037	17,649	0,000
P3	←	SAT	0,889	0,035	25,342	0,000
P2	←	SAT	0,92	0,019	48,496	0,000
P1	←	SAT	1			
P10	←	VAL	0,792	0,037	21,573	0,000
P9	←	VAL	0,673	0,035	19,102	0,000
P8	←	VAL	0,624	0,039	16,084	0,000
P7	←	VAL	1			
P15	←	REPU	1,553	0,097	16,048	0,000
P14	←	REPU	1,587	0,103	15,446	0,000
P13	←	REPU	0,851	0,053	16,139	0,000
P12	←	REPU	1,439	0,083	17,275	0,000
P11	←	REPU	1			
P21	←	CONF	1,123	0,064	17,429	0,000
P20	←	CONF	1,459	0,076	19,168	0,000
P19	←	CONF	1,54	0,082	18,89	0,000
P18	←	CONF	1,222	0,062	19,828	0,000
P17	←	CONF	0,811	0,047	17,319	0,000
P16	←	CONF	1			
P22	←	CONF	1,081	0,052	20,682	0,000
P23	←	CONF	1,067	0,052	20,578	0,000
P24	←	CONF	1,39	0,074	18,87	0,000
P28	←	FIDE	0,948	0,057	16,55	0,000
P27	←	FIDE	0,873	0,08	10,916	0,000
P26	←	FIDE	0,947	0,044	21,61	0,000
P25	←	FIDE	1			
P29	←	FIDE	0,771	0,059	13,087	0,000
P30	←	FIDE	1,083	0,056	19,261	0,000

**Figura 14 – Pesos da regressão calculados pelo AMOS**  
**{Fonte: elaborada pela autora com o software AMOS}**

Além do teste da razão crítica (CR), a tabela informa o tipo de parâmetro estimado, a estimativa desse parâmetro e seu erro padrão. Por exemplo, na linha grifada em vermelho: O parâmetro estimado é a carga fatorial entre o fator SAT e sua variável indicadora P6. A estimativa de tal parâmetro é 0,84, o erro padrão dessa estimativa é 0,026 e a razão Crítica (estimativa/erro padrão) é 32,763, altamente significativa como mostra o valor p.

Todas as estimativas foram estatisticamente significantes ( $|C.R.| > 1.96$ ), inclusive as covariâncias entre os termos de erro que foram incluídas ao modelo. Isso é um bom indício de que o modelo está bem especificado.

Como última análise se pode usar a matriz de covariâncias dos resíduos padronizados. Resíduos padronizados são os resíduos divididos pelos seus erros padrões assintóticos (é um erro padrão aproximado). Esses representam uma estimativa do número de desvios padrões que os resíduos observados estão do resíduo zero, que existiria caso o modelo fosse perfeitamente ajustado. Valores maiores que 2,58 são considerados grandes (BYRNE, 2001). Nenhum valor excedeu 2,58; conforme apresentado na Figura 15, outro ótimo indicativo de consistência entre os dados e o modelo hipotético.

O modelo final é o mesmo postulado inicialmente com a adição de alguns parâmetros (covariâncias entre as questões do questionário), cujas questões pretendem ser explicadas por cinco fatores: Satisfação com o provedor (SAT), o valor do provedor (VAL), a reputação do provedor (REPU), a confiança depositada no provedor (CONF) e a fidelidade (FIDE) do usuário para com o provedor de serviços.

É interessante apresentar algumas considerações sobre as covariâncias que foram acrescentadas, o que será feito de maneira subjetiva. A seguir seguem os itens do questionário que foram correlacionados.

P1 $\leftrightarrow$ P2

*Estamos muito contentes com o que o provedor de serviços faz por nós  $\leftrightarrow$  De forma geral, nós estamos muito satisfeitos com este provedor de serviços.*

P1 $\leftrightarrow$ P4

*Estamos muito contentes com o que o provedor de serviços faz por nós  $\leftrightarrow$  Nossa empresa lamenta a decisão de fazer negócios com este provedor de serviços.*

P5 $\leftrightarrow$ P6

*Se nós tivéssemos de escolher um fornecedor para este tipo de serviços, escolheríamos novamente este provedor de serviços  $\leftrightarrow$  Eu penso que nós fizemos a coisa certa quando decidimos por este provedor de serviços.*

## Standardized Residual Covariances

	P30	P29	P25	P26	P27	P28	P24	P23	P22	P16	P17	P18	P19	P20	P21	P11	P12
P30	0,00	1,61	-0,24	-0,31	0,28	0,66	0,09	0,01	-0,07	-0,05	0,20	-0,17	-0,10	-0,18	-0,63	-0,90	0,03
P29	1,61	0,00	-0,85	-0,16	-0,14	0,51	-0,18	-0,58	-0,68	0,42	-0,22	-0,73	-0,42	-0,17	-0,44	-1,08	-0,60
P25	-0,24	-0,85	0,00	0,32	0,09	-0,37	0,19	0,32	0,21	0,48	0,13	0,26	0,39	0,40	-0,11	0,05	-0,06
P26	-0,31	-0,16	0,32	-0,03	0,26	-0,40	-0,03	-0,10	0,01	0,20	0,99	-0,16	-0,08	-0,05	-0,72	0,11	-0,60
P27	0,28	-0,14	0,09	0,26	0,00	-0,57	-0,52	-0,17	-0,49	-0,10	-0,52	-0,53	0,25	0,51	0,15	-1,11	-0,06
P28	0,66	0,51	-0,37	-0,40	-0,57	0,41	-0,48	-0,25	-0,78	-0,27	0,09	-0,39	-0,24	0,17	0,01	-0,88	-0,37
P24	0,09	-0,18	0,19	-0,03	-0,52	-0,48	0,00	-0,12	0,09	0,23	0,39	-0,02	-0,35	-0,08	0,02	0,42	-0,55
P23	0,01	-0,58	0,32	-0,10	-0,17	-0,25	-0,12	0,00	0,29	-0,25	0,19	0,01	-0,07	-0,37	-0,44	0,65	-0,06
P22	-0,07	-0,68	0,21	0,01	-0,49	-0,78	0,09	0,29	0,00	0,06	-0,46	-0,01	-0,33	-0,35	0,29	-0,06	-0,33
P16	-0,05	0,42	0,48	0,20	-0,10	-0,27	0,23	-0,25	0,06	0,00	0,22	-0,34	-0,04	0,11	-0,16	0,01	0,30
P17	0,20	-0,22	0,13	0,99	-0,52	0,09	0,39	0,19	-0,46	0,22	0,23	-0,51	-0,07	0,27	0,08	2,03	0,49
P18	-0,17	-0,73	0,26	-0,16	-0,53	-0,39	-0,02	0,01	-0,01	-0,34	-0,51	0,00	0,47	0,22	0,06	-0,12	0,30
P19	-0,10	-0,42	0,39	-0,08	0,25	-0,24	-0,35	-0,07	-0,33	-0,04	-0,07	0,47	0,00	0,00	0,40	0,06	0,30
P20	-0,18	-0,17	0,40	-0,05	0,51	0,17	-0,08	-0,37	-0,35	0,11	0,27	0,22	0,00	0,00	0,67	0,13	0,30
P21	-0,63	-0,44	-0,11	-0,72	0,15	0,01	0,02	-0,44	0,29	-0,16	0,08	0,06	0,40	0,67	0,00	-0,10	-0,58
P11	-0,90	-1,08	0,05	0,11	-1,11	-0,88	0,42	0,65	-0,06	0,01	2,03	-0,12	0,06	0,13	-0,10	0,00	0,22
P12	0,03	-0,60	-0,06	-0,60	-0,06	-0,37	-0,55	-0,06	-0,33	0,30	0,49	0,30	0,30	0,30	-0,58	0,22	0,00
P13	-0,41	-0,22	0,57	0,73	-0,50	-0,17	0,33	0,83	-0,31	0,49	0,51	-0,47	0,24	0,35	-0,01	1,35	-0,43
P14	0,74	0,96	0,56	0,16	-1,36	0,27	-0,25	0,05	0,03	-0,12	0,29	-0,30	-0,07	0,12	-0,24	-0,08	-0,01
P15	0,99	0,78	-0,23	-0,84	-0,61	0,91	-0,13	-0,35	-0,34	0,44	0,11	-0,41	-0,50	0,10	-0,08	-0,44	0,06
P7	0,26	1,19	-0,21	-0,15	-0,02	1,02	-0,16	0,01	0,09	0,74	0,65	0,14	0,45	0,39	0,03	-0,33	0,26
P8	0,87	2,46	-1,33	-0,81	-1,95	2,31	-0,96	-0,72	-1,30	0,72	0,23	-1,03	-1,11	-0,36	-1,53	-1,11	-0,21
P9	0,50	2,00	-0,63	-0,50	-0,31	1,99	-0,84	-0,03	-0,81	1,41	0,95	-0,42	-0,06	0,72	-0,59	-0,60	0,74
P10	0,67	1,88	-0,49	-0,39	0,76	1,72	-0,32	0,46	-0,12	0,70	0,78	-0,01	0,37	0,96	-0,11	-0,42	0,89
P1	0,12	1,10	-0,22	-0,49	-0,41	0,58	-0,55	0,36	0,12	0,32	-0,22	0,44	0,51	0,19	-0,31	-0,38	0,26
P2	0,14	0,90	-0,18	-0,38	-0,44	0,36	-0,12	0,38	0,24	0,40	-0,06	0,78	0,54	0,11	-0,22	-0,46	0,66
P3	0,34	1,30	-0,37	0,13	-0,52	0,47	-0,14	-0,43	-0,38	0,86	0,92	0,05	0,13	-0,11	-0,95	-0,74	0,39
P4	-0,39	0,80	-0,50	0,46	0,11	0,24	-0,14	0,06	-0,14	0,39	1,72	-0,54	0,09	0,37	-0,59	0,14	0,94
P5	1,03	1,95	-0,41	-0,47	-0,35	1,61	-0,96	0,03	-0,64	0,89	0,32	-0,41	-0,24	-0,38	-1,26	-0,72	0,28
P6	0,40	1,42	-0,16	-0,11	-0,45	1,18	-0,69	0,26	-0,26	0,63	0,17	-0,31	-0,03	0,01	-0,79	-0,40	0,05

