**Modelando o efeito da omissão
de atributos em um estudo de
análise de preferência conjunta**

Karina Pretto

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

Área de Concentração: **Estatística**
Orientador: **Prof. Dr. Rinaldo Artes**

São Paulo, maio de 2007.

**Modelando o efeito da omissão
de atributos em um estudo de
análise de preferência conjunta**

Este exemplar corresponde à redação
final da dissertação devidamente corrigida
e defendida por Karina Pretto
e aprovada pela comissão julgadora.

São Paulo, maio de 2007.

Comissão Julgadora:

- Profa. Dr. Rinaldo Artes (orientador) - Ibmec, SP
- Prof. Dra. Lucia Pereira Barroso - IME, USP
- Prof. Dra. Maria Aparecida Gouvea- FEA, USP

*Aos meus pais, Pedro e Deiane
à minha irmã Natália,
aos meus amigos
e ao meu namorado Fernando.*

Agradecimentos

Agradeço, em primeiro lugar, aos professores Rinaldo Artes e Lúcia Pereira Barroso pela orientação, conselhos e pelos ensinamentos transmitidos durante o mestrado. Lembrarei com muito carinho de toda a atenção que recebi de vocês. Agradeço também as importantes sugestões da professora Maria Aparecida Gouvea, integrante da comissão julgadora desta dissertação, que enriqueceram ainda mais este trabalho. Agradeço aos professores do IME/USP pela oportunidade de me desenvolver e expandir meus conhecimentos em estatística. Agradeço aos colegas de mestrado e companheiros de estudo pela paciência, respeito e incentivo que recebi em todos os momentos. Muito obrigada Cíntia, Noemi, Betsabe, Núbia, Paula, Augusto, Pedro, Josivon, Joan, Cristian, Ivan, Marcos, Carlos, Frederico, Cléber e os demais colegas que por ventura tenha me esquecido. Agradeço especialmente às minhas amigas Mariana, Grazielle e Lauren pelo apoio, carinho, paciência, atenção e companheirismo durante o período que moramos juntas. Lembrarei sempre das tardes de estudo, das longas conversas que tivemos e de todas as experiências e aprendizados que compartilhamos. Agradeço a todos os colegas de trabalho que contribuíram na aplicação real das técnicas descritas nesta dissertação, respondendo aos questionário sobre preferências no ambiente de trabalho. Agradeço aos queridos primos Angélica e Cícero pelo incentivo, coragem, compreensão, paciência, acolhimento e força que me foi transmitido desde o primeiro dia que cheguei em São Paulo. Serei eternamente grata

por tudo o que vocês fizeram por mim. Aos meus pais Pedro e DeJane e a minha irmã, Natália, agradeço pela compreensão e pelo apoio incondicional que recebi ao tomar a decisão de cursar o mestrado no IME/USP. Agradeço ao meu namorado Fernando pelo carinho, paciência, estímulo e serenidade transmitidos em todos os momentos. Agradeço a todos aqueles que contribuíram de uma forma ou outra para a execução deste trabalho.

Resumo

A Análise de Preferência Conjunta (APC) é uma metodologia estatística bastante utilizada em estudos de comportamento do consumidor e do mercado em geral. Ela possibilita a realização de estudos sobre julgamentos individuais, tais como a aceitabilidade e preferência por um determinado produto no momento da sua aquisição (ver Artes, 1991 e Friedmann, 1998). Em um estudo de preferência conjunta, são apresentadas configurações hipotéticas de um mesmo produto, que devem ser avaliadas segundo a preferência do respondente. O julgamento de um estímulo é denominado de valor de preferência que nada mais é do que a quantificação da preferência do indivíduo por um estímulo. Quanto maior o número de atributos/níveis utilizados na caracterização de um produto, mais real será sua descrição. No entanto, a complexidade dos estímulos e o número de configurações possíveis aumenta exponencialmente a cada novo atributo ou nível acrescentado, podendo comprometer a qualidade dos resultados de uma pesquisa. Este problema é contornado através da utilização de estímulos gerados através de planejamentos fracionários combinado à omissão de um ou mais atributos nos diferentes estímulos, conhecidos como perfis incompletos. Neste trabalho, pretende-se testar o efeito da ausência de atributos na classificação de estímulos e diferentes formas de imputação da informação faltante em uma aplicação sobre o efeito de características do emprego na satisfação do funcionário.

