

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

**ANÁLISE CONJUNTA DE ATRIBUTOS**  
*(CONJOINT ANALYSIS)*

Autor: Hélio Radke Bittencourt

Orientadora: Jandyra M. G. Fachel

Monografia apresentada para a obtenção  
do título de Bacharel em Estatística

Porto Alegre, Dezembro de 1997.

## AGRADECIMENTOS

A conclusão de um curso de graduação é uma grande vitória pessoal que não teria sido conquistada sem a ajuda de muitas pessoas, as quais desejo expressar a minha gratidão.

Aos professores do Curso de Estatística, que foram responsáveis pela minha formação.

À Professora Jandyra, pela dedicada orientação não apenas na realização desse trabalho, mas também em atividades de pesquisa e extensão.

À meus familiares, em especial a minha mãe, que sempre me apoiou.

À todos os colegas do curso, que muito me ajudaram.

À pessoa que esteve ao meu lado desde a época do vestibular, repartindo preocupações e alegrias e me concedendo sua valiosa ajuda com muito amor: minha namorada Suzel.

À Deus, por ter me permitido concluir mais esta etapa de minha vida.

## APRESENTAÇÃO

Esse texto tratará de uma poderosa técnica estatística muito utilizada na área de marketing em países desenvolvidos: a *Conjoint Analysis*. Não há uma tradução generalizada para o termo no Brasil, por isso alguns autores mantêm o termo em inglês. Outros, simplesmente denominam de Análise Conjunta. Optamos em traduzir o termo por 'Análise Conjunta de Atributos', visto que a expressão 'Análise Conjunta' é utilizada com outro sentido na área de Planejamento de Experimentos. A metodologia da técnica será apresentada de forma didática para que usuários, tanto da área de Estatística como de Marketing, possam contar com uma referência resumida.

No primeiro capítulo, introduziremos a técnica apresentando os principais objetivos, referencial bibliográfico e também um exemplo para motivar o leitor.

No segundo capítulo serão apresentadas as principais etapas compreendidas na técnica. O processo de modelagem e métodos de estimação serão tratados a parte, no terceiro capítulo.

Nos capítulos subseqüentes, apresentaremos exemplos enfatizando os principais objetivos e contemplaremos a parte computacional com a utilização do *software* SPSS, cujo módulo *Categories* é próprio para realização da técnica.

## SUMÁRIO

1 – INTRODUÇÃO .....	06
1.1 – Vocabulário .....	07
1.2 – Revisão Bibliográfica .....	08
1.3 – Objetivos da Técnica .....	09
1.4 – Exemplo Motivador .....	10
2 – A TÉCNICA DE ANÁLISE CONJUNTA DE ATRIBUTOS .....	12
2.1 – Formulação do Problema .....	14
2.2 – Método de Apresentação dos Perfis .....	16
2.3 – Construção dos Perfis .....	20
2.4 – Escalas de Medida da Preferência .....	21
2.5 – Configuração Clássica .....	22
3 – MODELAGEM .....	24
3.1 – Regra de Composição .....	24
3.2 – Modelo de Preferência .....	26
3.3 – Métodos de Estimção .....	28
3.4 – Validade do Modelo .....	35
3.5 – Análise Conjunta de Atributos Híbrida .....	36

4 – APLICAÇÕES DA TÉCNICA .....	37
4.1 – Entendendo Estruturas de Preferência .....	37
4.2 – Segmentação de Mercado .....	44
5 – UTILIZAÇÃO DO <i>SOFTWARE</i> .....	50
5.1 – SPSS – Módulo <i>Categories</i> .....	51
6 – CONSIDERAÇÕES FINAIS .....	58
7 – ANEXOS .....	60
8 – BIBLIOGRAFIA .....	62

## 1 - INTRODUÇÃO

Análise Conjunta de Atributos (*Conjoint Analysis*) é uma técnica multivariada utilizada especificamente para entender de que maneira os respondentes desenvolvem preferências por produtos ou serviços. Está baseada na premissa de que consumidores avaliam o valor ou utilidade de um produto/serviço combinando importâncias provenientes de cada atributo (ou variável) associado.

Dentre as muitas técnicas multivariadas, esta é a única que proporciona ao pesquisador a construção prévia de um conjunto real ou hipotético de níveis de variáveis. Estes conjuntos são apresentados aos respondentes que têm a tarefa de avaliá-los de acordo com suas preferências. Desta forma é possível estudar reações e opiniões de consumidores e predeterminar combinações de variáveis que representem um produto ou serviço em potencial.

É considerada uma importante ferramenta para Pesquisa de Mercado, especialmente no planejamento de produtos. Com ela é possível obter respostas para perguntas de crucial importância no projeto e lançamento de um produto.

Está intimamente relacionada com a área de planejamento de experimentos; na realidade é uma aplicação desta área para obtenção de preferências de consumidores.

Apesar de ter sido desenvolvida na década de 70, a Análise Conjunta de Atributos não foi muito difundida no Brasil. Nos Estados Unidos, em meados dos anos 70, esse método atraiu considerável atenção, tanto a nível acadêmico quanto industrial, como sendo a melhor técnica para retratar escolhas ou decisões de consumidores de uma forma bastante realista. Sua maior aceitação e utilização internacional deu-se na década de 80, juntamente com a utilização de programas computacionais que passaram a integrar o processo inteiro de análise. Wittink e Cattin (1989) contabilizaram em torno de 400 aplicações comerciais da técnica por ano, realizadas durante o início dos anos 80 nos Estados Unidos.

## 1.1 – VOCABULÁRIO

A seguir serão comentados alguns termos associados com Análise Conjunta de Atributos:

- *Atributo* – Sinônimo de fator.
- *Fator* – Variável que o pesquisador controla para mensurar seu efeito sobre outra variável.
- *Nível* – Valor específico de um fator. Cada fator é representado por dois ou mais níveis.
- *Perfil* – Sinônimo de tratamento. Em alguns livros esse termo designa apenas os tratamentos que realmente serão utilizados no experimento.
- *Tratamento* – Conjunto específico de níveis. Também conhecido como estímulo.

- Variáveis *dummy* – Variáveis indicadoras binárias utilizadas no processo de estimação através da Regressão Linear.

## 1.2 – REVISÃO BIBLIOGRÁFICA

As técnicas de mensuração conjunta foram foco de muitos estudos no campo da psicologia matemática, durante as décadas de 60 e 70. Luce e Tukey, em 1964, apresentaram o primeiro trabalho com noções de procedimentos para mensuração simultânea.

No início dos anos 70, essas técnicas passaram a ser introduzidas na literatura de Pesquisa de Mercado. Em 1971, Paul Green e Vithala Rao publicaram no *Journal of Marketing Research*, um artigo relacionando as técnicas de mensuração conjunta com problemas encontrados na área de marketing. Esses autores, em especial Paul Green, trouxeram muitas outras contribuições, e seus artigos encontram-se publicados em periódicos da área de marketing, como: *Journal of Marketing*, *Journal of Marketing Research*, *Harvard Business Review*, etc.

Uma discussão sobre o uso comercial da Análise Conjunta de Atributos foi apresentada por Cattin e Wittink (1982). O artigo consta de um apanhado geral sobre as aplicações dessa metodologia em empresas americanas durante a década de 70. Em 1989, os mesmos autores voltaram a publicar um artigo com as mesmas características, porém com dados atualizados.

Uma revisão da técnica, contemplando todos pontos importantes e novos desenvolvimentos, foi publicada por Green e Srinivasan (1990).



Além dos periódicos, a *Internet* surge como uma rica fonte de consulta. Nela foi possível encontrar muitas páginas dedicadas exclusivamente à *Conjoint Analysis*, e uma bibliografia completa organizada por Clark Hu, um doutorando na Universidade de Nevada.

Atualmente, a Análise Conjunta de Atributos tem ocupado importante posição em livros de Pesquisa de Mercado e Análise Multivariada. Hair et al (1995) e Malhotra (1996), dedicam um capítulo inteiro à esta técnica. O primeiro explora todos estágios de um experimento envolvendo a técnica, mas não se aprofunda no desenvolvimento matemático. O segundo, apresenta detalhadamente o cálculo das utilidades parciais através da regressão múltipla.

Existem, ainda, *softwares* estatísticos que dispõem de módulos para se trabalhar com a análise conjunta de atributos. O módulo *Categories* do SPSS (SPSS Inc., 1994) é próprio para realização da técnica e seu manual é uma referência interessante para quem deseja entender e aplicar a técnica.

### 1.3 - OBJETIVOS DA TÉCNICA

A proposta da Análise Conjunta de Atributos é determinar as contribuições de variáveis e seus níveis no processo de escolha, através de combinações que representam conjuntos de escolha reais. A predição não é de uma preferência absoluta, mas de uma preferência relativa dentro de um conjunto definido.

O objetivo maior da técnica é identificar configurações ótimas de produtos ou serviços, analisando-se o relacionamento de características subjacentes às preferências dos respondentes. Segmentação de consumidores

com alto ou baixo potencial de compra e a identificação de novas oportunidades de mercado, constituem-se em outros importantes objetivos.

#### 1.4 - EXEMPLO MOTIVADOR

O exemplo relatado a seguir tem como objetivo motivar o leitor para a definição da técnica de Análise Conjunta de Atributos e consta do manual SPSS – *Categories* (1994).

Suponha que você deseja fazer uma reserva de vôo numa determinada companhia aérea. Você pode optar entre assentos apertados ou assentos espaçosos. Se esta for a única consideração, sua escolha deverá ser lógica. Você deverá preferir um assento espaçoso. Agora, suponha que você tem a opção por dois preços de bilhetes: \$225 e \$800. Levando em consideração apenas o preço, a escolha torna-se ainda mais óbvia pois o preço baixo sempre é preferido. Suponha também que exista um vôo direto, com duração de duas horas, e outro com escala e tempo de duração de cinco horas. A maioria das pessoas daria preferência ao vôo mais rápido.

A desvantagem dessa abordagem é que a escolha das alternativas é feita sobre atributos isolados, um de cada vez. A Análise Conjunta de Atributos apresenta as alternativas de escolha entre produtos definidos por conjuntos de atributos. Podemos ilustrar isto desta forma: você escolheria um vôo com assentos apertados, uma escala e custo de \$225, ou um vôo mais confortável, sem escalas e preço de \$800? Dando continuidade, percebe-se que o conforto, preço e duração são atributos relevantes. A tabela 1.1 apresenta a combinação dos níveis desses três fatores.

*Tabela 1.1 - Combinação dos níveis dos fatores relevantes para compra de passagens aéreas (SPSS Inc., 1994)*

Número do Produto (perfil)	Conforto do assento	Preço	Duração
1	apertado	\$225	2 horas
2	apertado	\$225	5 horas
3	apertado	\$800	2 horas
4	apertado	\$800	5 horas
5	espaçoso	\$225	2 horas
6	espaçoso	\$225	5 horas
7	espaçoso	\$800	2 horas
8	espaçoso	\$800	5 horas

Oferecendo essas alternativas, o produto 4 será, provavelmente, o menos preferido, enquanto que o produto 5 deverá ser o mais preferido. As preferências dos respondentes para os outros produtos oferecidos são implicitamente determinadas pelo o que eles consideram importante.

Utilizando Análise Conjunta de Atributos é possível determinar a importância relativa de cada fator, bem como quais níveis são mais preferidos. Se o produto mais preferido for impraticável por alguma razão, como o custo, a próxima alternativa poderá ser conhecida. Se for possível contar com informações sócio-econômicas e demográficas dos indivíduos, pode-se utilizar a técnica para identificar segmentos de mercado, para os quais podem ser criados produtos distintos. Por exemplo, um executivo que viaja a negócios e um estudante têm diferentes preferências que devem ser conhecidas, para que produtos distintos possam ser oferecidos.