	P13	P14	P15	P7	P8	P9	P10	P1	P2	P3	P4	P5	P6
P30	-0,41	0,74	0,99	0,26	0,87	0,50	0,67	0,12	0,14	0,34	-0,39	1,03	0,40
P29	-0,22	0,96	0,78	1,19	2,46	2,00	1,88	1,10	0,90	1,30	0,80	1,95	1,42
P25	0,57	0,56	-0,23	-0,21	-1,33	-0,63	-0,49	-0,22	-0,18	-0,37	-0,50	-0,41	-0,16
P26	0,73	0,16	-0,84	-0,15	-0,81	-0,50	-0,39	-0,49	-0,38	0,13	0,46	-0,47	-0,11
P27	-0,50	-1,36	-0,61	-0,02	-1,95	-0,31	0,76	-0,41	-0,44	-0,52	0,11	-0,35	-0,45
P28	-0,17	0,27	0,91	1,02	2,31	1,99	1,72	0,58	0,36	0,47	0,24	1,61	1,18
P24	0,33	-0,25	-0,13	-0,16	-0,96	-0,84	-0,32	-0,55	-0,12	-0,14	-0,14	-0,96	-0,69
P23	0,83	0,05	-0,35	0,01	-0,72	-0,03	0,46	0,36	0,38	-0,43	0,06	0,03	0,26
P22	-0,31	0,03	-0,34	0,09	-1,30	-0,81	-0,12	0,12	0,24	-0,38	-0,14	-0,64	-0,26
P16	0,49	-0,12	0,44	0,74	0,72	1,41	0,70	0,32	0,40	0,86	0,39	0,89	0,63
P17	0,51	0,29	0,11	0,65	0,23	0,95	0,78	-0,22	-0,06	0,92	1,72	0,32	0,17
P18	-0,47	-0,30	-0,41	0,14	-1,03	-0,42	-0,01	0,44	0,78	0,05	-0,54	-0,41	-0,31
P19	0,24	-0,07	-0,50	0,45	-1,11	-0,06	0,37	0,51	0,54	0,13	0,09	-0,24	-0,03
P20	0,35	0,12	0,10	0,39	-0,36	0,72	0,96	0,19	0,11	-0,11	0,37	-0,38	0,01
P21	-0,01	-0,24	-0,08	0,03	-1,53	-0,59	-0,11	-0,31	-0,22	-0,95	-0,59	-1,26	-0,79
P11	1,35	-0,08	-0,44	-0,33	-1,11	-0,60	-0,42	-0,38	-0,46	-0,74	0,14	-0,72	-0,40
P12	-0,43	-0,01	0,06	0,26	-0,21	0,74	0,89	0,26	0,66	0,39	0,94	0,28	0,05
P13	0,16	0,16	-0,25	-0,74	-0,82	-0,07	0,03	-0,22	-0,03	-0,39	0,51	-0,24	0,04
P14	0,16	0,00	0,68	-0,34	-0,19	0,12	0,07	0,12	-0,05	-0,79	-0,67	0,01	-0,71
P15	-0,25	0,68	0,00	0,87	0,78	0,36	0,40	0,43	0,55	0,18	-0,29	0,43	0,64
P7	-0,74	-0,34	0,87	0,00	-0,38	-0,54	-0,19	0,31	0,04	0,45	-0,11	-0,04	0,02
P8	-0,82	-0,19	0,78	-0,38	0,00	0,35	0,73	-0,26	-0,27	0,13	-0,58	0,64	0,40
P9	-0,07	0,12	0,36	-0,54	0,35	0,27	0,28	-0,11	-0,21	-0,10	-0,05	0,59	0,18
P10	0,03	0,07	0,40	-0,19	0,73	0,28	0,00	-0,09	-0,16	-0,48	-0,25	0,23	-0,02
P1	-0,22	0,12	0,43	0,31	-0,26	-0,11	-0,09	-0,01	-0,01	-0,04	0,04	0,08	-0,05
P2	-0,03	-0,05	0,55	0,04	-0,27	-0,21	-0,16	-0,01	0,00	0,15	0,09	-0,14	-0,05
P3	-0,39	-0,79	0,18	0,45	0,13	-0,10	-0,48	-0,04	0,15	0,00	0,20	-0,15	0,09
P4	0,51	-0,67	-0,29	-0,11	-0,58	-0,05	-0,25	0,04	0,09	0,20	0,00	-0,31	0,06
P5	-0,24	0,01	0,43	-0,04	0,64	0,59	0,23	0,08	-0,14	-0,15	-0,31	0,00	0,00
P6	0,04	-0,71	0,64	0,02	0,40	0,18	-0,02	-0,05	-0,05	0,09	0,06	0,00	0,00

**Figura 15: Matriz de covariância residual calculada pelo AMOS  
{Fonte: elaborada pela autora com o software AMOS}**

P8 $\leftrightarrow$ P9

*O tempo necessário para efetivar transações com este provedor de serviços é...  $\leftrightarrow$   
Pelo esforço envolvido ao efetivar seus pedidos, você diria que comprar deste provedor de serviços...*

P9 $\leftrightarrow$ P10

*Pelo esforço envolvido ao efetivar seus pedidos, você diria que comprar deste provedor de serviços...  $\leftrightarrow$  Como você avaliaria sua experiência de compra, ao longo do tempo, junto a este provedor de serviços?*

P3 $\leftrightarrow$ P17

*Em relação à sua reputação, este provedor de serviços tem uma má reputação no mercado  $\leftrightarrow$  Em relação à confiança depositada no provedor de serviços este provedor de serviços nem sempre é honesto conosco.*

P16 $\leftrightarrow$ P17

*Este provedor de serviços cumpre as promessas feitas a nossa empresa.  $\leftrightarrow$  Em relação à confiança depositada no provedor de serviços este provedor de serviços nem sempre é honesto conosco.*