Abstract

Conjoint Analysis is a statistic technique used in many behavior studies, product management and marketing researches. The conjoint method involves presenting customers with a test set of hypothetical products profiles and collecting their preferences. It's task is to identify some within a set of attributes those ones that are the most important for the research participants. Conjoint Analysis works better when the test set of profiles is small and the number of attributes is not so large. When a large number of attributes are considered in a conjoint study, the final number of possible profiles increase a lot. In this cases, fractional designs and incomplete profiles can be used to solve this problem. In this study will be tested the missing information effect in a conjoint study and will be compared some different imputations methods.

Índice

Agradecimentos	iv
Resumo	vi
Abstract	vii
1 Contextualização	1
1.1 Introdução	2
1.2 Antecedentes	5
1.3 Caracterização do modelo de APC	7
1.4 Definição dos atributos	9
2 Formas de Imputação	13
2.1 Perfis incompletos e imputação de dados	13
2.1.1 Imputação utilizando um valor padrão	16
2.1.2 Imputação utilizando a média	16
2.1.3 Imputação por associação	17
2.1.4 Imputação via recência	18
2.1.5 Imputação via aprendizado	19
2.2 Modelo Bayesiano	30
3 Aplicação: A Motivação no Ambiente de Trabalho	33
3.1 Propósito do estudo	33
3.1.1 Motivação	33

<i>Índice</i>	ix
3.2 A seleção dos atributos	35
3.2.1 Descrição dos atributos	36
3.2.2 Planejamento da pesquisa e apresentação dos estímulos	40
4 Estimação dos Modelos e Comparação de Métodos	45
4.1 Medidas de diagnóstico do ajuste dos modelos	46
4.1.1 Concordância entre as estimativas dos modelos	51
5 Aplicação	54
5.1 Principais resultados	54
6 Considerações finais e futuros estudos	61
A Apêndice	64
A.1 Cadeias de Markov e Algoritmo de Metropolis-Hasting	64
A.2 Rotina Computacional	66
A.3 Questionário	70
A.4 Erros de ajuste do modelo	75
A.5 Gráficos de convergência do modelo de aprendizado	76
Referências bibliográficas	79

Contextualização

A Análise de Preferência Conjunta (APC), ou “Conjoint Analysis”, é uma metodologia estatística amplamente utilizada em pesquisas de marketing cujo objetivo é identificar características (atributos) de um produto ou serviço que mais se associam com a preferência do consumidor.

Basicamente, o ponto de partida da análise é a avaliação de uma série de produtos hipotéticos (estímulos) definidos a partir de um conjunto de características (atributos).

Na grande maioria dos estudos uma quantidade excessiva de atributos são avaliados simultaneamente o que aumenta exponencialmente o número de possíveis estímulos, ou configurações hipotéticas do produto, a ser avaliado. Uma alternativa, nestes casos, é a apresentação de estímulos incompletos, ou seja, não utilizar todos os atributos do objeto em estudo na sua descrição. Assim, permite-se que o respondente julgue estímulos mais simples.

Embora o ganho de tempo e a redução no número de configurações apresentadas possam ser significativos, cabe avaliar se a apresentação de um estímulo incompleto interfere no processo de julgamento, ou seja, deve-se investigar até que ponto um atributo, mesmo ausente, interfere na avaliação do respondente.

Neste trabalho, são discutidas algumas propostas de mensuração da influência de atributos ausentes na avaliação quando estímulos incompletos são apresentados aos respondentes.

Para a leitura desta dissertação é necessário que o leitor conheça as técnicas usuais de APC e tenha noções de Estatística Bayesiana.

1.1 Introdução

A Era Industrial, iniciada no século XVII, foi marcada pelo aumento na eficiência dos métodos de produção, o que além de baratear os preços estimulou o consumo. Nesse período, a padronização e produção em massa eram as chaves do sucesso. Já em meados do século XX, o aumento da concorrência e a rápida disseminação de informação através da internet fez com que muitas empresas reestruturassem seus processos de produção em busca da satisfação e fidelização de seu cliente.