## 2 - A TÉCNICA DE ANÁLISE CONJUNTA DE ATRIBUTOS

Para atingir os objetivos descritos no item 1.2, é necessário observar todas etapas que envolvem um experimento de Análise Conjunta de Atributos. Este capítulo irá explanar os procedimentos necessários para a realização da técnica, com exceção da parte de estimação que será apresentada no próximo capítulo. A figura 2.1 apresenta as etapas.

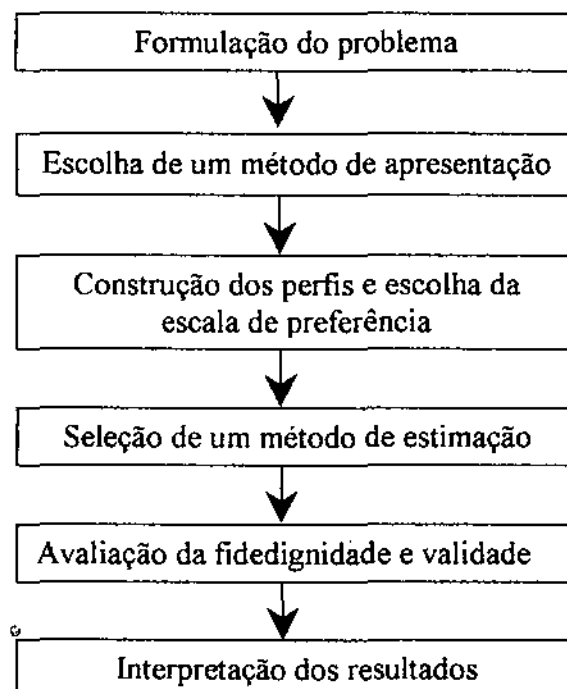


Figura 2.1 – Conduzindo Análise Conjunta de Atributos (adaptado de Malhotra, 1996)

A primeira coisa a se fazer, como em qualquer técnica estatística, é ter bem claro o problema de pesquisa para que se avalie a adequabilidade da técnica em relação aos objetivos. Segundo Hair et al. (1995) Análise Conjunta de Atributos, no que se refere a análise de decisões de consumidores, tem dois objetivos:

- Determinar as contribuições das variáveis preditoras e seus respectivos níveis para determinação de preferências de consumidores.
- Estabelecer um modelo válido para a opinião de consumidores e que seja útil na predição da aceitação dos consumidores para alguma combinação de atributos.

Os próximos passos referem-se à construção dos perfis e ao método de coleta de dados junto ao respondente.

Através de um método de estimação adequado, são calculados coeficientes chamados de utilidades parciais (*part-worths*) para os níveis dos atributos, por meio dos quais é possível identificar a importância relativa de cada fator diretamente. A interpretação desses coeficientes possibilita o alcance dos objetivos propostos pela técnica, desde que o modelo estimado reproduza satisfatoriamente as preferências dos respondentes.

O quadro a seguir, adaptado de Green e Srinivasan (1990), apresenta as alternativas mais utilizadas e conhecidas para importantes etapas da Análise Conjunta de Atributos.

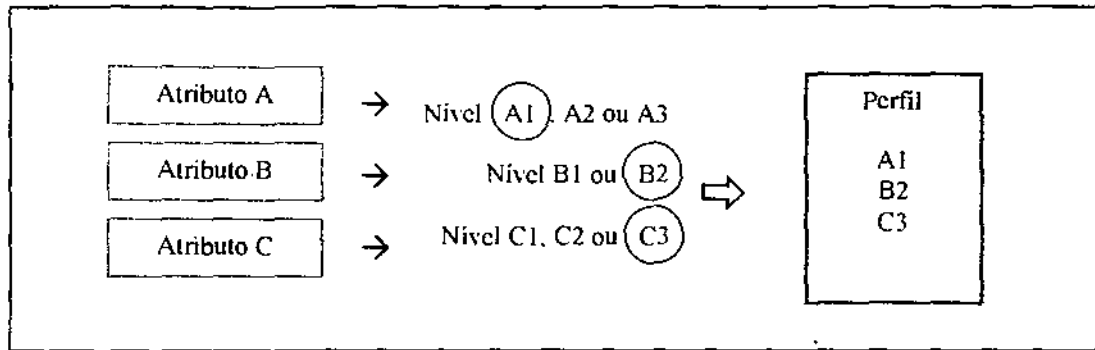
Tabela 2.1 – Alternativas na Análise Conjunta de Atributos

<i>Etapa</i>	<i>Métodos Alternativos</i>
1. Método de Apresentação dos perfis	Perfil completo ( <i>full-profile, full-concept method</i> ) Tabelas <i>Trade-off</i> Comparações pareadas Método alternativo de D. Mangen
2. Construção dos perfis	Delineamento fatorial completo Delineamento fatorial fracionário
3. Forma de entrada dos dados: escala de medida da variável dependente (preferência)	Escala ordinal ( <i>Rating scale</i> ) Ordenação por postos ( <i>Rank order</i> )
4. Modelo de preferência	Modelo linear ou vetorial Modelo quadrático ou ideal Modelo de utilidades parciais ( <i>part-worth model</i> )
5. Método de estimação	Regressão múltipla (OLS) MONANOVA Logit LINMAP

## 2.1 – FORMULAÇÃO DO PROBLEMA

Assim como no planejamento de experimentos, a conceitualização da pesquisa é crítica para o sucesso da Análise Conjunta de Atributos. O pesquisador deve tomar algumas decisões importantes no delineamento do experimento e análise dos resultados.

Em Análise Conjunta de Atributos, cada perfil é uma combinação de níveis selecionados para cada um dos atributos em estudo. Os atributos são as principais características de um produto ou serviço, enquanto que os níveis são pontos específicos destes atributos (figura 2.2). É através do estudo da preferência de consumidores, mediante a apresentação de vários perfis, que encontrar-se-á qual a combinação de níveis de atributos que deverá ser utilizada no novo produto ou serviço.



*Figura 2.2: O relacionamento entre um perfil, atributos e níveis.*

Os respondentes irão reagir apenas frente às combinações de atributos especificadas pelo pesquisador. Será que os atributos que estão sendo utilizados e seus níveis estão realmente afetando a escolha dos consumidores? Todos atributos que afetam potencialmente o processo de escolha e melhor diferenciam os objetos deveriam ser incluídos. É importante que a utilidade total de um objeto esteja bem definida e de acordo com a realidade. O preço é um atributo quase sempre incluído.

Os fatores e os níveis escolhidos devem ter relevância prática e serem distintos, possuindo um conceito único. Atributos como 'qualidade geral' ou 'conveniência' não devem ser utilizados, pois são muito amplos e imprecisos devido a diferença conceitual existente entre as pessoas. Níveis impraticáveis, ou que não poderão ser utilizados em situações reais, podem afetar artificialmente os resultados. Para que haja uma avaliação bastante realística, os fatores devem ser facilmente comunicáveis.

O número de atributos incluídos na análise afeta diretamente a eficiência estatística e a validade dos resultados. Quanto mais atributos e níveis forem incluídos, um número maior de combinações poderá ser feito, aumentando, conseqüentemente, o número de perfis. Uma quantidade muito

grande de perfis confunde as respostas fornecidas pelos respondentes e aumenta o número de parâmetros a serem estimados.

Outro importante aspecto refere-se à correlação interatributos, também conhecida por correlação ambiental (*environmental correlation*), que pode gerar combinações de atributos inviáveis ou redundantes. No exemplo motivador, o perfil número 5 poderia ser tranquilamente inviável na prática. Isso acontece porque os atributos conforto e preço estão diretamente correlacionados e o tempo de duração e o preço correlacionam-se inversamente. Já os produtos 2 e 7 poderiam ser redundantes. A correlação interatributos indica uma perda de ortogonalidade entre os atributos. Em tais casos, as estimativas dos parâmetros são afetadas da mesma forma que na regressão.

### *2.1.1 Considerações sobre o tamanho amostral*

O tamanho amostral varia muito em estudos envolvendo a técnica de Análise Conjunta de Atributos. Cattin e Wittink (1982), referindo-se a aplicações comerciais da técnica, descrevem que o tamanho amostral usual pode variar de 100 até 1000, sendo que a maioria dos estudos baseia-se em amostras de 300 a 550 indivíduos. Por outro lado, há autores que dizem que tamanhos amostrais inferiores a 100 também são usuais. Como sempre, o tamanho amostral deve ser grande o bastante para assegurar fidedignidade. (SPSS Inc., 1994)

## **2.2 – MÉTODO DE APRESENTAÇÃO DOS PERFIS**

Depois de especificar os fatores e níveis que irão compor o experimento, o pesquisador deve decidir sobre o método de apresentação dos perfis aos respondentes. O objetivo é expressar a combinação de atributos de uma maneira eficiente e realística. Os métodos perfil completo, tabelas *trade-*



*off* e comparações pareadas são os mais utilizados. Existe também um novo método, proposto em abril deste ano, que será comentado.

O métodos de apresentação mais popular é o perfil completo (Hair et al, 1995; Cattin e Wittink, 1989). Essa abordagem descreve as combinações de atributos (tratamentos) como perfis que serão apresentados aos respondentes através de descrições, modelos físicos (protótipos) ou até animações no computador. Caracteriza-se por uma descrição fiel da realidade, refletindo com precisão o comportamento de escolha de indivíduos no mercado, pois todos atributos são considerados ao mesmo tempo.

Um dos principais motivos de se trabalhar com o método perfil completo é a possibilidade de redução no número de comparações através da utilização do delineamento fatorial fracionário (ver item 2.3). Apesar disso, recomenda-se não utilizar a técnica de Análise Conjunta de Atributos quando o número de fatores envolvidos for superior a seis. No exemplo motivador, a tabela 1.1 apresenta as combinações dos níveis dos fatores através desse método. Como haviam apenas três atributos envolvidos, com dois níveis cada, não foi necessário realizar fracionamento. Avaliar oito perfis não é uma tarefa que pode ser considerada difícil pelos respondentes.

No método *trade-off*, os respondentes avaliam dois atributos por vez. Para cada par, todas as combinações de níveis são avaliadas. A apresentação é feita na forma de matrizes, cujas células são ordenadas pelos respondentes.

A figura 2.3 apresenta a forma de utilização do método *trade-off* para a coleta de dados no exemplo motivador. Os respondentes deveriam ordenar cada matriz de 1 (combinação mais preferida) a 4 (menos preferida), assumindo que o produto em questão – o voo – difere apenas em relação aos dois atributos dispostos em cada matriz.

		Conforto do assento					
		Apertado	Espaçoso				
Preço	\$225			Duração	2 horas		
	\$800				5 horas		
		Duração					
		2 horas	5 horas				
Preço	\$225			Duração	2 horas		
	\$800				5 horas		

Figura 2.3 – Abordagem *trade-off* para coleta de dados

De acordo com Cattin e Wittink (1989), a utilização desse método vem decrescendo drasticamente devido as suas muitas limitações:

- não retrata bem a realidade, devido a utilização de apenas dois fatores de cada vez;
- um grande número de comparações é necessário para um pequeno número de níveis;
- pode haver confusão por parte dos respondentes na hora de preencher a matriz;
- é imprescindível a apresentação das matrizes em papel;
- não é possível utilizar o delineamento fatorial fracionário para reduzir o número de comparações.

Para mais informações sobre a abordagem *trade-off*, ver Richard Johnson (1974).

O terceiro método de apresentação é o de comparações pareadas, que agrega aspectos dos anteriores. Nada mais é do que a comparação de dois perfis, realizada através da utilização de uma escala ordinal (*rating scale*) que indicará a preferência por um ou outro perfil. É similar ao método *trade-off*, pois as comparações são feitas aos pares e similar ao perfil completo, pois todos atributos são considerados ao mesmo tempo.