P17 $\leftrightarrow$ P24

*Em relação à confiança depositada no provedor de serviços este provedor de serviços nem sempre é honesto conosco  $\leftrightarrow$  Em relação à confiança depositada no provedor de serviços é necessário tomar certas precauções com este provedor de serviços.*

P19 $\leftrightarrow$ P20

*Este provedor de serviços está verdadeiramente preocupado com que o nosso negócio seja bem-sucedido  $\leftrightarrow$  Quando decisões importantes são tomadas, este provedor de serviços considera o nosso bem-estar como o seu próprio bem-estar.*

P24 $\leftrightarrow$ P26

*Em relação à confiança depositada no provedor de serviços é necessário tomar certas precauções com este provedor de serviços  $\leftrightarrow$  É provável que eu faça comentários negativos a respeito deste provedor de serviços a amigos e empresários.*

P28 $\leftrightarrow$ P29

*Mesmo que este provedor de serviços aumentasse os preços dos serviços que utilizamos, eu ainda continuaria a ser seu cliente  $\leftrightarrow$  Se um provedor de serviços concorrente oferecesse um preço melhor ou um desconto nos serviços, eu trocaria.*

P28 $\leftrightarrow$ P30


*Mesmo que este provedor de serviços aumentasse os preços dos serviços que utilizamos, eu ainda continuaria a ser seu cliente  $\leftrightarrow$  Por quanto mais tempo permanecemos com este provedor de serviços, menor a probabilidade de trocarmos para um provedor de serviços concorrente.*

Pode se observar que os itens correlacionados fazem sentido, com relação à plausibilidade. Destaca-se a relação P1 $\leftrightarrow$ P4, onde o *software* detectou a correlação negativa de -0,29 entre essas variáveis.

A Figura 16 apresenta o modelo final, com as estimativas dos parâmetros na forma padronizada. Esse foi o melhor modelo encontrado para esse instrumento, que é o modelo postulado inicialmente com a adição alguns parâmetros indicados durante a análise.

Vale ressaltar no modelo final que a estimativa da correlação entre os construtos SAT e VAL é muito forte (0,96), assim como os construtos REPU e CONF, indicando uma associação positiva entre os construtos. Isso indica que os escores obtidos pelo questionário que apresentaram valores altos no fator VAL, tem a tendência de terem apresentado valores altos no construto SAT. Em suma, entrevistados que marcaram escores altos num fator marcaram em média valores altos no outro escore. Isso vale também para os escores baixos. Note que a correlação só demonstra essa associação, nenhuma definição de causa explícita foi determinada.





**Figura 16: Diagrama de caminhos para o modelo final**  
 {Fonte: elaborada pela autora com o software AMOS}

Já na questão construto / questão, SAT → P1, por exemplo, o valor da saída 0,96 é a carga fatorial que expressa o coeficiente de correlação entre a variável P1 e seu

respectivo fator (SAT). Em cada fator, as variáveis mais representativas são aquelas cujas cargas fatoriais são maiores.

A opinião do cliente com o provedor é um modelo composto por vários fatores, formado pelos fatores satisfação com o provedor, valor do provedor, reputação do provedor, confiança depositada no provedor e fidelidade do usuário para com o provedor de serviços, que são fortemente correlacionados como mostram as análises.

Uma amostra maior com perguntas mais diferenciadas (muitas perguntas semelhantes que geraram vários itens correlacionados), traria uma identificação mais precisa desses fatores. Logo, seria interessante rodar novamente a análise com um incremento amostral e/ou talvez uma modificação em algumas questões do questionário aplicado.

## 5 CONCLUSÃO

### 5.1 Considerações Finais

A Modelagem de Equações Estruturais é formada por um conjunto de técnicas estatísticas multivariadas, abrangendo várias metodologias simultaneamente, como regressão, análise de covariância, *path analysis*, análise fatorial confirmatória, entre outras.

Este conjunto de técnicas e sua forma de aplicação ainda estão sendo explorados, e ainda são alvos de muita pesquisa por parte de várias áreas da ciência, especialmente em Marketing e Medicina, por tratar-se uma técnica estatística relativamente recente e cuja potencialidade no uso estatístico ainda não foi plenamente alcançada. Como exemplo desta potencialidade não atingida, pode-se citar seu pouco uso na área da Engenharia de Produção, onde se aplicam técnicas multivariadas que tem sua análise prejudicada por não assumir alguns pressupostos estatísticos, muitas vezes não sendo possível realizar a análise. Como explicitado anteriormente o uso de SEM pode trazer resultados benéficos a várias sub-áreas da Engenharia. A SEM pode ser usada mais largamente na indústria em áreas de Ergonomia e Segurança do Trabalho, Engenharia de produto, marketing estratégico industrial.

Para a análise de Equações Estruturais é necessário um bom conhecimento das técnicas e testes estatísticos utilizados em SEM (tais como: análise fatorial confirmatória, teste qui-quadrado, etc), e que o pesquisador tenha um bom conhecimento a respeito das inter-relações das variáveis do modelo, a fim de estruturar e compor corretamente o digrama de caminhos. Aqui a abordagem teve ênfase na análise fatorial confirmatória.

Nesse trabalho foi realizada a Modelagem de Equações Estruturais para medir a opinião de clientes com relação a um provedor de serviços. O modelo final resultante deste trabalho é o mesmo postulado inicialmente com a adição de alguns parâmetros, cujas questões pretendem ser explicadas por cinco fatores: Satisfação com o provedor (SAT), o valor do provedor (VAL), a reputação do provedor (REPU), a confiança depositada no provedor (CONF) e a fidelidade (FIDE) do usuário para com o provedor de serviços. Se confirma que a satisfação geral é um modelo multidimensional formado por esses fatores.

Muitas vezes mesmo que se encontre um modelo com bons índices e bons resultados numéricos não é garantido que este seja o modelo correto ou o melhor modelo disponível, pois existem várias maneiras de se conduzir a Modelagem de Equações Estruturais. Esse julgamento cabe ao pesquisador que deve se basear na fundamentação teórica para essa avaliação.

Para a obtenção de um modelo em SEM é necessário a realização de vários passos, desde a elaboração do modelo de caminhos até a análise de matrizes e testes estatísticos, sendo assim se faz necessária a utilização de um software específico, pois sem ele o tempo utilizado com esses cálculos e interações seria demasiadamente grande. Os passos sugeridos nesse trabalho são os elaborados por Hair *et al.* (1998), não fazendo alterações, mas tornando sua aplicação mais fácil, uma vez que se busca o bom entendimento do que foi sugerido pelo autor e os conceitos sugeridos por demais autores que abordam os passos para utilização de SEM.

Nesse trabalho foi abordado o software AMOS, distribuído pela SPSS, é um pacote de fácil utilização, mas que requer um grande embasamento teórico para o desenvolvimento do modelo.

Comparativamente o software AMOS distingue-se justamente pela interface gráfica mais amigável ao usuário que possui, incluindo ferramentas de desenho do modelo, e suporta estimativas de *bootstrapped*. O pacote LISREL tem um conjunto mais compreensivo de opções, incluindo restrições não lineares em estimativas de parâmetro, o módulo PRELIS2 (incluso no LISREL) pode ser usado para gerar uma matriz de covariância usando variáveis dicotômicas ou ordinais, ou amostras de *bootstrapped*. O EQS por sua vez, é notável para lidar com grande número de dados, opções flexíveis para testes associados com modelos de reespecificação, e procedimentos de estimação para dados não normais. Também existem outras diferenças nos resultados obtidos (*output*). Por exemplo, à parte de diferenças em amigabilidade do usuário e características de resultado, o AMOS (SPSS) aplica a correção de Bartlett para qui-quadrado enquanto que LISREL não o faz, respondendo por diferenças no resultado estatístico para os mesmos dados (a partir de 1997). Os três pacotes LISREL, AMOS, e EQS são os três pacotes estatísticos mais populares para análise de SEM, e têm em comum o fato de utilizarem modelos de regressão linear nas análises efetuadas para verificar as relações hipotetizadas entre variáveis.