Na Era da Informação, a produção em massa cedeu lugar à produção personalizada, que utiliza informações sobre comportamentos cotidianos e de consumo para oferecer produtos e serviços que atendam tanto as necessidades quanto o desejo do consumidor. Basta observar a grande expansão da TV a cabo, que trouxe a opção de informação e entretenimento que se adapta a cada estilo de vida de seus telespectadores. Ou ainda, a diversidade de produtos eletro-eletrônicos disponíveis no comércio, que deixam a critério do consumidor a difícil missão da escolha do produto de sua preferência.

Ao oferecer um produto personalizado, ou seja, que tenha a “cara do consumidor”, as empresas procuram aproximar-se mais do seu cliente e assim se tornam mais atrativas e competitivas frente à concorrência. Nestes casos, o aumento das vendas não é o único objetivo, pois o interesse maior é formatar e oferecer um produto que conquiste a satisfação e a fidelização do cliente.

Surge assim o jogo de sedução entre vendedores e compradores que se inicia muito antes do lançamento de um novo produto no mercado, pois para identificar qual a “cara” que o produto precisa ter para diferenciar-se dos demais é preciso conhecer o cliente e entender seus hábitos de consumo, financeiros e cotidianos.

Obter informações confiáveis sobre hábitos de consumo passou a ser uma etapa fundamental no processo de fabricação de um novo produto ou formatação de um novo serviço, uma vez que os responsáveis já possuem indicativos antecipados de sucesso do seu projeto, aceitação no mercado e quão satisfeitos seus clientes estarão ao adquirir seu produto.

A utilização de pesquisas científicas sobre o comportamento do mercado consumidor talvez seja uma das práticas mais frequentes e antigas utilizadas para mensurar a preferência. Desde o início do século XX, a aplicação de questionários e utilização de medidas estatísticas básicas auxiliam no entendimento do perfil do consumidor e do

mercado. Visitas a “sites” de busca ou de vendas na internet, registros de compras em estabelecimentos comerciais, utilização de cartão de crédito, resultados de pesquisas de opinião, entre outras, são ótimas fontes de informação na pesquisa de satisfação e preferência do cliente.

Com o passar dos anos e com o desenvolvimento de novas metodologias estatísticas de análise de dados, Modelos de Regressão Múltipla, Análise de Correlação, Modelos de Planejamento de Experimentos, além das Técnicas Multivariadas, foram incorporados a estes estudos enriquecendo ainda mais este processo. A tendência atual da pesquisa em marketing aponta para estudos sobre a análise de preferência do consumidor e o processo de decisão presente no momento da compra de um bem ou contratação de um serviço (Friedmann, 1998).

Nestes casos a intenção é identificar fatores que apresentam uma maior influência na compra, ou seja, fatores capazes de, por exemplo, diferenciar um produto dos seus concorrentes a fim de torná-lo mais competitivo. Outros estudos verificam se há a presença de alguma regra de decisão implícita utilizada pelo consumidor no momento da compra, e de que forma o conhecimento a priori sobre o produto pode influenciar na sua aquisição. Seus resultados podem fornecer informações sobre a aceitabilidade do produto, suas vantagens e desvantagens frente aos concorrentes e ainda dar suporte a estudos de simulação de penetração do produto e distribuição no mercado antes mesmo da sua fabricação (Green e Savitz, 1994).

Uma técnica estatística multivariada muito utilizada neste tipo de estudo é a Análise de Preferência Conjunta (APC), também conhecida por *Conjoint Analysis*. A APC se preocupa em estimar modelos que expressem as preferências individuais de um consumidor como função de um conjunto de características pré-definidas. É possível ainda mensurar o impacto de cada uma dessas características sobre a preferência do consumidor, dado que um dos objetivos em uma análise de preferência é estimar a preferência em relação a diferentes configurações de um mesmo produto. Este produto pode ser qualquer objeto tal como um aparelho eletro-eletrônico, automóvel, alimentos, produtos de beleza, ou então, pode representar um serviço, como por exemplo a composição de um plano de saúde, forma de atendimento em uma agência bancária ou estrutura de um curso de pós-graduação.

As características que descrevem o produto em estudo são conhecidas como **atributos** ou fatores. Assim, se o produto alvo for um automóvel, a potência do motor, a

presença de direção hidráulica ou o número de portas são possíveis atributos presentes na caracterização do mesmo. As possíveis variações de um atributo, por exemplo, o número de portas (2 ou 4 portas) são denominados **níveis** de um atributo. Quando diferentes níveis de diferentes atributos são combinados, temos uma possível configuração do produto denominada **estímulo** ou **perfil**.