Veamos, na figura 2.4, uma comparação pareada que poderia ser feita no exemplo motivador. O respondente deve posicionar-se na escala de acordo com sua preferência por um dos dois perfis.




Figura 2.4 – Exemplo de comparação pareada

Um empresário americano chamado David Mangen, da *Mangen Research Associates* propôs, em abril deste ano, uma nova forma de coleta de dados. Um de seus objetivos é tornar possível a coleta de dados via telefone, o que seria inviável com os outros métodos existentes. Mangen utiliza-se de uma escala de escores, através da qual calcula o que ele chama de *escores derivados*.

Para facilitar o entendimento, vamos recorrer a um projeto hipotético envolvendo um determinado chá (Mangen, 1997), onde há três atributos envolvidos com dois níveis cada:

- Temperatura: quente – gelado
- Concentração: muito forte – muito fraco
- Quantidade de açúcar: Sem açúcar – 2 colheres

A forma de coleta de dados junto ao respondente dispensa a construção de perfis e é feita de acordo com a figura 2.5.

Quente	1	2	3	4	5	6	7	8	Gelado
Muito forte	1	2	3	4	5	6	7	8	Muito fraco
Sem açúcar	1	2	3	4	5	6	7	8	Dois colheres

Figura 2.5 - Coleta de dados pelo método de David Mangen

Para ilustrar o cálculo dos escores derivados, vamos assumir que um indivíduo indicou as respostas circuladas na figura 2.5. A partir de suas respostas, podemos calcular escores para as oito combinações de atributos através da diferença de sua resposta em relação às combinações de referência. Por exemplo, o escore derivado da preferência desse sujeito para a combinação de atributos 'quente – muito forte – sem açúcar' é o seguinte:

$$\text{Escore derivado}_{\text{Quente - muito forte - sem açúcar}} = (8-1) + (5-1) + (7-1) = 17$$

Escore derivados altos indicarão baixa preferência por uma determinada combinação de atributos, pois são indicativos de que as respostas do indivíduo estão distantes da combinação de referência. Por outro lado, valores próximos de zero indicarão alta preferência.

A partir dos escores derivados são calculados *rankings derivados*, sobre os quais pode-se aplicar diretamente a técnica tradicional da Análise Conjunta de Atributos. Para maiores detalhes, ver Mangen (1997).

### 2.3 – CONSTRUÇÃO DOS PERFIS

Após ter selecionado um método de apresentação, o pesquisador tem a tarefa de criar os tratamentos a serem avaliados pelos respondentes.

A abordagem utilizada para combinação de níveis de fatores nos métodos perfil completo e comparações pareadas é conhecida como experimento fatorial. Ao optar pela apresentação de todas combinações de níveis de fatores possíveis, o pesquisador estará realizando um experimento fatorial completo. Entretanto, pode ser desnecessário ou inviável submeter o respondente a um número muito grande de avaliações. Para redução do número de tratamentos pode-se utilizar um experimento fatorial fracionário. Uma classe especial de delineamentos fracionários, chamada de vetores ortogonais, permite uma estimação eficiente de todos efeitos principais de interesse sobre uma base não correlacionada. Este delineamento assume que todas as interações são desprezíveis.

No método *trade-off*, todas combinações possíveis de atributos devem ser utilizadas. Se 'n' fatores compõem o experimento,  $C_n^2$  matrizes devem ser formadas. Já no método alternativo de Mangen, o pesquisador apresentaria apenas 'n' escalas de preferência.

## 2.4 – ESCALAS DE MEDIDA DA PREFERÊNCIA

Em Análise Conjunta de Atributos geralmente utiliza-se uma das seguintes escalas para mensuração da preferência: escala ordinal (*rating scale*) ou ordenação por postos (*rank order*). A escala ordinal normalmente é do tipo *Likert* com, no mínimo, 8 pontos. Ordenamento por postos (*rank order*) significa o ordenamento de todos os perfis, do mais preferido (*rank 1*) ao menos preferido.

O método *trade-off* comporta apenas o ordenamento por postos e o método de comparações pareadas apenas a escala ordinal. O método perfil completo pode acomodar ambas as escalas, sendo que cada uma delas possui vantagens e limitações. Segundo Hair et al (1995), uma escala de ordenamento

por postos é mais realística do que a escala ordinal, porque o ordenamento é uma tarefa considerada mais fácil do que avaliação de cada perfil através de uma escala métrica, desde que o número de perfis a serem avaliados seja inferior a 20. Uma desvantagem da escala de ordenamento é a dificuldade na administração, pois o processo de ordenamento é freqüentemente realizado com protótipos ou cartões, o que dificilmente pode ser realizado sem uma entrevista pessoal.

## 2.5 – CONFIGURAÇÃO CLÁSSICA

Apesar das muitas alternativas disponíveis para as várias etapas da Análise Conjunta de Atributos, observa-se no artigo de Cattin e Wittink (1989) que é possível estabelecer uma configuração clássica para experimentos envolvendo a técnica.

O método de apresentação de perfis mais utilizado desde a década de 70 é o perfil completo. Esse fato deve-se ao seguinte:

- é a alternativa que mais condiz com a realidade;
- a maioria dos estudos são realizados através de entrevista pessoal: uma medida necessária para utilização do método.

Como o método perfil completo pode gerar um número muito grande de combinações de tratamentos, é muito comum a utilização de um delineamento fatorial fracionário para reduzir o número de perfis a serem apresentados ao respondente. Este fato está de acordo com Green e Srinivasan (1991) que dizem ser bem típico estimar apenas os efeitos principais em experimentos desse tipo.

Quanto as escalas de mensuração da preferência, as mais utilizadas são o ordenamento por postos e a escala ordinal. O método de estimação através da regressão múltipla é amplamente utilizado. Apesar de ser

próprio para escalas métricas como a escala ordinal, o método também tem sido utilizado com escalas não métricas, como o ordenamento por postos. O *software* SPSS, por exemplo, estima o modelo através do método dos mínimos quadrados, independente do tipo de escala utilizada. Esse assunto será abordado mais detalhadamente no próximo capítulo.

A partir dessas informações, podemos identificar uma configuração clássica para experimentos com Análise Conjunta de Atributos, descrita na tabela 2.2.

*Tabela 2.2 – Análise Conjunta de Atributos clássica*

<b>Método de Apresentação dos perfis</b> <i>Perfil completo</i>
<b>Construção dos perfis</b> <i>Delineamento fatorial completo ou fracionário</i>
<b>Escala de medida da variável dependente</b> <i>Escala ordinal ou ordenamento por postos</i>
<b>Método de estimação</b> <i>Regressão múltipla (OLS)</i>

### **3 – MODELAGEM**

A fundamentação conceitual da Análise Conjunta de Atributos, como aplicação em marketing, surgiu da teoria da demanda do consumidor, que assume que uma função utilidade poderá ser decomposta em utilidades separadas para características ou benefícios de produtos ou serviços. Essa visão de decomposição do processo de formação da utilidade de consumidores veio a ser amplamente aceita como uma razoável aproximação para o comportamento do mercado de consumidores.

A técnica, então, baseia-se num modelo de decomposição, porque parte de opiniões gerais de consumidores sobre um conjunto de alternativas, sobre as quais realiza-se um trabalho de decomposição das preferências originais em escalas de utilidade separadas (*part-worths*). A partir dos escores de utilidade é possível reconstruir as opiniões globais (*total-worth*).

#### **3.1 – REGRA DE COMPOSIÇÃO**

Para introduzir o modelo devemos, primeiramente, definir qual combinação de variáveis constituirá o valor ou utilidade total do produto ou serviço. O pesquisador necessitará conhecer as variáveis envolvidas e também os possíveis valores para cada variável. O único valor fornecido pelo



respondente será a variável dependente, ou seja sua preferência. No exemplo motivador, apresentado na introdução, um simples modelo aditivo poderia ser utilizado para predizer a preferência por algum dos produtos apresentados, baseando-se na fórmula:

$$\text{Preferência} = \text{Efeito do conforto} + \text{Efeito do Preço} + \text{Efeito da Duração}$$

Para combinar as utilidades parciais (*part-worth*) dos fatores e obter a utilidade total (*total worth*) de um objeto, utiliza-se uma regra de composição que descreve como o respondente combina essas utilidades parciais para obter a utilidade total. A mais comum e básica regra de composição é representada por um modelo aditivo, com o qual soma-se as utilidades parciais para se conseguir o valor total de uma combinação de atributos.

Na maioria dos casos o modelo aditivo explica de 80 a 90% da variação na preferência de consumidores, sendo suficiente para a maioria das aplicações (Hair et al, 1995). É bem típico estimar apenas os efeitos principais considerando os efeitos de interação desprezíveis. (Green e Srinivasan, 1990)

De uma forma geral, um modelo de análise conjunta pode ser mostrado da forma descrita a seguir. A preferência geral, que representa a utilidade total ( $U(X)$ ) de um objeto, é reflexo das utilidades parciais (*part-worths*) dos níveis dos fatores considerados.

$$U(X) = \sum_{i=1}^m \sum_{j=1}^{k_i} \alpha_{ij} x_{ij}$$

$U(X)$  = Utilidade geral de um perfil

$\alpha_{ij}$  = Utilidade parcial associada ao  $j$ -ésimo nível ( $j=1,2,\dots, k_i$ ) do  $i$ -ésimo atributo ( $i=1,2,\dots, m$ )

$x_{ij}$  = Variável indicadora que representa a presença ou ausência de um determinado nível de atributo num perfil

$k_i$  = Número de níveis do atributo  $i$

$M$  = Número de atributos

Para interpretar o impacto dos níveis dos fatores através das utilidades parciais estimadas, a importância relativa de cada fator é determinada. Como as estimativas estão sobre uma mesma escala, a importância de um atributo,  $I_i$ , é definida em termos da amplitude das utilidades parciais,  $\alpha_{ij}$ , entre os níveis desse atributo:

$$I_i = \{Max(\alpha_{ij}) - Min(\alpha_{ij})\} \text{ para cada } i$$

Essa importância é padronizada para se obter a importância relativa aos outros atributos,  $W_i$ :

$$W_i = \frac{I_i}{\sum_{i=1}^n I_i}$$

tal que,

$$\sum_{i=1}^n W_i = 1$$

Devido a padronização, os valores de  $W_i$  formarão uma consistente base de comparação entre respondentes. Através deles, será possível identificar quais fatores estão influenciando com maior força a escolha dos respondentes.

### 3.2 – MODELO DE PREFERÊNCIA

Além da regra de composição, que se refere ao relacionamento entre os fatores no processo de decisão do respondente, é preciso determinar o tipo de relacionamento existente entre as preferências e os níveis dos fatores. A Análise Conjunta de Atributos fornece três alternativas (figura 3.1) ao pesquisador:

- Linear - o mais simples e restritivo tipo de relacionamento
- Quadrático - relacionamento curvilíneo
- Utilidades Parciais - o mais geral e menos restritivo




Figura 3.1 - Tipos de relacionamentos dentro dos atributos

O modelo linear, também chamado de modelo vetorial, é representado por uma simples função linear que assume que a preferência irá aumentar ou diminuir de acordo com o aumento do nível no atributo. O preço é tipicamente linear, pois as pessoas quase sempre preferem preços mais baixos. Esse modelo requer que um simples parâmetro seja estimado para cada um dos fatores.

O modelo quadrático, mais conhecido como modelo ideal, trata-se de uma função curvilínea que define uma quantidade ótima para cada atributo. O modelo estabelece um relacionamento inverso entre preferências e a distância ponderada de um nível ao ponto ideal.

O modelo de utilidades parciais é o mais geral e menos restritivo dos modelos de estimação de utilidades, implicando em estimativas próprias de utilidade parcial para cada um dos níveis de um atributo. Esse é um dos motivos pelo qual não se trabalha com um número grande de níveis dentro de um fator.