Os objetivos desse trabalho foram cumpridos uma vez que se desejava mostrar um guia para a utilização da Modelagem de Equações Estruturais, uma vez que a maioria da bibliografia não se encontra na língua pátria. Foi realizada uma vasta revisão

sobre o tema, uma abordagem dos aplicativos de SEM e a aplicação prática da Modelagem de Equações Estruturais. A utilização de SEM passo a passo com a breve descrição do aplicativo AMOS traz ao leitor um rumo a ser tomado na aplicação dessa modelagem.

## 5.2 Trabalhos futuros

Considerando o fato da metodologia ser relativamente incipiente, pode-se considerar que ainda há um bom caminho a percorrer no intuito de tornar este processo mais prático, preciso e seguro em seus resultados, a fim de que o pesquisador possa utilizar esta ferramenta com desenvoltura, além disso, tendo mais confiabilidade e precisão em seus resultados.

Como uma sugestão de trabalhos futuros, existe a possibilidade de investigar as particularidades dos outros softwares, disponíveis no mercado, de Modelagem de Equações Estruturais, como EQS, LISREL, entre outros; podendo assim tecer um estudo comparativo das vantagens e desvantagens de cada um dos softwares de Modelagem de Equações Estruturais, determinando assim qual deles melhor se adapta a cada modelo estudado em particular.

Outra sugestão seria a de estruturar uma metodologia mais enxuta para a realização da modelagem, com passos mais precisos e maiores dicas de resolução de problemas de modelagem. Atualmente a literatura existente está embasada nos passos utilizados por Hair *et al*, é muito difícil encontrar disponível em artigos ou livros algo mais direto para a Modelagem de Equações Estruturais, devido certamente, ao fato desta metodologia ser relativamente recente.

Mais um problema encontrado na literatura, devido a ambigüidade de vários autores, seria o tamanho ideal de amostra para a utilização da Modelagem de Equações Estruturais, não existe um consenso entre os autores estudados, isso poderia ser resolvido realizando um estudo comparativo para investigar o tamanho de amostra para a modelagem, estudando a relação entre o número de variáveis e o tamanho da amostra.

Por fim, ainda existem muitos detalhes a serem abordados em Modelagem de Equações Estruturais, ainda pouco se explora sobre o assunto, apesar desta ser uma ferramenta muito útil em muitos ramos de pesquisa. Nesse trabalho foram encontradas algumas limitações por falta de material sobre o assunto e aplicações na área da

engenharia, ficando como sugestão de mais um trabalho futuro uma vasta investigação de aplicações dentro da engenharia, manufatura, confiabilidade e qualidade.

## Referências

- ARBUCKLE, J. L. **AMOS users' guide** : version 3.6. Chicago, IL : SPSS, 1997.
- Research**, v. XIX, p. 491-504, Nov. 1982.
- BENTLER, P. M., & WU, E. J. C. **EQS for Windows: User's Guide**. Encino, CA: Multivariate Software, Inc., 1995.
- BYRNE, B. M., **Structural equation modeling with AMOS**. Mahwah: Lawrence Erlbaum, 2001.
- CZIRAKY, D., LISREL 8.54: **A Program for Structural Equation Modeling With Latent Variables**. Journal of Applied Econometrics. v. 19, n. 1, p. 135, Jan/Fev 2004.
- EISENHARDT, K. M., **Building Theories From Case Study Research**. Academy Management Review, v.14, n.4, p. 532-550, 1989.
- FARIAS, S. A. e SANTOS, R. C., **Modelagem de Equações Estruturais e Satisfação do Consumidor**: uma investigação Teórica e Prática. RAC, v. 4, n. 3, p. 107-132, set/dez. 2000.
- GARSON, D., **Structural Equation modeling**. (1998) Disponível em: <http://www2.chass.ncsu.edu/garson/pa765/structur.htm>, acesso em 13/01/2006.
- GIL, A. C., **Como elaborar projetos de pesquisa**. 3. ed., Atlas. São Paulo, 1991.
- GOLDBERGER, A. S. e DUNCAN, O. D., **Structural Equation Models in the Social Sciences**. New York, Seminar Press, 1973.
- GOLDENBERG, Mirian. **A arte de pesquisar**. Rio de Janeiro: Re-cord, 1999.
- GOLOB, T. F., **Structural Equation Modeling for Travel Behavior Reserch**. Transportation Reserch Part B v. 37, p. 1- 25, 2003.
- GONÇALVES, C. A.; FILHO, C. G.; VEIGA, R. T.; RABELO, J.;LARA, J. E.;RIBEIRO, A. H. P.;MOURA, A. C. e SILVA, C.G., **Relatório final de pesquisa: Produtos de Sucesso – Estratégias de Marketing no Processo de Gestão do Portfólio de Novos Produtos: Um Estudo Comparativo entre Grandes Organizações em Ambientes Globalizados**. Universidade Federal de Minas Gerais, Faculdade de Ciências Econômicas. Relatório final de pesquisa. Belo Horizonte, fev. 2001. Disponível em: [http://www.cepead.face.ufmg.br/nucleos/nume/downloads/rel\\_produtos.pdf](http://www.cepead.face.ufmg.br/nucleos/nume/downloads/rel_produtos.pdf), acesso em 10/01/2006.
- HAIR, J.F., ANDERSON, R.E., TATHAM, R.L. & BLACK, W.C. **Multivariate data analysis**, 5. Ed. , Prentice Hall, Upper Sanddle River, New Jersey, 1998. Chapter 11 – Structural Equation Modeling.
- HOYLE, R. H. e PANTER, **Writing about structural equation models**. In.: HOYLE, R. H. Structural equation modeling. London: Sage Publications, 1995.
- IRIONDO, J. M.; ALBERT, M. J.; ESCUDERO A., **Structural equation modelling: an alternative for assessing causal relationships in threatened plant populations**. Biological Conservation. v.113, p.367 – 377, 2003.

JAKSON, J. L., DEEZE, K., DOUGLAS, K., SHIMEALL, W.; **Introduction to Structural Equation Modeling** (Path Analysis). SGIM Precourse PA08 May 2005.

KELLOWAY, E. K. **Using LISREL for structural equation modeling: a researcher guide**. USA: Sage Publications, Inc. 1998.

KEYTON, J.; ANDERSON, K.; MANNING, J.; OZLEY, R. R.; SOLIZ, J., Communication at the Crossroads: Investigation of Structural Equation Modeling, The University of Kansas, disponível em: <http://www.people.ku.edu/~jkeyton/CSCASEMout.pdf>, acesso em 10/05/2006.

KLIN, R. B. **Principles and practice of structural equation modeling**. New York: The Guilford Press. 1998.

KOUFTEROS, X. A., **Testing a Model of Pull Production: A Diagram for Manufacturing research using Structural Equation Modeling**. Journal of Operations Management v.17, p. 467 – 488, 1999.

LEMKE, C., **Modelos de Equações Estruturais com Ênfase em Análise Fatorial Confirmatória no Software AMOS**, Universidade Federal do Rio Grande do Sul, Instituto de Matemática, Departamento de Estatística. Porto Alegre, 2005. Monografia.

MATOS, C. A.; GOSLING, M.; DINIZ, L. C. O.; RAMALHO, W.; **Como os Consumidores Reagem ao Recall de Produtos? Uma Abordagem com Equações Estruturais Considerando também Indicadores Formativos**, EnANPAD 2004 > Presented Papers > MKT | Marketing. Disponível em: <http://www.anpad.org.br/enanpad2004-trabs-apres-mkt-i.html>, acesso em 23/04/2006.

MEDEIROS, C. A. F., **Comprometimento Organizacional: Um Estudo de suas Relações com Características Organizacionais e Desempenho nas Empresas Hoteleiras**, Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade, Departamento de Administração, Programa de Pós-Graduação em Administração, São Paulo, 2003. Tese.

MILAN, G. S., **A Prática do Marketing de Relacionamento e a Retenção de Clientes: Um Estudo Aplicado em um Ambiente de Serviços**, Universidade Federal do Rio Grande do Sul, Escola de Engenharia, Programa de Pós-Graduação em Engenharia de Produção, Porto Alegre, 2006. Tese.