Para cada estímulo o respondente deve atribuir um valor que quantifica sua preferência pela configuração apresentada. Este valor é conhecido como **valor de preferência** e é resultado da combinação das preferências individuais ou **utilidades** de cada atributo. Logo, o valor de preferência por um estímulo pode ser visto como as combinações das utilidades parciais de todos os atributos. A escala de medida da preferência varia de estudo a estudo, podendo ser sob forma de uma nota, ou outra escala de preferência.

A quantidade excessiva de características ou atributos mostra-se como um dos pontos mais críticos neste tipo de estudo, pois quanto mais detalhes de um produto forem avaliados simultaneamente, um maior número de estímulos serão gerados, o que aumenta significativamente o tempo de resposta do questionário e a fadiga dos respondentes. Para contornar o número excessivo de perfis, Green et al.(1978) propõem que os delineamentos experimentais fatoriais fracionários sejam utilizados. Há situações, no entanto, em que mesmo esse artifício não consegue reduzir satisfatoriamente o número de produtos hipotéticos sendo necessária a utilização de planejamentos de experimentos fracionários combinados com a omissão de um ou mais atributos na descrição do estímulo.

Também é comum assumir que os atributos ausentes não interferem na quantificação da preferência de um estímulo, contudo vários estudos questionam tal posicionamento. Quando um atributo muito importante é omitido na descrição de um estímulo, a percepção de um indivíduo sobre o produto pode ser afetada, e conseqüentemente seu julgamento sobre a preferência também pode sofrer alterações. Por exemplo, Broniarczyk e Alba, em 1994 em seu artigo *The Role of Consumers' Intuitions in Inference Making* discutem experimentos em que os respondentes atribuíram valores de preferências distintos ao classificar um mesmo estímulo apresentado de forma completa ou incompleta, o que leva o autores a crer na influência dos demais fatores na quantificação da preferência de um atributo ausente. Feldman e Lynch, 1988, acreditam que os respondentes usem de crenças, atitudes e pré-conceitos ao avaliar

um estímulo. Assim, ao deparar-se com a omissão de um atributo, o respondente pode associar o nível ausente aos níveis dos atributos presentes.

Resta avaliar até que ponto o valor de preferência atribuído a um estímulo é afetado pela ausência de um atributo e quais são os artifícios utilizados pelos respondentes para incorporar tal informação no processo de julgamento. Neste estudo, pretende-se testar o efeito da ausência de atributos na classificação de estímulos em uma aplicação sobre o efeito de características do emprego na satisfação e motivação do funcionário. Embora o produto em estudo aqui não seja um bem de consumo, a função exercida pode muito bem ser avaliada como sendo um produto, cujo fabricante é a própria organização para a qual o empregado trabalha. Ao oferecer uma atividade composta pelos elementos de maior atratividade do funcionário, a empresa o estará motivando e estimulando a produzir mais e melhor.

A seguir, apresenta-se uma breve revisão bibliográfica descrevendo um pouco mais sobre a técnica de Conjoint Analysis e sua evolução ao longo do tempo.

O Capítulo 2 trata da problemática do número excessivo de atributos e abordam-se diferentes métodos de imputação propostos por diferentes autores, em especial uma descrição mais detalhada sobre o modelo de aprendizado proposto por Bradlow, Hu e Ho (2004) é apresentado aos leitores.

No Capítulo 3 descreve-se a seleção dos atributos de um estudo de APC realizado com um grupo de funcionários do setor financeiro sobre suas preferências no ambiente de trabalho.

O Capítulo 4 trata da comparação dos métodos de imputação utilizados no estudo, enquanto que os principais resultados da aplicação da análise de preferência conjunta são apresentados no Capítulo 5.

O Capítulo 6 traz as principais conclusões e considerações finais sobre o trabalho.