O tipo de relacionamento pode ser especificado para cada fator separadamente. Esta escolha não afeta o processo de construção de tratamentos, mas sim o impacto de como e quais tipos de utilidades parciais são estimados pela técnica. Cada modelo de preferência requer que um diferente número de parâmetros seja estimado.

O pesquisador pode optar por muitas abordagens para decidir sobre o tipo de relacionamento de cada fator. O modelo pode ser estimado, primeiramente, como um modelo de utilidades parciais, cujos parâmetros estimados podem ser examinados visualmente para detectar se uma forma quadrática ou linear é apropriada. Como o relacionamento de utilidades parciais é o menos restritivo, concentraremos nosso estudo nele.

### 3.3 – MÉTODOS DE ESTIMAÇÃO

O método de estimação a ser utilizado depende do tipo de escala de medida que é utilizada para a variável dependente. Se os dados forem provenientes de avaliações através do ordenamento de perfis, a escolha poderá ser entre um método não-métrico como, por exemplo, Análise de Variância Monotônica (MONANOVA) ou Mapeamento Linear (LINMAP). Estes dois métodos estão disponíveis em *softwares* específicos e não serão comentados nesse texto.

Se uma medida métrica de preferência for utilizada (escala ordinal), então vários métodos podem estimar as utilidades parciais. Dentre os muitos procedimentos para métodos de estimação, o mais simples e popular é a análise de regressão múltipla através do método dos mínimos quadrados. O objetivo da regressão é produzir um conjunto de utilidades parciais aditivas (os modelos vetor e ideal também podem ser estimados) que identifiquem a preferência dos respondentes para cada nível do conjunto de atributos .

As variáveis preditoras consistirão de variáveis *dummy*. Se um fator tem  $k_i$  níveis, eles são codificados em termos de  $k_i - 1$  variáveis *dummy* que indicarão a presença (1) ou ausência (0) do nível do fator no perfil (ou tratamento) considerado. Se os dados obtidos são métricos, os escores de preferência ou os postos formam a variável dependente e a análise de

regressão apresenta a configuração a seguir. O modelo a ser estimado pode ser representado por:

$$U = X\beta + \varepsilon$$

onde,

$U$  = vetor de preferências

$\beta$  = vetor dos coeficientes de regressão

$X$  = matriz de variáveis dummy ou variáveis indicadoras

$\varepsilon$  = vetor de erros não observável

Primeiramente, vamos definir a matriz de variáveis *dummy*: seja  $X$  uma matriz de zeros e uns com  $p$  linhas e  $t+1$  colunas ( $p$  e  $t$  estão definidos no quadro a seguir). Observe que cada fator  $i$  possui  $k_i - 1$  variáveis indicadoras, pois em cada fator  $i$  o  $k_i$ -ésimo nível é assumido como base.

$$X = \begin{bmatrix} \overbrace{X_1 \quad X_2 \quad \dots \quad X_{k_1-1}}^{\text{Fator1}} & \overbrace{X_1 \quad X_2 \quad \dots \quad X_{k_2-1}}^{\text{Fator2}} & \dots & \overbrace{X_1 \quad X_2 \quad \dots \quad X_{k_n-1}}^{\text{Fator n}} \\ 1 \quad x_{111} \quad x_{121} \quad x_{1(k_1-1)1} & x_{211} \quad x_{221} \quad x_{2(k_2-1)1} & \dots & x_{n11} \quad x_{n21} \quad x_{n(k_n-1)1} \\ 1 \quad x_{112} \quad x_{122} \quad x_{1(k_1-1)2} & x_{212} \quad x_{222} \quad x_{2(k_2-1)2} & \dots & x_{n12} \quad x_{n22} \quad x_{n(k_n-1)2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 \quad x_{11p} \quad x_{12p} \quad x_{1(k_1-1)p} & x_{21p} \quad x_{22p} \quad x_{2(k_2-1)p} & \dots & x_{n1p} \quad x_{n2p} \quad x_{n(k_n-1)p} \end{bmatrix}$$

onde,

$x_{ijk} = 1$ , se o  $j$ -ésimo nível do  $i$ -ésimo fator está presente no perfil  $k$ ;  
0, caso contrário.

$p$  = número total de perfis

$k_i$  = número de níveis do atributo  $i$

$n$  = número total de atributos

$t = (k_1 + k_2 + \dots + k_n) - n$

A matriz de variáveis *dummy*  $X$ , o vetor de preferências  $U$  e o vetor dos coeficientes de regressão  $\beta$ , possuem as seguintes dimensões (tabela 3.1).

Tabela 3.1 - Dimensão dos vetores e matrizes

	Linhas	Colunas
$U$	$p$	$1$
$X$	$p$	$t+1$
$\beta$	$t+1$	$1$

Definida a matriz  $X$  e as dimensões dos termos do modelo, podemos visualizar a estrutura na forma matricial.

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \\ \vdots \\ u_{p-2} \\ u_{p-1} \\ u_p \end{bmatrix} = X \times \begin{bmatrix} b_0 \\ b_{11} \\ \vdots \\ b_{1(k_1-1)} \\ b_{21} \\ \vdots \\ b_{2(k_2-1)} \\ \vdots \\ b_n \\ \vdots \\ b_{n(k_n-1)} \end{bmatrix}$$

onde,

$u_i$  - preferência associada ao  $i$ -ésimo perfil;  $i=1,2,\dots,p$

$b_{ij}$  = coeficiente de regressão a ser estimado, associado ao  $j$ -ésimo nível ( $j=1,2,\dots, k_i$ ) do  $i$ -ésimo atributo ( $i=1,2,\dots,n$ )

$p$  = número total de perfis

$k_i$  = número de níveis do atributo  $i$

$n$  = número de total atributos

Conforme já foi mencionado anteriormente, para realizar a análise de regressão através do modelo com variáveis indicadoras é necessário

que se adote um dos níveis de cada atributo para ser o nível base. Estes níveis são codificados como nulos na sua presença ou ausência num determinado perfil, conforme a tabela 3.2.

Tabela 3.2 - Codificação dos níveis do  $i$ -ésimo atributo

	$X_1$	$X_2$	...	$X_{k_i-1}$
Nível 1	1	0	...	0
Nível 2	0	1	...	0
...	...	...	...	...
Nível $k_i - 1$	0	0	...	1
Nível $k_i$	0	0	...	0

O vetor solução  $\hat{\beta}$  é encontrado através da relação:

$$\hat{\beta} = (XX)^{-1} XU$$

A partir do vetor de coeficientes de regressão estimados  $\hat{\beta}$ , calculam-se as utilidades parciais ( $\alpha_{ij}$ ) para os atributos considerados no experimento. Os cálculos são feitos através de  $n$  sistemas, onde as equações são contrastes das utilidades parciais em relação ao nível base do fator, como segue:

Fator 1	Fator 2	...	Fator n
$\alpha_{11} - \alpha_{1k_1} = b_{11}$	$\alpha_{21} - \alpha_{2k_2} = b_{21}$		$\alpha_{n1} - \alpha_{nk_n} = b_{n1}$
$\alpha_{12} - \alpha_{1k_1} = b_{12}$	$\alpha_{22} - \alpha_{2k_2} = b_{22}$		$\alpha_{n2} - \alpha_{nk_n} = b_{n2}$
$\vdots$	$\vdots$		$\vdots$
$\alpha_{1(k_1-1)} - \alpha_{1k_1} = b_{1(k_1-1)}$	$\alpha_{2(k_2-1)} - \alpha_{2k_2} = b_{2(k_2-1)}$		$\alpha_{n(k_n-1)} - \alpha_{nk_n} = b_{n(k_n-1)}$
$\alpha_{11} + \alpha_{12} + \dots + \alpha_{1k_1} = 0$	$\alpha_{21} + \alpha_{22} + \dots + \alpha_{2k_2} = 0$		$\alpha_{n1} + \alpha_{n2} + \dots + \alpha_{nk_n} = 0$

onde,

$\alpha_{ij}$  = utilidade parcial associada ao  $j$ -ésimo ( $j=1,2,\dots, k_i$ ) nível do  $i$ -ésimo fator ( $i=1,2,\dots,n$ )

$b_{ij}$  = coeficiente de regressão estimado, associado ao  $j$ -ésimo nível ( $j=1,2,\dots, k_i-1$ ) do  $i$ -ésimo atributo ( $i=1,2,\dots,n$ )

$k_i$  = Número de níveis do fator  $i$  ( $i=1,2,\dots,n$ )

### 3.3.1 - O Modelo de ANOVA e o Modelo de Regressão

Como já foi dito no início do trabalho, Análise Conjunta de Atributos está intimamente relacionada com a área de planejamento de experimentos. Façamos, então, uma conexão entre os modelos de análise de variância e o modelo de regressão com variáveis *dummy*. Para tanto, vamos admitir um experimento envolvendo 2 fatores com 3 níveis cada, o que caracteriza um experimento fatorial  $3^2$ . A tabela 3.3 apresenta a descrição dos fatores e seus níveis.

Tabela 3.3 - Descrição dos fatores e seus níveis

Fator	Níveis
A	1,2,3
B	1,2,3

O modelo de análise de variância e o modelo de regressão são apresentados a seguir:

*Modelo de análise de variância*

$$U_{ij} = \mu + \tau_i + \gamma_j + \varepsilon_{ij}$$

onde,

$U_{ij}$  = Preferência associada ao  $j$ -ésimo nível do  $i$ -ésimo fator

$\mu$  = Média geral do experimento

$\tau_i$  = Efeito do  $i$ -ésimo nível do fator A

$\gamma_j$  = Efeito do  $j$ -ésimo nível do fator B

$\varepsilon_{ij}$  = Erro aleatório associado a preferência  $U_{ij}$

*Modelo de Regressão com variáveis indicadoras*

$$U_{ij} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_4 X_4$$

onde;

$U_{ij}$  = preferência associada ao  $j$ -ésimo nível do  $i$ -ésimo fator

$\beta_i$  = coeficientes de regressão estimados através do método dos mínimos quadrados

$X_i$  = variáveis indicadoras com a seguinte codificação:



A descrição das variáveis indicadoras é apresentada na tabela 3.4. Observe que o nível 3 de cada fator é assumido como base.

Tabela 3.4 – Codificação das variáveis  $X_i$

Variáveis	Fator A		Fator B	
	Nível 1	Nível 2	Nível 1	Nível 2
X1	1	0	0	0
X2	0	1	0	0
X3	0	0	1	0
X4	0	0	0	1

Para determinar a correspondência entre os parâmetros  $\tau_i$  e  $\gamma_i$  do modelo de análise de variância com os parâmetros  $\beta_i$  da regressão, iremos fixar valores para os  $X_i$ 's:

- Fixando:  $X_1 = 1$ ;  $X_2 = 0$ ;  $X_3 = 0$ ;  $X_4 = 0$ , encontramos as relações:

$$U_{11} = \mu + \tau_1 \quad \therefore \quad U_{11} = \beta_0 + \beta_1$$

de onde obtemos,

$$\beta_0 + \beta_1 = \mu + \tau_1$$

- Fixando:  $X_1 = 0$ ;  $X_2 = 1$ ;  $X_3 = 0$ ;  $X_4 = 0$ , encontramos as relações:

$$U_{12} = \mu + \tau_2 \quad \therefore \quad U_{12} = \beta_0 + \beta_2$$

de onde obtemos,

$$\beta_0 + \beta_2 = \mu + \tau_2$$

- Fixando:  $X_1 = X_2 = X_3 = X_4 = 0$ , encontramos a relação com  $\beta_0$ :

$$\mu + \tau_3 + \gamma_3 = \beta_0$$

desta forma é possível escrever os parâmetros  $\beta_i$  como função dos efeitos fatoriais:

$$\begin{aligned}
 \beta_1 &= \mu + \tau_1 - \beta_0 = \\
 &= \mu + \tau_1 - (\mu + \tau_3 + \gamma_3) = \\
 &= \mu + \tau_1 - \mu - \tau_3 - \gamma_3 =
 \end{aligned}$$

logo,

$$\beta_1 = \tau_1 - \tau_3$$

Através do mesmo procedimento é possível determinar todos os relacionamentos entre os parâmetros.

$$\beta_2 = \tau_2 - \tau_3 \quad \beta_3 = \gamma_1 - \gamma_3 \quad \beta_4 = \gamma_2 - \gamma_3$$

Os parâmetros  $\beta_i$  são contrastes dos efeitos fatoriais em relação ao nível base. Os efeitos, por sua vez, nada mais são do que as utilidades parciais. Para encontrar os valores desses parâmetros é preciso resolver o sistema de equações composto pelos contrastes, acrescido da restrição de que a soma dos efeitos dentro de um mesmo fator seja nula.