MÜCKENBERGER, E., **O Papel da Satisfação, Confiança e Comprometimento na Formação de Intenção de Compra Futura Entre Clientes com Níveis de Experiência Diferenciados**, Universidade Federal do Rio Grande do Sul, Escola de Administração – Programa de Pós-Graduação em Administração. Porto Alegre, 2000. Dissertação.

NUNNALLY, J. C., BERNSTEIN, I. H.; **Psychometric Theory**. New York, 3. ed., 1994.

PALMER, A., Introducing LISREL. **European Journal of Marketing**. Bradford. v. 37, n. 5/6; p. 937, 2003.



REISENGER, I. & TURNER, L. **Structrual Equation Modeling with Lisrel: Application in Tourism**. Tourism Management v. 20, p. 71 – 80, 1999.

SANTOS, R. B., **Modelos de Equações Estruturais**, Universidade Federal do Rio Grande do Sul, Instituto de Matemática, Departamento de Estatística. Porto Alegre, 2002. Monografia.

STOELTING, R. **Structural Equation Modeling/Path Analysis**. (2002) Disponível em: <http://online.sfsu.edu/~efc/classes/biol710/path/SEMwebpage.htm>, acesso em: 25/03/2004.

STREINER, D. L., **Finding Our Way: An Introduction to Path Analysis**. Canadian Journal of Psychiatry. v. 50, n. 2, p. 115, feb. 2005.

STEVENS, J.; **Applied Multivariate Statistics for the Social Sciences**, 1996.

YIN, R. K. **Estudo de Caso: Planejamento e Métodos**. 2. ed., Ed. Bookman. Porto Alegre, 2001.

## ANEXO A: Demais índices utilizados em SEM

**RFI:** (*Relative Fit Index*); também variação de zero a 1, com valores perto de 0,95 indicando um bom ajuste (LEMKE, 2005).

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

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*); é uma derivação do NFI, com a computação basicamente a mesma, com a diferença do número de graus de liberdade utilizados (LEMKE, 2005). Também conhecido como RHO1, não é garantido variar de 0 a 1. RFI perto de 1 indica um ajuste bom (GARSON, 1998).

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

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*); também com valores entre zero e um, e valores próximos a 0,95 (para amostras grandes) indicando bom ajuste (LEMKE, 2005). É o índice de ajuste menos afetado pelo tamanho da amostra (GARSON, 1998).

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

**PNFI:** (*Parsimony Normed Fit Index*); índice computado de forma relativa ao índice NFI (LEMKE, 2005). É igual ao PRATIO vezes NFI (GARSON, 1998).

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

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

**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.

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

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

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

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

**PCLOSE:** em adição ao I.C. de RMSEA, o índice PCLOSE testa a proximidade do ajuste, ou seja, ele testa a  $H_0: RMSEA \leq 0,05$ , deve ser maior que 0,05 para aceitar esta hipótese. Ideal que seja  $> 0,50$  (LEMKE, 2005).

$$PCLOSE = 1 - \phi(\hat{C}_{0,05}^2 nd.d)$$

O *p-value* de P (anteriormente descrito) testa  $H_0: RMSEA=0$ . Se  $RMSEA \leq 0,05$  indica ótimo ajuste.

**CAIC:** (*Consistent AIC*); 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 (LEMKE, 2005).

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

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

**BCC:** (*Browne-Cudeck Criterion*); funciona da mesma maneira que o AIC e CAIC com diferença que impõem grandes penalidades para a complexidade do modelo (LEMKE, 2005). Penaliza para tamanho de amostra como também complexidade modelo (GARSON, 1998).

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

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

**BIC:** (*Bayes Information Criterion*); opera como BCC, AIC e CAIC, também conhecido como o critério de informação Bayesiano de Akaike (ABIC) e o critério

baysiano de Schwarz (SBC). Como CAIC, BIC penaliza para tamanho de amostra como também complexidade modelo. BIC é uma aproximação de um fator de Bayes para o modelo de interesse comparado ao modelo saturado (GARSON, 1998).

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

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

**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 (LEMKE, 2005). Em sua variante habitual é equivalente a BCC, e é útil para comparar modelos não aninhados como AIC. Quanto mais baixo o ECVI melhor o ajuste (GARSON, 1998).

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

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:

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

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

## ANEXO B – Questionário

### QUESTIONÁRIO

Prezado(a) Senhor(a):

A partir de sua experiência no que diz respeito ao relacionamento existente entre a sua empresa e a “Alfa”, gostaríamos que indicasse com um “X” a sua opinião para cada uma das afirmações a seguir, posicionando-se quanto ao grau de concordância ou discordância. Sendo assim, avalie as afirmativas utilizando a escala de sete posições, assinalando um número entre **1 (discordo totalmente)** e **7 (concordo totalmente)** que melhor represente a sua percepção.

a) Em relação à satisfação com o provedor de serviços:	Discordo Totalmente	Concordo Totalmente
1. Estamos muito contentes com o que o provedor de serviços faz por nós.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
2. De forma geral, nós estamos muito satisfeitos com este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
3. Nossa empresa não está completamente satisfeita com este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
4. Nossa empresa lamenta a decisão de fazer negócios com este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
5. Se nós tivéssemos de escolher um fornecedor para este tipo de serviços, escolheríamos novamente este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
6. Eu penso que nós fizemos a coisa certa quando decidimos por este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	

b) Por favor, responda às questões abaixo considerando os extremos possíveis:

7. Pelo preço pago pelos serviços, você diria que a escolha por este provedor de serviços é um...

Péssimo Negócio    1.  2.  3.  4.  5.  6.  7.  8.  9.  10.  Ótimo Negócio

8. O tempo necessário para efetivar transações com este provedor de serviços é...

Altamente Inaceitável    1.  2.  3.  4.  5.  6.  7.  8.  9.  10.  Altamente Aceitável

9. Pelo esforço envolvido ao efetivar seus pedidos, você diria que comprar deste provedor de serviços...

Realmente Não Vale a Pena    1.  2.  3.  4.  5.  6.  7.  8.  9.  10.  Realmente Vale a Pena

10. Como você avaliaria sua experiência de compra, ao longo do tempo, junto a este provedor de serviços?

Extremamente Sem Valor    1.  2.  3.  4.  5.  6.  7.  8.  9.  10.  De Extremo Valor

c) Em relação à sua reputação, este provedor de serviços:	Discordo Totalmente	Concordo Totalmente
11. Tem a reputação de ser honesto.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
12. Tem a reputação de se preocupar com seus clientes.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
13. Tem uma má reputação no mercado.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
14. Tem uma reputação diferenciada (melhor) perante o mercado.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	
15. A maioria das empresas gostaria de negociar com este provedor de serviços.	1. <input type="checkbox"/> 2. <input type="checkbox"/> 3. <input type="checkbox"/> 4. <input type="checkbox"/> 5. <input type="checkbox"/> 6. <input type="checkbox"/> 7. <input type="checkbox"/>	

d) Em relação à confiança depositada no provedor de serviços:	Discordo							Concordo						
	Totalmente							Totalmente						
16. Este provedor de serviços cumpre as promessas feitas a nossa empresa.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
17. Este provedor de serviços nem sempre é honesto conosco.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
18. Nós acreditamos nas informações que este provedor de serviços nos fornece.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
19. Este provedor de serviços está verdadeiramente preocupado com que o nosso negócio seja bem-sucedido.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
20. Quando decisões importantes são tomadas, este provedor de serviços considera o nosso bem-estar como o seu próprio bem-estar.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
21. Nós confiamos que este provedor de serviços considere nossos melhores interesses.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
22. Este provedor de serviços é confiável.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
23. Em nosso relacionamento, o provedor de serviços demonstra ter elevada integridade.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
24. É necessário tomar certas precauções com este provedor de serviços.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>

e) Quanto à possibilidade de sua empresa permanecer com este provedor de serviços ao longo do tempo:	Discordo							Concordo						
	Totalmente							Totalmente						
25. Eu certamente recomendaria este provedor de serviços a outros empresários.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
26. É provável que eu faça comentários negativos a respeito deste provedor de serviços a amigos e empresários.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
27. Em um futuro próximo, eu pretendo utilizar mais os serviços ofertados por este provedor de serviços.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
28. Mesmo que este provedor de serviços aumentasse os preços dos serviços que utilizamos, eu ainda continuaria a ser seu cliente.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
29. Se um provedor de serviços concorrente oferecesse um preço melhor ou um desconto nos serviços, eu trocaria.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>
30. Por quanto mais tempo permanecemos com este provedor de serviços, menor a probabilidade de trocarmos para um provedor de serviços concorrente.	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>	1. <input type="checkbox"/>	2. <input type="checkbox"/>	3. <input type="checkbox"/>	4. <input type="checkbox"/>	5. <input type="checkbox"/>	6. <input type="checkbox"/>	7. <input type="checkbox"/>

### Informações para Caracterização do Perfil dos Respondentes da Pesquisa:

31. Sexo: 1.  Feminino 2.  Masculino
32. Escolaridade:
1.  Primeiro grau incompleto
  2.  Primeiro grau completo
  3.  Segundo grau incompleto
  4.  Segundo grau completo
  5.  Superior incompleto
  6.  Superior completo
  7.  Superior completo com pós-graduação em andamento
  8.  Superior completo com pós-graduação concluído
33. Cargo: \_\_\_\_\_.
34. Tipo de Empresa: 1.  Pública 2.  Privada
35. Número de funcionários de sua empresa:
1.  até 50 funcionários
  2.  de 51 a 150 funcionários
  3.  mais de 151 funcionários
36. Cidade: \_\_\_\_\_.
37. Estado: \_\_\_\_\_.

**Obrigado pela sua participação!**

## APÊNDICE A - Forma tabular retirada da saída do AMOS.

Your model contains the following variables

P6	observed	endogenous
P5	observed	endogenous
P4	observed	endogenous
P3	observed	endogenous
P2	observed	endogenous
P1	observed	endogenous
P10	observed	endogenous
P9	observed	endogenous
P8	observed	endogenous
P7	observed	endogenous
P15	observed	endogenous
P14	observed	endogenous
P13	observed	endogenous
P12	observed	endogenous
P11	observed	endogenous
P21	observed	endogenous
P20	observed	endogenous
P19	observed	endogenous
P18	observed	endogenous
P17	observed	endogenous
P16	observed	endogenous
P22	observed	endogenous
P23	observed	endogenous
P24	observed	endogenous
P28	observed	endogenous
P27	observed	endogenous
P26	observed	endogenous
P25	observed	endogenous
P29	observed	endogenous
P30	observed	endogenous
SAT	unobserved	exogenous
e6	unobserved	exogenous
e5	unobserved	exogenous
e4	unobserved	exogenous
e3	unobserved	exogenous
e2	unobserved	exogenous
e1	unobserved	exogenous
VAL	unobserved	exogenous
e10	unobserved	exogenous
e9	unobserved	exogenous
e8	unobserved	exogenous
e7	unobserved	exogenous
REPU	unobserved	exogenous
e15	unobserved	exogenous
e14	unobserved	exogenous
e13	unobserved	exogenous
e12	unobserved	exogenous
e11	unobserved	exogenous
CONF	unobserved	exogenous

e21	unobserved exogenous
e20	unobserved exogenous
e19	unobserved exogenous
e18	unobserved exogenous
e17	unobserved exogenous
e16	unobserved exogenous
e22	unobserved exogenous
e23	unobserved exogenous
e24	unobserved exogenous
FIDE	unobserved exogenous
e28	unobserved exogenous
e27	unobserved exogenous
e26	unobserved exogenous
e25	unobserved exogenous
e29	unobserved exogenous
e30	unobserved exogenous

Number of variables in your model: 65  
 Number of observed variables: 30  
 Number of unobserved variables: 35  
 Number of exogenous variables: 35  
 Number of endogenous variables: 30

#### Summary of Parameters

	Weights	Covariances	Variances	Means	Intercepts	Total
	-----	-----	-----	-----	-----	-----
Fixed:	35	0	0	0	0	35
Labeled:	0	0	0	0	0	0
Unlabeled:	25	10	35	0	0	70
	-----	-----	-----	-----	-----	-----
Total:	60	10	35	0	0	105

#### NOTE:

The model is recursive.



## APÊNDICE B – Índices de modificação fornecidos pelo AMOS

### Modification Indices

Covariances:			M.I.	Par Change
e20	<-->	e19	<b>84,432</b>	0,195
e28	<-->	e29	77,219	0,488
e9	<-->	e8	51,379	0,147
e7	<-->	VAL	49,046	-0,248
e7	<-->	SAT	34,272	0,167
e13	<-->	e17	32,867	0,072
e6	<-->	e5	30,385	0,072
e9	<-->	e7	28,814	-0,156
e2	<-->	e1	28,77	0,037
e25	<-->	e29	28,562	-0,214
e28	<-->	e30	28,253	0,258
e17	<-->	e16	27,455	0,096
e26	<-->	e25	26,327	0,15
e2	<-->	e18	23,241	0,049
e22	<-->	e23	22,913	0,041
e24	<-->	e26	22,859	0,128
e17	<-->	REPU	22,763	0,038
e13	<-->	e11	22,525	0,045
e17	<-->	e24	22,477	0,098
e28	<-->	VAL	21,815	0,165
e4	<-->	e1	21,726	-0,061
e11	<-->	e17	20,405	0,067
e4	<-->	e17	19,535	0,094
e1	<-->	e17	19,31	-0,052
e8	<-->	e27	19,224	-0,26
e20	<-->	e23	18,784	-0,055
e5	<-->	e2	18,574	-0,049
e9	<-->	e16	18,464	0,072
e8	<-->	e28	17,393	0,157
e20	<-->	VAL	17,258	0,09
e25	<-->	VAL	17,007	-0,106
e28	<-->	e25	16,046	-0,15
e20	<-->	e22	14,887	-0,05
e18	<-->	e17	14,783	-0,061
e15	<-->	e30	14,752	0,136
e28	<-->	e26	14,504	-0,155
e10	<-->	e27	14,446	0,173
e13	<-->	e18	13,84	-0,038
e15	<-->	e26	13,53	-0,11
e8	<-->	e25	13,472	-0,1
e1	<-->	e7	12,87	0,071
e9	<-->	VAL	12,83	0,067
e5	<-->	e16	12,805	0,061
e6	<-->	e2	12,673	-0,031
e19	<-->	e24	12,552	-0,08
e17	<-->	e22	12,175	-0,046
e13	<-->	e26	12,053	0,056
e13	<-->	e23	12,034	0,029
e19	<-->	e22	11,897	-0,049
e3	<-->	e17	11,703	0,071

e8	<-->	e29	11,483	0,135
e4	<-->	e18	11,474	-0,06
e6	<-->	e18	11,429	-0,039
e9	<-->	e22	11,404	-0,04
e5	<-->	e28	11,333	0,099
e17	<-->	SAT	11,331	-0,058
e5	<-->	CONF	11,245	-0,033
e3	<-->	e23	11,191	-0,046
e5	<-->	e30	11,006	0,092
e18	<-->	SAT	10,845	0,046
e4	<-->	e26	10,444	0,089
e29	<-->	VAL	10,176	0,12
e20	<-->	SAT	9,971	-0,054
e17	<-->	CONF	9,652	-0,033
e10	<-->	e8	9,334	-0,062
e16	<-->	VAL	9,241	0,062
e8	<-->	e15	9,007	0,082
e8	<-->	CONF	9,006	-0,037
e2	<-->	e17	8,974	-0,037
e21	<-->	e20	8,535	0,057
e25	<-->	CONF	8,383	0,036
e13	<-->	e12	8,346	-0,034
e1	<-->	e16	8,336	-0,033
e6	<-->	e14	7,862	-0,051
e15	<-->	e28	7,752	0,106
e11	<-->	e30	7,624	-0,063
e8	<-->	e16	7,624	0,06
e14	<-->	e27	7,621	-0,181
e29	<-->	CONF	7,386	-0,05
e12	<-->	e18	7,351	0,041
e21	<-->	e23	7,317	-0,035
e11	<-->	e23	7,292	0,027
e11	<-->	e26	7,192	0,051
e1	<-->	e24	7,151	-0,034
e22	<-->	VAL	7,079	-0,039
e8	<-->	e30	7,072	0,093
e9	<-->	e20	7,045	0,047
e3	<-->	e7	7,043	0,092
e13	<-->	e30	7	-0,051
e2	<-->	e28	6,996	-0,053
e3	<-->	e10	6,967	-0,049
e11	<-->	e29	6,961	-0,068
e6	<-->	e8	6,831	0,043
e10	<-->	e20	6,785	0,046
e3	<-->	e16	6,734	0,051
e2	<-->	e20	6,671	-0,032
e4	<-->	e12	6,652	0,052
e1	<-->	e14	6,583	0,04
e5	<-->	FIDE	6,583	0,047
e23	<-->	CONF	6,549	-0,018
e2	<-->	VAL	6,5	-0,035
e21	<-->	e22	6,496	0,034
e17	<-->	e26	6,486	0,064
e28	<-->	CONF	6,462	-0,044
e5	<-->	e29	6,436	0,08
e9	<-->	SAT	6,426	-0,039
e14	<-->	FIDE	6,385	0,065