Vejam os sistemas de equações para encontrar os efeitos fatoriais nesse experimento:

$$\begin{array}{ll}
 \tau_1 - \tau_3 = \beta_1 & \gamma_1 - \gamma_3 = \beta_3 \\
 \tau_2 - \tau_3 = \beta_2 & \therefore \gamma_2 - \gamma_3 = \beta_4 \\
 \tau_1 + \tau_2 + \tau_3 = 0 & \gamma_1 + \gamma_2 + \gamma_3 = 0
 \end{array}$$

Os efeitos fatoriais  $\tau_i$  e  $\gamma_i$  ( $i=1,2,3$ ) são as utilidades parciais dos fatores A e B, respectivamente.

Através da Análise Conjunta de Atributos é possível gerar modelos para predição de preferências a nível individual, pois é realizada uma análise de regressão sobre as preferências de cada respondente e, conseqüentemente, são obtidos escores de preferência para cada indivíduo. A maioria das outras técnicas multivariadas requerem uma simples medida de

preferência e então desenvolvem um modelo comum para todos respondentes. A precisão do modelo, também pode ser feita a nível individual. Sem dúvida, esta é uma importante diferença em relação a maioria das outras técnicas multivariadas. Para se obter um resultado global, é usual trabalhar com a média das utilidades parciais individuais.

### 3.4 - VALIDADE DO MODELO

Um modelo será válido se possuir uma habilidade preditiva satisfatória. Vários procedimentos são descritos na literatura para indicar o ajuste do modelo aos dados.

Uma maneira simples e muito utilizada é a correlação entre as preferências observadas e as previstas pelo modelo. O modelo será válido se os valores dos coeficientes forem grandes em magnitude e tiverem significância estatística. Os coeficiente de correlação  $\rho$  de Spearman e  $\tau$  de Kendall são indicados para escalas de ordenamento por postos. Para escalas métricas, o coeficiente  $R$  de Pearson pode ser utilizado, desde que o método de estimação utilizado seja o de regressão.

Outra maneira de se obter uma medida de ajuste quando for utilizada a análise de regressão, é avaliar o coeficiente de determinação do modelo ( $R^2$ ). Modelos com baixo  $R^2$  serão considerados não satisfatórios.

Muitas vezes o número de parâmetros é próximo do número de perfis em estudo, o que faz as correlações serem altas de uma forma um pouco artificial. Devido a isso, muitos pesquisadores incluem no experimento alguns perfis que serão utilizados unicamente para obtenção de uma medida de ajuste do modelo. Eles são chamados de perfis de validação (*holdout*) e serão avaliados pelos respondentes, mas não serão utilizados no cálculo das

estimativas das utilidades parciais. O ajuste do modelo poderá ser verificado através da correlação entre a preferência observada e a predita pelo modelo para os perfis de validação. Entretanto, deve ficar claro que os perfis de validação irão sempre produzir coeficientes de correlação mais baixos (SPSS Categories, 1994).

### **3.5 – ANÁLISE CONJUNTA DE ATRIBUTOS HÍBRIDA**

Existe dois métodos de conduzir a Análise Conjunta de Atributos: o primeiro é chamado de regular ou tradicional, e o segundo é chamado de híbrido. O tradicional é o método que estamos apresentando nesse trabalho e, como vimos, está baseado em uma técnica de decomposição que deriva um conjunto de utilidades para todos os níveis de atributos definidos, em perfis escolhidos por um delineamento específico. O método híbrido não contempla apenas os termos do método tradicional, mas também um termo derivado das reações auto-explicadas dos respondentes para um conjunto de atributos e seus níveis.

Na abordagem híbrida, os respondentes avaliam um número limitado de perfis (geralmente inferior a nove), de forma que diferentes grupos avaliam conjuntos de perfis distintos, até que todos os perfis de interesse tenham sido avaliados. Os respondentes também avaliam diretamente a importância relativa de cada atributo e o desejo pelos níveis de cada atributo. Combinando esses resultados é possível estimar um modelo a nível agregado e conservar algumas diferenças individuais.

O modelo híbrido pode simplificar a tarefa de coleta de dados e estimar, além dos efeitos principais, interações selecionadas. Entretanto, mesmo possuindo algumas vantagens, ainda não é muito popular. Para maiores detalhes, ver Green, Goldberg e Montemayor (1981).

## 4 – APLICAÇÕES DA TÉCNICA

### 4.1 – ENTENDENDO ESTRUTURAS DE PREFERÊNCIA

Através da Análise Conjunta de Atributos, o pesquisador pode identificar a importância relativa de cada variável preditora e identificar como seus níveis afetam a opinião de consumidores. O conhecimento da forma como os consumidores desenvolvem preferências pode ser imprescindível no lançamento de um novo produto ou serviço.

Através de exemplos numéricos, buscaremos apresentar ao leitor os princípios e cálculos envolvidos na técnica.

#### 4.1.1 – Exemplo – Empresa HATCO (Hair et al, 1995)

Suponha que a empresa HATCO deseja entender como a combinação de alguns atributos afetam a escolha de compra no mercado de comida para cães. As variáveis de interesse são apresentadas na tabela 4.1.

*Tabela 4.1 – Descrição dos atributos e seus níveis*

<i>Fator</i>	<i>Níveis</i>
Nome da marca	Arf <sup>1</sup> Mr. Dog <sup>2</sup>
Ingredientes	Pura carne <sup>1</sup> Carne com fibras <sup>2</sup>
Tamanho do pacote	170g <sup>1</sup> 340g <sup>2</sup>

As três variáveis são facilmente comunicáveis e familiares aos proprietários dos cães que participarão do experimento. Como trata-se de um típico experimento fatorial  $2^3$ , oito combinações de tratamentos podem ser construídas.

O simples modelo aditivo, apresentado abaixo, representará a preferência por um determinado perfil, pois o pesquisador estará assumindo a inexistência de efeitos de interação entre as variáveis.

$$\text{Preferência} = \text{Efeito da Marca} + \text{Efeito dos ingredientes} + \text{Efeito do tamanho}$$

O método utilizado para apresentação dos tratamentos será o de perfil completo e a construção dos tratamentos será feita através de um delineamento fatorial completo. Os oito perfis que serão apresentados aos respondentes são descritos na tabela 4.2:

*Tabela 4.2 -- Descrição dos perfis*

Número do Perfil	Descrição do produto		
	Tamanho	Ingredientes	Marca
1	170g	Carne pura	Arf
2	170g	Carne pura	Mr. Dog
3	170g	Carne e fibras	Arf
4	170g	Carne e fibras	Mr. Dog
5	340g	Carne pura	Arf
6	340g	Carne pura	Mr. Dog
7	340g	Carne e fibras	Arf
8	340g	Carne e fibras	Mr. Dog

A escala de medida de preferência a ser utilizada é a de ordenamento por postos, implicando que os respondentes terão a tarefa de ordenar os perfis de 1 (mais preferido) até 8 (menos preferido). Na tabela 4.3 estão as respostas fornecidas por dois respondentes.




Tabela 4.3 – Ordenação por postos realizada pelos respondentes

Número do Perfil	Vetores de preferência - $U(X)$	
	Respondente 1	Respondente 2
1	1	1
2	2	2
3	5	6
4	6	5
5	3	4
6	4	3
7	7	7
8	8	8

A utilidade total  $U(X)$  de um perfil será dada pelo seguinte modelo:

$$U(X) = \alpha_{11}x_{11} + \alpha_{12}x_{12} + \alpha_{21}x_{21} + \alpha_{22}x_{22} + \alpha_{31}x_{31} + \alpha_{32}x_{32} \quad (18.25)$$

Para estimar as utilidades parciais através da regressão múltipla com variáveis *dummy* é necessário, em primeiro lugar, estimar os parâmetros  $\beta$  do modelo de regressão, através do modelo:

$$U = X\beta + \varepsilon$$

Na forma matricial, a estrutura do modelo para esse exemplo é a seguinte:

$$\begin{bmatrix} u_1 \\ u_2 \\ u_3 \\ u_4 \\ u_5 \\ u_6 \\ u_7 \\ u_8 \end{bmatrix} = \begin{bmatrix} 1 & x_{111} & x_{211} & x_{311} \\ 1 & x_{112} & x_{212} & x_{312} \\ 1 & x_{113} & x_{213} & x_{313} \\ 1 & x_{114} & x_{214} & x_{314} \\ 1 & x_{115} & x_{215} & x_{315} \\ 1 & x_{116} & x_{216} & x_{316} \\ 1 & x_{117} & x_{217} & x_{317} \\ 1 & x_{118} & x_{218} & x_{318} \end{bmatrix} \times \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \end{bmatrix}$$

Observe que temos 8 perfis ( $p=8$ ), quatro coeficientes de regressão ( $t+1=4$ ) e três variáveis indicadoras  $x_i$  ( $t=3$ ) – uma para cada fator.

As codificações utilizadas para as variáveis indicadoras  $x_{ijk}$  e os índices  $(i, j, k)$  são apresentados na tabela 4.4.

Tabela 4.4 – Codificação das variáveis dummy

Tamanho ( $i = 1$ )	$x_{ijk}$	Ingredientes ( $i = 2$ )	$x_{ijk}$	Marca ( $i = 3$ )	$x_{ijk}$
170g ( $j=1$ )	1	Carne pura ( $j=1$ )	1	Arf ( $j=1$ )	1
340g ( $j=2$ )	0	Carne e fibras ( $j=2$ )	0	Mr. Dog ( $j=2$ )	0

Índice para o número do perfil:  $k = 1, 2, \dots, 8$

Utilizando a codificação acima para a matriz  $X$ , temos a seguinte estrutura para o respondente número 1.

$$\begin{bmatrix} 1 \\ 2 \\ 5 \\ 6 \\ 3 \\ 4 \\ 7 \\ 8 \end{bmatrix} = \begin{bmatrix} 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 0 \\ 1 & 1 & 0 & 1 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{bmatrix} \times \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \end{bmatrix}$$

$$\hat{U} = X \times \hat{\beta}$$

Pelo método dos mínimos quadrados, o vetor  $\hat{\beta}$  é estimado por:

$$\hat{\beta} = (X'X)^{-1} X'U$$

Resolvendo o sistema, chegamos ao seguinte vetor solução  $\hat{\beta}$ :

$$\hat{\beta} = \begin{bmatrix} +8 \\ -2 \\ -4 \\ -1 \end{bmatrix}$$



Os cálculos das utilidades parciais são feitos através de três sistemas, onde as equações são contrastes em relação ao nível base de cada fator, como segue:

<i>Fator 1</i>	<i>Fator 2</i>	<i>Fator 3</i>
$\alpha_{11} - \alpha_{12} = b_1$	$\alpha_{21} - \alpha_{22} = b_2$	$\alpha_{31} - \alpha_{32} = b_3$
$\alpha_{11} + \alpha_{12} = 0$	$\alpha_{21} + \alpha_{22} = 0$	$\alpha_{31} + \alpha_{32} = 0$

Substituindo os  $b_i$  ( $i=1,2,3$ ) pelo vetor solução  $\hat{\beta}$  encontrado, temos os seguintes sistemas:

<i>Fator 1: Tamanho</i>	<i>Fator 2: Ingredientes</i>	<i>Fator 3: Marca</i>
$\alpha_{11} - \alpha_{12} = -2$	$\alpha_{21} - \alpha_{22} = -4$	$\alpha_{31} - \alpha_{32} = -1$
$\alpha_{11} + \alpha_{12} = 0$	$\alpha_{21} + \alpha_{22} = 0$	$\alpha_{31} + \alpha_{32} = 0$

As utilidades parciais estimadas para os três fatores são as seguintes:

<i>Fator 1: Tamanho</i>	<i>Fator 2: Ingredientes</i>	<i>Fator 3: Marca</i>
170g $\alpha_{11} = -1$	Pura carne $\alpha_{21} = -2$	Arf $\alpha_{31} = -0,5$
300g $\alpha_{12} = 1$	Carne e fibras $\alpha_{22} = 2$	Mr. Dog $\alpha_{32} = +0,5$

A importância de cada fator,  $I_i$  ( $i=1,2,3$ ) pode ser computada diretamente e será representada pela amplitude das utilidades parciais dentro de cada fator.