e2	<-->	e16	6,22	-0,029
e29	<-->	e30	6,115	0,128
e21	<-->	CONF	6,107	0,026
e19	<-->	e18	6,104	0,043
e15	<-->	e14	6,096	0,074
e6	<-->	e1	6,069	-0,02
e1	<-->	e18	6,047	0,024
e24	<-->	FIDE	6,034	0,052
e19	<-->	e17	6,024	-0,052
e8	<-->	e19	6,01	-0,062
e22	<-->	e28	5,937	-0,052
e5	<-->	e21	5,933	-0,044
e26	<-->	e30	5,89	-0,092
e9	<-->	e28	5,879	0,07
e5	<-->	VAL	5,879	0,048
e3	<-->	e24	5,877	0,053
e7	<-->	e13	5,834	-0,05
e10	<-->	e16	5,813	-0,04
e15	<-->	e19	5,716	-0,061
e6	<-->	FIDE	5,625	0,034
e13	<-->	e22	5,571	-0,02
e28	<-->	e27	5,523	-0,194
e3	<-->	e26	5,428	0,062
e25	<-->	FIDE	5,376	-0,052
e26	<-->	VAL	5,321	-0,064
e23	<-->	REPU	5,258	0,012
e18	<-->	VAL	5,258	-0,041
e11	<-->	e28	5,258	-0,056
e1	<-->	e19	5,192	0,03
e12	<-->	e24	5,088	-0,044
e5	<-->	e25	5,052	-0,048
e12	<-->	VAL	5,051	0,046
e6	<-->	e28	5,049	0,052
e26	<-->	e29	5,003	-0,097
e6	<-->	e15	4,98	0,037
e13	<-->	e25	4,915	0,033
e6	<-->	e4	4,888	0,034
e10	<-->	e9	4,865	0,033
e1	<-->	e8	4,826	-0,031
e21	<-->	e26	4,746	-0,055
e22	<-->	SAT	4,729	0,025
e8	<-->	e7	4,711	-0,083
e18	<-->	e16	4,707	-0,033
e2	<-->	FIDE	4,68	-0,027
e20	<-->	e27	4,603	0,108
e17	<-->	VAL	4,581	0,046
e4	<-->	e13	4,574	0,029
e2	<-->	e9	4,495	-0,024
e18	<-->	REPU	4,494	-0,014
e4	<-->	e3	4,479	0,048
e5	<-->	e9	4,456	0,035
e10	<-->	e12	4,423	0,035
e5	<-->	e8	4,41	0,045
e4	<-->	e15	4,325	-0,053
e9	<-->	e17	4,218	0,036
e9	<-->	e24	4,209	-0,039
e3	<-->	e14	4,192	-0,055

e1	<-->	e22	4,187	0,016
e8	<-->	VAL	4,148	0,051
e12	<-->	FIDE	4,133	-0,038
e2	<-->	SAT	4,11	0,021
e7	<-->	e25	4,103	0,078
e15	<-->	e25	4,102	-0,056
e12	<-->	e29	4,058	-0,064

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

P28	<--	P29	35,022	0,245
P29	<--	P28	23,796	0,197
P8	<--	P27	17,175	-0,096
P13	<--	P17	14,881	0,1
P9	<--	P8	14,711	0,107
P20	<--	P19	14,192	0,096
P25	<--	P29	13,06	-0,109
P19	<--	P20	13,046	0,108
P7	<--	P3	12,848	0,177
P28	<--	P8	12,792	0,179
P17	<--	P13	12,572	0,198
P10	<--	P27	11,55	0,061
P16	<--	P17	11,008	0,127
P7	<--	P1	10,617	0,157
P4	<--	P17	10,402	0,143
P29	<--	P8	10,259	0,171
P16	<--	P9	9,954	0,092
P11	<--	P17	9,743	0,096
P25	<--	P8	9,374	-0,111
P8	<--	P19	9,231	-0,091
P24	<--	P17	9,023	0,13
P7	<--	P22	8,962	0,191
P30	<--	P28	8,82	0,106
P1	<--	P4	8,736	-0,066
P16	<--	P8	8,679	0,085
P17	<--	P11	8,595	0,14
P26	<--	P24	8,529	0,106
P7	<--	P15	8,31	0,148
P9	<--	P7	8,299	-0,057
P8	<--	P21	8,089	-0,112
P17	<--	P16	7,831	0,103
P7	<--	P21	7,789	0,155
P7	<--	P19	7,674	0,118
P9	<--	P22	7,284	-0,094
P7	<--	SAT	7,232	0,135
P1	<--	P17	7,178	-0,066
P7	<--	P2	7,114	0,137
P7	<--	P18	6,972	0,145
P13	<--	P11	6,783	0,08
P8	<--	P22	6,647	-0,116
P7	<--	CONF	6,638	0,192
P6	<--	P5	6,597	0,062
P17	<--	P4	6,596	0,093
P8	<--	P9	6,566	0,093
P11	<--	P13	6,549	0,11
P24	<--	P26	6,399	0,072
P7	<--	P24	6,38	0,119

P28	<--	P30	6,354	0,092
P7	<--	P25	6,35	0,112
P25	<--	P26	6,258	0,08
P27	<--	P8	6,217	-0,197
P16	<--	P5	6,211	0,078
P5	<--	P28	6,094	0,053
P8	<--	P25	6,091	-0,077
P18	<--	P17	5,941	-0,081
P15	<--	P8	5,782	0,087
P25	<--	P22	5,769	0,109
P28	<--	P22	5,769	-0,15
P8	<--	P18	5,723	-0,093
P25	<--	P13	5,703	0,159
P25	<--	P18	5,642	0,093
P28	<--	P9	5,624	0,12
P11	<--	P29	5,592	-0,046
P9	<--	P24	5,447	-0,06
P7	<--	P26	5,411	0,104
P23	<--	P13	5,393	0,086
P12	<--	P4	5,282	0,079
P21	<--	P5	5,257	-0,077
P8	<--	P23	5,255	-0,104
P26	<--	P17	5,247	0,119
P8	<--	CONF	5,224	-0,12
P7	<--	P6	5,172	0,127
P7	<--	REPU	5,164	0,224
P25	<--	P28	5,049	-0,062
P5	<--	P29	5,027	0,052
P25	<--	P23	5,021	0,103
P26	<--	P13	5,021	0,161
P8	<--	P20	4,983	-0,071
P22	<--	P17	4,897	-0,06
P25	<--	P11	4,882	0,125
P29	<--	P25	4,876	-0,102
P7	<--	P4	4,858	0,134
P5	<--	P30	4,841	0,045
P2	<--	P28	4,837	-0,032
P6	<--	P8	4,719	0,048
P25	<--	P19	4,696	0,066
P15	<--	P30	4,652	0,057
P2	<--	P18	4,623	0,045
P26	<--	P25	4,613	0,073
P7	<--	P11	4,609	0,171
P10	<--	P20	4,608	0,053
P28	<--	P24	4,592	-0,099
P18	<--	P13	4,535	-0,098
P26	<--	P28	4,524	-0,063
P28	<--	P11	4,499	-0,166
P17	<--	P24	4,497	0,06
P29	<--	P11	4,412	-0,175
P16	<--	P3	4,268	0,058
P3	<--	P17	4,241	0,088
P25	<--	CONF	4,234	0,109
P6	<--	P28	4,189	0,034
P9	<--	P18	4,135	-0,061
P22	<--	P9	4,127	-0,042
P5	<--	P8	4,11	0,057