<i>Fator 1: Tamanho</i>	<i>Fator 2: Ingredientes</i>	<i>Fator 3: Marca</i>
$I_1 = \text{Máx}(\alpha_{1j}) - \text{Min}(\alpha_{1j})$	$I_2 = \text{Máx}(\alpha_{2j}) - \text{Min}(\alpha_{2j})$	$I_3 = \text{Máx}(\alpha_{3j}) - \text{Min}(\alpha_{3j})$
$I_1 = 1 - (-1) = 2$	$I_2 = 2 - (-2) = 4$	$I_3 = 0,5 - (-0,5) = 1$

Essa importância é padronizada através da divisão pelo somatório de  $I_i$ . Assim obtemos a importância relativa de cada fator em relação aos demais:

$$\sum_{i=1}^3 I_i = 2 + 4 + 1 = 7$$

<i>Fator 1: Tamanho</i>	<i>Fator 2: Ingredientes</i>	<i>Fator 3: Marca</i>
$W_1 = \frac{2}{7} = 28,57\%$	$W_2 = \frac{4}{7} = 57,14\%$	$W_3 = \frac{1}{7} = 14,29\%$

Como vimos, Análise Conjunta de Atributos baseia-se num modelo que decompõe a preferência em utilidades parciais. Se, através do modelo, for possível reproduzir a preferência (nesse caso, os postos) do respondente, chegaremos a conclusão de que o modelo está bem ajustado, e os resultados serão válidos. A tabela 4.5 apresenta os resultados. Observe que valores negativos indicam maior preferência, pois o *rank* 1 foi utilizado para o perfil de maior preferência.

*Tabela 4.5 – Utilidades e postos preditos para o primeiro respondente*

<i>Descrição do Perfil</i>			<i>Valores preditos</i>	
<i>Tamanho</i>	<i>Ingredientes</i>	<i>Marca</i>	<i>Utilidade total</i>	<i>Posto predito</i>
170g (-1)	Carne pura (-2)	Arf (-0,5)	-3,5	1
170g (-1)	Carne pura (-2)	Mr. Dog (+0,5)	-2,5	2
170g (-1)	Carne e fibras (+2)	Arf (-0,5)	+0,5	5
170g (-1)	Carne e fibras (+2)	Mr. Dog (+0,5)	+1,5	6
340g (+1)	Carne pura (-2)	Arf (-0,5)	-1,5	3
340g (+1)	Carne pura (-2)	Mr. Dog (+0,5)	-0,5	4
340g (+1)	Carne e fibras (+2)	Arf (-0,5)	+2,5	7
340g (+1)	Carne e fibras (+2)	Mr. Dog (+0,5)	+3,5	8

↳ O demandante as utilidades mais de cada perfil, onde 1º mais (-) mais preferido.

O modelo reproduziu literalmente as respostas do 1º respondente, indicando um bom ajustamento. Uma das medidas de adequacidade do modelo é o coeficiente de correlação de Pearson ( $r^2$ ) entre os postos informados pelo respondente e os preditos. Neste caso o coeficiente indicou ajuste perfeito ( $r^2 = 1$ ).

Análise Conjunta de Atributos estima modelos a nível individual. Se utilizássemos o mesmo procedimento para o 2º respondente, chegaríamos a outro modelo destinado a prever sua preferência. Para um resultado global, o usual é trabalhar com as médias das utilidades parciais.

Apenas para efeito de interpretação dos resultados, vamos admitir que o 1º respondente representa muito bem a população de proprietários de cães de uma determinada região. Poderíamos chegar as seguintes conclusões: o atributo que mais afeta a preferência desses proprietários por uma ou outra comida para cães é o ingrediente. Há maior preferência por carne pura do que carne com fibras. O segundo atributo em importância é o tamanho do pacote: o de 170g é preferido. A marca da comida pouco afeta a escolha dos proprietários.

Com esses resultados é possível entender a estrutura de preferência dos proprietários em relação a comida de seus cães, o que poderá ser útil na área de publicidade e também no lançamento de novos produtos. A empresa HATCO poderá concentrar sua produção em produtos a base de carne pura acondicionados em pacotes pequenos. Quanto a marca, tanto faz chamar de Arf ou Mr. Dog, pois os consumidores provavelmente darão pouca importância a ela.

## 4.2 – SEGMENTAÇÃO DE MERCADO

Análise Conjunta de Atributos é um método de mensuração de preferência muito útil para a segmentação de mercado e posicionamento de produtos (Green e Krieger, 1991), dois assuntos de extrema importância e muito discutidos na área de marketing.

As idéias básicas da segmentação de mercado, de acordo com Green e Krieger (1991) são as seguintes:

- Pressuposição da existência de heterogeneidade na preferência de compradores por produtos ou serviços.
- A heterogeneidade na preferência por produtos ou serviços pode ser relacionada à variáveis pessoais (características demográficas, psicográficas, etc.).
- Empresas podem reagir à heterogeneidade na preferência promovendo modificações em seus produtos correntes.
- A modificação dos produtos de uma empresa inclui decisões de adição e retirada de produtos da linha de produção e seu reposicionamento no mercado.

Existem dois grandes motivos para a utilização da Análise Conjunta de Atributos em estudos de segmentação de mercado. Primeiro, a técnica está diretamente focalizada sobre a preferência de compradores por produtos ou serviços. Segundo, as funções de utilidades parcial são mensuradas a nível individual, significando que é possível contar com medidas individuais de preferência para todos atributos e seus níveis.

Utilizando informações sobre as características demográficas dos respondentes, o pesquisador poderá identificar perfis de consumidores dentro de grupos com utilidades parciais similares.

Em termos de metodologia, segmentações baseadas em técnica de análise de agrupamento (*cluster analysis*) são bastante utilizadas. A maioria dos estudos de segmentação de mercado na área comercial empregam técnicas de agrupamento não hierárquicas para agrupar consumidores.

#### 4.2.1 - Exemplo - Indústria de Automóveis

Assuma que uma indústria automotora está estudando o lançamento de um novo carro. Atualmente existe uma grande preocupação no setor com questões ecológicas, principalmente com a futura escassez do petróleo. Vários projetos de carros que utilizam energia alternativa já foram apresentados, entretanto por questões políticas não foram implantados.

O público-alvo dessa indústria são as classes média-alta e alta, que estão acostumadas com carros potentes. A empresa deseja descobrir se os consumidores estariam dispostos a abrir mão da potência por um carro que apresentasse um consumo de combustível menor, mas mantivesse o alto padrão de luxo dos carros potentes. Na realidade, ela deseja saber se a mentalidade dos consumidores está sofrendo mudanças.

Desta forma, a empresa tem interesse em três variáveis: a potência, o consumo e o preço do automóvel. Os níveis escolhidos foram os seguintes:

Potência (em cilindradas)	: 1600cc; 2000cc; 3000cc
Consumo médio por litro	: 8km/lt; 11km/lt; 14km/lt;
Preço	: \$14000; \$17000; \$20000

Há suspeitas de que exista diferença na preferência de acordo com a classe social. Para isso, a empresa realizou o experimento com um grupo de 10 pessoas escolhidas aleatoriamente de forma a representar as classes sociais A e B de uma certa população de consumidores.

Os perfis foram apresentados em entrevista pessoal através de cartões. Foi utilizado o método perfil completo e, como são possíveis construir 27 tratamentos (3x3x3), utilizou-se um fracionamento para reduzir o número de tratamentos a nove. A tabela 4.6 descreve os perfis que foram apresentados:

*Tabela 4.6 – Perfis apresentados aos respondentes*

Perfil	Potência	Consumo	Preço
1	3000	8km/lt	\$14000
2	3000	11km/lt	\$17000
3	3000	14km/lt	\$20000
4	2000	8km/lt	\$20000
5	2000	11km/lt	\$14000
6	2000	14km/lt	\$17000
7	1600	8km/lt	\$17000
8	1600	11km/lt	\$20000
9	1600	14km/lt	\$14000

Foi utilizada uma escala ordinal, implicando que os respondentes assinalaram sua pretensão de compra para cada perfil numa escala de 1 a 100. Altos escores indicarão grande pretensão de compra. Vejamos na tabela 4.7, a caracterização dos respondentes e suas respostas:

*Tabela 4.7 – Caracterização dos dez respondentes e suas avaliações*

N	Sexo	Classe	Perfil 1	Perfil 2	Perfil 3	Perfil 4	Perfil 5	Perfil 6	Perfil 7	Perfil 8	Perfil 9
1	M	A	70	75	80	10	10	20	1	1	50
2	M	B	60	45	10	1	80	20	10	1	90
3	F	B	75	50	20	10	85	25	15	10	95
4	F	A	100	100	100	70	70	70	10	10	50
5	F	A	60	70	80	35	45	55	20	30	40
6	M	A	85	90	95	75	80	85	10	25	40
7	F	B	60	50	20	1	60	55	10	1	80
8	F	B	70	40	30	1	55	35	10	1	100
9	M	B	80	70	30	10	60	55	10	20	80
10	M	A	70	80	90	30	40	50	10	10	10

Aplicando a técnica de Análise Conjunta de Atributos, como mostrado no exemplo anterior, chegamos as estimativas das utilidades parciais para os níveis dos fatores utilizados no experimento. Lembre-se que agora valores altos indicarão alta preferência. A tabela 4.8 mostra os resultados:

Tabela 4.8 – Utilidades parciais estimadas para os níveis dos atributos

N	Potência			Consumo médio			Preço		
	3000	2000	1600	8km/lt	11km/lt	14km/lt	\$14000	\$17000	\$20000
1	39,78	-21,89	-17,89	-8,22	-6,56	14,78	8,11	-3,22	-4,89
2	3,11	-1,56	-1,56	-11,56	6,78	4,78	41,44	-10,22	-31,22
3	5,56	-2,78	-2,78	-9,44	5,56	3,89	42,22	-12,78	-29,44
4	35,56	5,56	-41,11	-4,44	-4,44	8,89	8,89	-4,44	-4,44
5	21,67	-3,33	-18,33	-10	0	10	0	0	0
6	25	15	-40	-8,33	0	8,33	3,33	-3,33	0
7	5,89	1,22	-7,11	-13,78	-0,44	14,22	29,22	0,89	-30,11
8	8,67	-7,67	-1	-11	-6	17	37	-9,67	-27,33
9	13,89	-4,44	-9,44	-12,78	3,89	8,89	27,22	-1,11	-26,11
10	36,67	-3,33	-33,33	-6,67	0	6,67	-3,33	3,33	0

Se existisse heterogeneidade na pretensão de compra dos respondentes, seria possível captá-la através das utilidades parciais. Realizamos, então, uma análise de agrupamento não-hierárquica através do método *K-Means Cluster* para verificar a possibilidade de perfilar consumidores dentro de grupos com utilidades parciais homogêneas. O procedimento foi realizado no SPSS e os resultados são mostrados na tabela 4.9.

Tabela 4.9 – Classificação em grupos pelo *K-Means Cluster*

N	Grupo em que foi alocado
1	1
2	2
3	2
4	1
5	1
6	1
7	2
8	2
9	2
10	1

Como temos duas variáveis para caracterização dos indivíduos – sexo e classe social – construímos tabelas cruzadas entre elas e os grupos formados pelo *K-Means Cluster*. As tabelas 4.10 e 4.11 apresentam os resultados.

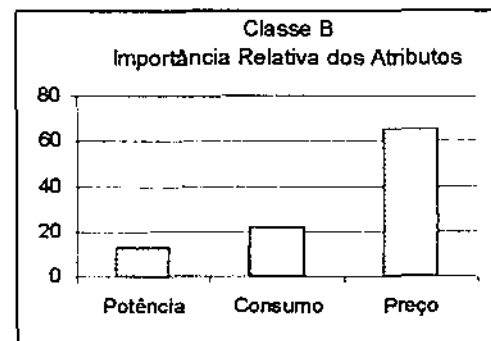

Tabela 4.10 – Tabela cruzada: Sexo X Grupos

	Grupo 1	Grupo 2	Totais
Masculino	3	2	5
Feminino	2	3	5
Totais	5	5	10

Tabela 4.11 – Tabela cruzada: Classe X Grupos

	Grupo 1	Grupo 2	Totais
Classe A	5	0	5
Classe B	0	5	5
Totais	5	5	10

Com relação a variável sexo, não é possível identificar uma diferença na pretensão de compra entre homens e mulheres. Já entre as classes sociais, existe grande diferença na preferência. Resta saber agora, qual o perfil de consumidor dentro das classes sociais, olhando para a importância relativa dos atributos média de cada grupo.



Gráficos 4.1 e 4.2 – Importância relativa dos atributos

Conforme o gráfico 4.1, para a classe A a potência do carro é o atributo mais importante. O consumo e o preço pouco influenciam na escolha.



Por outro lado, na classe B (gráfico 4.2), a potência praticamente não influi na escolha. O fator preço passa a ser o mais importante, seguido do consumo.

Baseando-se nessas informações é possível verificar que a classe A não está disposta a abrir mão de carros potentes, demonstrando indiferença quanto ao consumo de combustível e preço do carro. A classe B, provavelmente motivada por aspectos financeiros dá grande importância ao preço do carro. O consumo, que era a 'variável ecológica do experimento', ficou em segundo plano nas duas classes sociais, o que pode ser indicativo de pouca consciência ecológica no processo de escolha por um ou outro automóvel.

## 5 – UTILIZAÇÃO DE SOFTWARE

Segundo Green e Srinivasan (1990), o crescimento de aplicações da técnica de Análise Conjunta de Atributos na década de 80 teve como principal motivo a introdução de *softwares* para realização da técnica. Os mesmos autores afirmam que a disponibilidade desses programas pode facilitar a aplicação da técnica e ampliar sua utilização, porém esses mesmos *softwares* podem ser incentivadores do uso indevido.

Dentre os principais *softwares* disponíveis atualmente no mercado, destacamos os seguintes:

- *Adaptive Conjoint Analysis (ACA)* -- desenvolvido por Richard Johnson da *Sawtooth Software*.
- *Conjoint Designer, Conjoint Analyser e Conjoint LINMAP* -- um conjunto de programas desenvolvidos por Steven Herman da *Bretton-Clark Software*.
- *SAS* -- o mais poderoso e completo *software* estatístico. Possibilita a utilização da técnica através do procedimento *TRANSREG*.
- *SIMGRAF* -- um sofisticado simulador de escolhas.
- *SPSS* -- o mais difundido dos *softwares* que possibilitam a execução da técnica.

No Brasil, os *softwares* SPSS e SAS são os mais conhecidos, havendo uma preferência pelo SPSS, devido a facilidade de sua utilização e pelo maior difundimento. Esse *software* possibilita a realização de tudo que foi apresentado nos capítulos anteriores e, por isso, foi o escolhido para ser apresentado na seqüência desse texto. Utilizaremos a versão 6.1 para Windows, datada de 24 de junho de 1994. A técnica só está disponível no SPSS a partir da versão 6.0, porém o procedimento de geração de delineamentos ortogonais está disponível apenas nas versões a partir da 6.1.

### 5.1 – SPSS – MÓDULO *CATEGORIES*

SPSS *Categories* (SPSS, Inc. 1994) utiliza o método de apresentação perfil completo (*full-profile*), não podendo ser utilizado com os outros métodos. O módulo *Categories* consiste de um sistema para coleta e análise de dados. Para a coleta de dados, utiliza a abordagem de delineamentos fatoriais fracionários, que apresenta uma fração de tratamentos quando o número de combinações possíveis for muito grande. O procedimento '*Generate Orthogonal Design*' gera automaticamente planilhas que possibilitam a estimação de todos efeitos principais, enquanto que o procedimento '*Display Design*' auxilia na geração de perfis físicos que serão avaliados pelos respondentes.

O procedimento '*Conjoint*' realiza o processo de estimação através do método dos mínimos quadrados ordinários. Este comando não dispõe de interface gráfica e as instruções são dadas por sintaxe. A saída inclui a importância relativa dos atributos, as estimativas das utilidades parciais e correlações entre os escores preditos pelo modelo com os observados. Também é possível especificar perfis de validação (*holdout*), que serão úteis para validação do modelo. É possível gerar arquivos com as utilidades

parciais individuais, que poderão ser utilizados diretamente numa análise de agrupamento de indivíduos para segmentação de mercado.

Para ilustrar os procedimentos disponíveis no SPSS, iremos refazer o exemplo 4.1.1, discutindo sucintamente cada elemento de comando ou sintaxe. Relembrando: haviam três fatores com dois níveis cada, caracterizando um experimento fatorial  $2^3$ .

### 5.1.1 – Obtendo um delineamento ortogonal

Para obter um delineamento ortogonal no SPSS, o pesquisador precisa informar quais são os fatores e os respectivos níveis envolvidos no experimento. O procedimento é acionado a partir dos menus:

```
DATA
  ORTHOGONAL DESIGN ►
    GENERATE...
```

Este procedimento irá abrir a caixa de diálogo do Gerador de delineamentos ortogonais, conforme a figura 5.1.

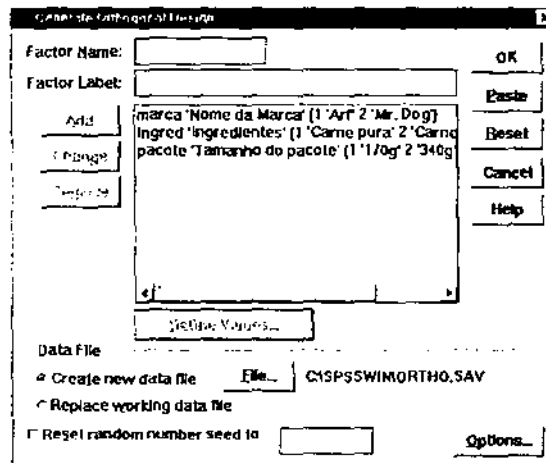


Figura 5.1 – Gerando um delineamento ortogonal

Deve-se informar o nome de cada fator (*Factor Name*) e seus respectivos rótulos (*Factor Label*), clicando em 'Add' após a definição de cada

um. Pode-se, ainda, remover ou alterar fatores através dos botões ‘*Remove*’ e ‘*Change*’, respectivamente. O pesquisador também pode especificar o nome do arquivo que conterá os tratamentos gerados. O nome padrão é ‘ortho.sav’, mas é possível alterá-lo através do botão ‘*File*’, o que é altamente recomendável. Não é aconselhável utilizar a opção ‘*Replace working data file*’, pois corre-se o risco de perder dados devido à substituição do arquivo de dados corrente pela planilha ortogonal gerada. A figura 5.2 apresenta o botão ‘*Options*’, pelo qual pode-se especificar um número mínimo de casos a serem gerados e o número desejado de perfis de validação (*holdout*).




Figura 5.2 -- Caixa de diálogo das opções para geração de delineamentos ortogonais

O pesquisador deve informar os níveis de cada fator que serão considerados no experimento, conforme exemplo na figura 5.3.

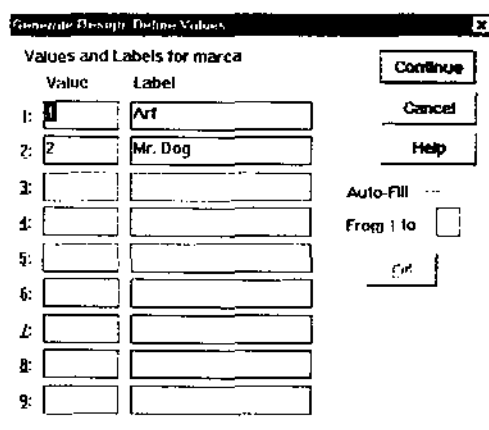


Figura 5.3 – Caixa de diálogo da definição dos níveis dos fatores

Definidos os fatores e seus níveis, o nome do arquivo a ser gerado e as opções, o pesquisador pode exibir o esquema de tratamentos

através do procedimento 'Display Design'. A figura 5.4 apresenta a caixa de diálogo deste comando.

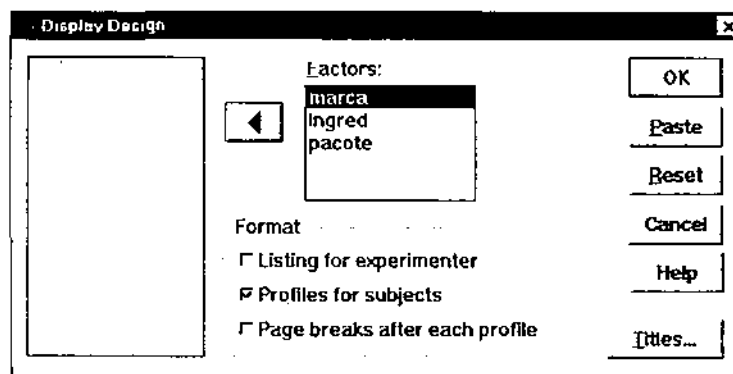


Figura 5.4 – Caixa de diálogo do procedimento Display Design

A melhor maneira de apresentar os perfis é através da opção 'Profiles for subjects', cuja saída apresenta o formato mostrado na figura 5.5.

```

Profile Number 1
Nome da marca  Arf
Ingredientes  Carne Pura
Tamanho do Pacote  170g

Profile Number 2
Nome da marca  Mr. Dog
Ingredientes  Carne Pura
Tamanho do Pacote  170g

Profile Number 3
Nome da marca  Arf
Ingredientes  Carne e fibras
Tamanho do Pacote  170g

```

Figura 5.5 – Exemplo da saída do procedimento Display Design

Este comando pode ser de grande utilidade na construção dos perfis que serão apresentados aos respondentes. Se, por algum motivo, o pesquisador deseja alterar a ordem dos perfis, isso pode ser realizado diretamente na planilha gerada, em nosso caso a planilha gerada é 'dog.sav'. Para fazer alterações deve-se clicar sobre as células com o botão direito do mouse e teclar 'Enter', conforme ilustrado na figura 5.6.