P2	<--	P5	4,082	-0,042
P29	<--	P5	4,061	0,116
P11	<--	P30	4,017	-0,034
P8	<--	P12	4,011	-0,082
P29	<--	P9	4,005	0,107

## APÊNDICE C – Pesos de regressão fornecidos pelo AMOS

### Regression Weights

			Estimate	S.E.	C.R.	P
P6	<--	SAT	0,84	0,026	32,763	0,000
P5	<--	SAT	0,796	0,031	25,348	0,000
P4	<--	SAT	0,654	0,037	17,649	0,000
P3	<--	SAT	0,889	0,035	25,342	0,000
P2	<--	SAT	0,92	0,019	48,496	0,000
P1	<--	SAT	1			
P10	<--	VAL	0,792	0,037	21,573	0,000
P9	<--	VAL	0,673	0,035	19,102	0,000
P8	<--	VAL	0,624	0,039	16,084	0,000
P7	<--	VAL	1			
P15	<--	REPU	1,553	0,097	16,048	0,000
P14	<--	REPU	1,587	0,103	15,446	0,000
P13	<--	REPU	0,851	0,053	16,139	0,000
P12	<--	REPU	1,439	0,083	17,275	0,000
P11	<--	REPU	1			
P21	<--	CONF	1,123	0,064	17,429	0,000
P20	<--	CONF	1,459	0,076	19,168	0,000
P19	<--	CONF	1,54	0,082	18,89	0,000
P18	<--	CONF	1,222	0,062	19,828	0,000
P17	<--	CONF	0,811	0,047	17,319	0,000
P16	<--	CONF	1			
P22	<--	CONF	1,081	0,052	20,682	0,000
P23	<--	CONF	1,067	0,052	20,578	0,000
P24	<--	CONF	1,39	0,074	18,87	0,000
P28	<--	FIDE	0,948	0,057	16,55	0,000
P27	<--	FIDE	0,873	0,08	10,916	0,000
P26	<--	FIDE	0,947	0,044	21,61	0,000
P25	<--	FIDE	1			
P29	<--	FIDE	0,771	0,059	13,087	0,000
P30	<--	FIDE	1,083	0,056	19,261	0,000

### Standardized Regression Weights

			Estimate
P6	<--	SAT	0,936
P5	<--	SAT	0,877
P4	<--	SAT	0,792
P3	<--	SAT	0,876
P2	<--	SAT	0,941
P1	<--	SAT	0,961
P10	<--	VAL	0,903
P9	<--	VAL	0,853
P8	<--	VAL	0,776
P7	<--	VAL	0,879
P15	<--	REPU	0,821
P14	<--	REPU	0,8
P13	<--	REPU	0,823
P12	<--	REPU	0,861
P11	<--	REPU	0,818
P21	<--	CONF	0,846
P20	<--	CONF	0,895
P19	<--	CONF	0,887
P18	<--	CONF	0,911
P17	<--	CONF	0,749
P16	<--	CONF	0,833
P22	<--	CONF	0,932
P23	<--	CONF	0,929
P24	<--	CONF	0,886
P28	<--	FIDE	0,77
P27	<--	FIDE	0,591

P26	<--	FIDE	0,873
P25	<--	FIDE	0,914
P29	<--	FIDE	0,67
P30	<--	FIDE	0,831

**Covariances**

			<b>Estimate</b>	<b>S.E.</b>	<b>C.R.</b>	<b>P</b>
SAT	<-->	VAL	1,568	0,153	10,261	0,000
SAT	<-->	REPU	0,619	0,065	9,573	0,000
SAT	<-->	CONF	0,753	0,081	9,322	0,000
SAT	<-->	FIDE	1,159	0,119	9,743	0,000
VAL	<-->	REPU	0,754	0,082	9,169	0,000
VAL	<-->	CONF	0,93	0,103	8,993	0,000
VAL	<-->	FIDE	1,46	0,154	9,467	0,000
REPU	<-->	CONF	0,45	0,049	9,267	0,000
REPU	<-->	FIDE	0,653	0,069	9,437	0,000
CONF	<-->	FIDE	0,85	0,089	9,5	0,000
e20	<-->	e19	0,207	0,029	7,119	0,000
e28	<-->	e29	0,5	0,068	7,382	0,000
e9	<-->	e8	0,21	0,029	7,316	0,000
e13	<-->	e17	0,071	0,012	5,746	0,000
e6	<-->	e5	0,054	0,015	3,698	0,000
e10	<-->	e9	0,132	0,023	5,694	0,000
e2	<-->	e1	0,066	0,015	4,354	0,000
e28	<-->	e30	0,246	0,051	4,849	0,000
e17	<-->	e16	0,094	0,018	5,199	0,000
e4	<-->	e1	-0,056	0,012	-4,657	0,000
e24	<-->	e26	0,109	0,026	4,238	0,000
e17	<-->	e24	0,078	0,019	4,229	0,000

**Correlations**

			<b>Estimate</b>
SAT	<-->	VAL	0,963
SAT	<-->	REPU	0,902
SAT	<-->	CONF	0,832
SAT	<-->	FIDE	0,842
VAL	<-->	REPU	0,898
VAL	<-->	CONF	0,841
VAL	<-->	FIDE	0,867
REPU	<-->	CONF	0,965
REPU	<-->	FIDE	0,919
CONF	<-->	FIDE	0,908
e20	<-->	e19	0,578
e28	<-->	e29	0,522
e9	<-->	e8	0,505
e13	<-->	e17	0,361
e6	<-->	e5	0,296
e10	<-->	e9	0,424
e2	<-->	e1	0,514
e28	<-->	e30	0,303
e17	<-->	e16	0,319
e4	<-->	e1	-0,29
e24	<-->	e26	0,302
e17	<-->	e24	0,244

**Variations**

	<b>Estimate</b>	<b>S.E.</b>	<b>C.R.</b>	<b>P</b>
SAT	1,33	0,126	10,531	0,000
VAL	1,992	0,222	8,955	0,000
REPU	0,354	0,044	8,034	0,000
CONF	0,614	0,074	8,283	0,000
FIDE	1,425	0,149	9,556	0,000
e6	0,134	0,015	8,974	0,000
e5	0,253	0,025	10,188	0,000



e4	0,338	0,031	10,753	0,000
e3	0,32	0,031	10,391	0,000
e2	0,146	0,018	8,149	0,000
e1	0,112	0,017	6,693	0,000
e10	0,285	0,034	8,476	0,000
e9	0,339	0,032	10,543	0,000
e8	0,511	0,048	10,541	0,000
e7	0,586	0,063	9,258	0,000
e15	0,414	0,039	10,563	0,000
e14	0,502	0,047	10,696	0,000
e13	0,122	0,012	10,534	0,000
e12	0,256	0,025	10,174	0,000
e11	0,175	0,017	10,581	0,000
e21	0,307	0,029	10,69	0,000
e20	0,326	0,032	10,215	0,000
e19	0,394	0,038	10,3	0,000
e18	0,188	0,019	9,975	0,000
e17	0,317	0,028	11,419	0,000
e16	0,272	0,025	10,769	0,000
e22	0,109	0,012	9,458	0,000
e23	0,11	0,012	9,535	0,000
e24	0,325	0,031	10,418	0,000
e28	0,878	0,081	10,875	0,000
e27	2,026	0,183	11,095	0,000
e26	0,399	0,043	9,272	0,000
e25	0,28	0,035	7,974	0,000
e29	1,042	0,096	10,908	0,000
e30	0,751	0,076	9,951	0,000