3 marca		2				
	pacote	ingred	marca	status_	card_	
1	170g	Carne Pura	Arf	Design	1	
2	170g	Carne Pura	Mr. Dog	Design	2	
3	170g	Carne e fibr	Arf	Design	3	
4	170g	Carne e fibr	Mr. Dog	Design	4	
5	340g	Carne Pura	Arf	Design	5	
6	340g	Carne Pura	Mr. Dog	Design	6	
7	340g	Carne e fibr	Arf	Design	7	
8	340g	Carne e fibr	Mr. Dog	Arf	8	
:				Mr. Dog		

Figura 5.6 - Planilha gerada pelo procedimento

Perceba que ao clicar com o botão direito do mouse sobre as células, todos os níveis daquele fator são apresentados. O mesmo procedimento pode ser adotado para definir perfis de validação (*holdout*). Clicando nas células da coluna 'status' aparecem todas as opções disponíveis:

*Design* – indica que o perfil está sendo utilizado na estimação das utilidades parciais do experimento;

*Holdout* – indica que o perfil não será utilizado no processo de estimação, mas sim para a validação do modelo.

*Simulation* – indica que o perfil não será administrado aos respondentes. Este perfil, geralmente é uma combinação de atributos, a qual o pesquisador tem interesse especial. Esse assunto não foi abordado nesse texto.

### 5.1.2 – Analisando preferências – Procedimento 'Conjoint'

Não existe interface gráfica para realização do procedimento de estimação das utilidades parciais. Os comandos devem ser fornecidos por sintaxe. A figura 5.7 apresenta os comandos apropriados ao nosso exemplo.

```

DATA LIST FREE /ID RANK1 TO RANK8.
BEGIN DATA.
01 01 02 05 06 03 04 07 08
02 01 02 06 05 04 03 07 08
END DATA.
CONJOINT PLAN='C:\SPSSWIN\DATA\DOG.SAV'
  /DATA=*
  /RANK=RANK1 TO RANK8
  /SUBJECT=ID
  /FACTORS= pacote ingred marca
  /PRINT=ALL
  /UTILITY='RUUTIL.SAV'.

```

Figura 5.7 – Comando Conjoint para o exemplo

Como é possível observar na figura 5.7, o procedimento ‘Conjoint’ necessita de muitas instruções. Primeiramente, é necessário indicar a origem dos dados através do nome do arquivo no subcomando ‘Data’. Em nosso caso indicamos com um asterisco, pois os dados foram digitados na mesma janela de sintaxe. As linhas representam o número de respondentes e as colunas o número de perfis avaliados. É necessário que a mesma ordem da planilha ortogonal gerada seja mantida, ou seja, a coluna um indica as preferências pelo primeiro perfil.

Também é necessário indicar o tipo de escala utilizada. Para escalas de ordenamento, utiliza-se o subcomando ‘Rank’ e para escalas de preferência utiliza-se o subcomando ‘Score’. Nos dois casos a estrutura da sintaxe é a mesma.

O subcomando ‘Subject’ indica a variável que está identificando os indivíduos.

O subcomando ‘Factors’ especifica o relacionamento esperado dentro dos níveis de cada fator. Por *default*, o programa assume relacionamento do tipo utilidades parciais, mas é possível indicar relacionamentos lineares e quadráticos.

Através do subcomando ‘Print’ pode-se optar em apresentar as estimativas das utilidades parciais a nível individual ou agregado. Se o



experimento envolver um número muito grande de respondentes, o mais coerente é substituir a opção *All* por *Summaryonly*.

O subcomando *'Utility'* serve para salvarmos uma planilha de dados contendo as estimativas das utilidades parciais para todos os respondentes. Esta planilha é indispensável para realização de análise de agrupamento de indivíduos, o que é muito comum em experimentos envolvendo a técnica de análise conjunta de atributos.

Vejamos, na figura 5.8, a saída obtida através do comando *'Conjoint'* para o primeiro respondente.

Importance	Utility(s.e.)	Factor	
28,57	1,0000(,0000)	PACOTE	Tamanho do Pacote
	-1,0000(,0000)		170g
			340g
157,14	2,0000(,0000)	INGRED	Ingredientes
	-2,0000(,0000)		Carne Pura
			Carne e fibras
14,29	,5000(,0000)	MARCA	Nome da marca
	-,5000(,0000)		Arf
			Mr. Dog
	4,5000(,0000)	CONSTANT	
Pearson's R	= 1,000		Significance = ,
Kendall's tau	= 1,000		Significance = ,0003

Figura 5.8 – Saída obtida para o primeiro respondente

Os resultados calculados manualmente no item 4.1.1 foram reproduzidos. A única diferença são os sinais, pois o SPSS multiplica as utilidades parciais por (-1) automaticamente. Perceba que a saída inclui duas medidas para verificação do ajuste do modelo.

A sintaxe completa do comando *'Conjoint'* encontra-se em anexo. O leitor que desejar obter maiores informações sobre a utilização da técnica, deve recorrer ao manual SPSS – Categories (1994).

## **6 – CONSIDERAÇÕES FINAIS**

Existe grande carência da utilização do conhecimento científico no ramo industrial e comercial no Brasil. Muitas vezes, importantes decisões tomadas são mais baseadas no empirismo do que na ciência. Esse fato colabora para que muito conhecimento fique limitado ao ambiente acadêmico.

Na Estatística não é diferente. Apesar de existir uma infinidade de técnicas para descrição e inferência, a maioria delas sequer são conhecidas pelo nome fora da Universidade. Sendo assim, perde o estatístico e perdem as empresas, que poderiam estar contando com uma valiosa colaboração. Por exemplo, a área de marketing de uma empresa poderia crescer muito com a inclusão de um estatístico em sua equipe.

Pois bem, Análise Conjunta de Atributos está diretamente ligada a área de marketing, podendo trazer subsídios para questões de extrema importância em qualquer empresa, principalmente quando se trata do lançamento de um novo produto ou segmentação de mercado. A simplicidade, o grau de realismo e a flexibilidade da técnica permitem que o pesquisador sinta-se bem à vontade em utilizá-la. Entretanto, todas as etapas devem ser cuidadosamente elaboradas e os resultados corretamente interpretados para que os objetivos sejam atingidos com êxito.

Os artigos utilizados como referencial bibliográfico deste texto, em especial Cattin e Wittink (1989), apontam para uma utilização crescente da técnica nos Estados Unidos. Os estudos têm sido utilizados para identificação de novos produtos potenciais, análise competitiva, colocação de preços em produtos, segmentação de mercado, reposicionamento de produtos e publicidade.

Existe consenso de que a Análise Conjunta de Atributos é uma poderosa e importante ferramenta para Pesquisa de Mercado, contudo existem algumas discussões envolvendo sua fundamentação conceitual. Como vimos, existe a suposição de que a utilidade total de um produto ou serviço pode ser decomposta em utilidades separadas para as características que o compõem. Algumas pessoas não concordam com essa visão do processo de formação de utilidade, o que é perfeitamente aceitável, porque mensurar o comportamento de pessoas nunca foi uma tarefa considerada fácil. Entretanto, a teoria descrita nesse texto é adotada e aceita pela maioria dos autores.

O fato da fundamentação metodológica da técnica estar intimamente relacionada com a área de planejamento de experimentos, dá ainda mais segurança ao pesquisador.

Consciente de que sua utilização pode auxiliar no processo de tomada de decisões de empresas, esperamos que a Análise Conjunta de Atributos venha a ser um instrumento útil nas mãos de pesquisadores da área de marketing de muitas empresas brasileiras.

## **7 - ANEXOS**

## Conjoint Syntax - SPSS Inc. 1994

```

CONJOINT [PLAN={ * }]
           {file}
[/DATA={ * }]
           {file}
/{SEQUENCE}=varlist
  {RANK      }
  {SCORE     }
[/SUBJECT=variable]
[/FACTORS=varlist['labels']]
  ({{DISCRETE[{{MORE}}]}}[values['labels']]])
  {LESS}
  {LINEAR[{{MORE}}] }
  {LESS}
  {IDEAL          }
  {ANTIIDEAL     }
  varlist...
[/PRINT={ALL** } [SUMMARYONLY] ]
  {ANALYSIS }
  {SIMULATION}

  {NONE      }
[/UTILITY=file]
[/PLOT={SUMMARY}]
  {SUBJECT}
  {ALL      }
  {NONE**  }

```

\*\*Default if the subcommand is omitted.

## 8 – BIBLIOGRAFIA

- BOHL, Patrick (1997). Conjoint Literature Database CLD, University of Mainz, Germany [<http://www.uni-mainz.de/~bohlp/cld.html>]
- CATTIN, Philippe; WITTINK, Dick (1982). Commercial use of Conjoint Analysis: A Survey . *Journal of Marketing*. v. 46 (Summer), p. 44-53.
- CATTIN, Philippe; WITTINK, Dick (1989). Commercial use of Conjoint Analysis: An Update . *Journal of Marketing*. v. 53, p. 91-96 (Julho).
- DEAN, Edwin B. Conjoint Analysis: from the Perspective of Competitive Advantage, [<http://akao.larc.nasa.gov/dfc/ppt/cja.html>]
- GREEN, Paul E.; RAO, Vithala R. (1971). Conjoint Measurement for Quantifying Judgment Data. *Journal of Marketing Research*. v. VIII (Agosto), p. 355-363.
- GREEN, Paul E.; WIND, Yoram (1975). New way to measure consumers' judgments. *Harvard Business Review*. v. 53 (Jul-Ago), p. 107-117.
- GREEN, Paul E.; GOLDBERG, S. M.; MONTEMAYOR, M. (1981). A Hybrid Utility Estimation Model for Conjoint Analysis. *Journal of Marketing*. v. 45 (Winter), p. 33-41.

- GREEN, Paul E.; SRINIVASAN, V. (1990). Conjoint Analysis in Marketing: new developments with implications for research and practice. *Journal of Marketing*. v. 54 (Outubro), p. 3-19.
- GREEN, Paul E.; KRIEGER, Abba M. (1991). Segmenting Markets with Conjoint Analysis. *Journal of Marketing*. v. 55 (Outubro), p. 20-31.
- HAIR, J.F.; Anderson R.E.; Tatham, R.L & Black, W. C. (1995). *Multivariate Data Analysis: with readings*. 4<sup>a</sup> ed. Englewood Cliffs, NJ: Prentice Hall.
- JOHNSON, Richard M. (1974). Trade-Off Analysis of Consumer Values. *Journal of Marketing Research*. v. IX (Maio), p. 121-127.
- KAMAKURA, Wagner (1988). A Least Squares Procedures for Benefit Segmentation with Conjoint Experiments. *Journal of Marketing Research*. v. 25 (Maio), p. 157-167.
- LOUVIERE, Jordan J. (1994). *Conjoint Analysis*. In: BAGOZZI, Richard (org). *Advanced methods of marketing research*. Oxford: Basil Blackwell, p. 223-259.
- LUCE, R. Duncan; TUKEY, John W. (1964). Simultaneous Conjoint Measurement: A New Type of Fundamental Measurement. *Journal of Mathematical Psychology*. (Fevereiro), p. 1-27.
- MALHOTRA, Nareesh K. (1996). *Marketing Research: an applied orientation*. 2 ed. New Jersey: Prentice Hall.
- MANGEN, David J. (1997). An Alternate Method for Collecting Conjoint Data. Minneapolis: MRA Inc. World Wide Web, <http://www.mrainc.com>

RIBOLDI, João (1994) *Planejamento e Análise de Experimentos (Parte 1)*.  
Cadernos de Matemática e Estatística – Instituto de Matemática – UFRGS.  
Série B, n. 23.

SAS Institute Inc. The SAS System – Manual vol. 2. Cary: 1993.

SPSS Inc. SPSS Categories 6.1 – Chicago: 1994.