1.2 Antecedentes

Os primeiros trabalhos sobre a Análise de Preferência Conjunta (APC) e efeitos conjuntos de atributos foram publicados a partir da década de 60. Luce e Tukey (1964) apresentaram um estudo sobre o efeito conjunto de dois ou mais atributos na ordenação de estímulos. Em 1971, Green e Rao publicaram o primeiro artigo sobre medida conjunta aplicado a marketing enfatizando aspectos relativos à estimação de

um modelo de preferência. Primeiro em 1978 e depois em 1990, Green e Srinivasan descreveram as etapas fundamentais para a realização de um estudo de preferência enfatizando aspectos teóricos e práticos importantes a serem considerados neste tipo de pesquisa.

São apresentados, nesse mesmo período, estudos utilizando técnicas de *Trade-off* e *Conjoint Analysis* e os primeiros estudos com modelos com estruturas híbridas (Green, 1984), que buscam minimizar o número de estímulos respondidos pelos participantes quando um grande número de características são avaliadas simultaneamente. Isto, porque à medida que o número de características (atributos) avaliadas aumenta, o número de possíveis configurações (estímulos) também aumenta consideravelmente. Por exemplo, um estudo envolvendo três atributos, com dois níveis cada, gera oito ($2^3 = 8$) possíveis estímulos a serem avaliados. Se mais três atributos forem acrescentados neste mesmo estudo, o número de estímulos aumenta para sessenta e quatro ($2^6 = 64$). Um aumento substancial, dado que o número de estímulos tornou-se oito vezes maior. Conseqüentemente, um indivíduo levará mais tempo para responder à pesquisa o que pode tornar a tarefa mais cansativa e comprometer a qualidade dos resultados. Logo, um dos grandes desafios na APC é obter dados suficientes para estimar as utilidades dos atributos com um número mínimo de perfis avaliados.

Uma boa alternativa quando há um número excessivo de perfis é a utilização de Delineamentos Fatoriais Fracionários ou Blocos Incompletos (Montgomery, 1996). No entanto, mesmo com a utilização deste tipo de planejamento, alguns estudos continuam prejudicados, principalmente quando muitos atributos, dez ou doze por exemplo, forem considerados simultaneamente.

Embora Green(1984) assuma que a preferência por um estímulo não sofra alteração diante da falta de alguns atributos, ou seja, não exista nenhum processo de imputação, alguns autores, tais como Lynch e Srull (1982), Yamagishi e Hill (1981) e Bradlow, Hu e Ho (2004), entre outros, acreditam que os respondentes ponderam suas decisões levando em consideração a falta de informação na descrição dos perfis. Tal ponderação pode ser interpretada como um fenômeno de **imputação** feita mentalmente pelos indivíduos. Logo, descrever matematicamente um modelo que capte este processo de imputação mostra-se uma tarefa bastante árdua e rica em detalhes, dado que cada sujeito pode utilizar um ou mais procedimentos diferentes de ponderação ao longo de sua participação da pesquisa.

Lynch e Srull (1982) acreditam que os respondentes tendem a utilizar o último nível visto de um atributo quando este estiver ausente, ou seja, assumem que quando nada for mencionado sobre um atributo, o seu nível não tenha sofrido alteração em relação ao perfil anterior. Já Yamagishi e Hill (1981) supõem que todos os níveis já apresentados ao respondente podem influenciar igualmente em sua decisão, assumindo então que a imputação é feita pela “média” dos níveis do atributo ausente. Segundo Huber e McCann (1982) é possível ainda que o respondente associe dois ou mais atributos por meio de uma estrutura arbitrária de correlação, por exemplo, associar preço à qualidade ou horas de trabalho e remuneração. Logo, quando qualquer um destes atributos estiver ausente, a informação seria imputada com base na informação do atributo presente.

Combinando conceitos de associação de perfis (Camerer e Ho, 1998) e a forma de aprendizado e memória adquiridos ao longo do processo de classificação (Ho e Chong, 2003) Bradlow, Hu e Ho (2004) propõem um novo modelo de imputação, denominado de modelo de aprendizado. Os autores acreditam que o respondente vá aprendendo à medida que mais informação sobre o produto lhe é apresentada, podendo ainda associar um ou mais atributos simultaneamente.

1.3 Caracterização do modelo de APC

Segundo Friedmann (1998), Conjoint Analysis, também conhecida por Análise de Preferência Conjunta (APC), é uma técnica multivariada que permite avaliar as preferências dos consumidores através de diferentes configurações de um mesmo produto ou serviço. Tal avaliação ocorre através da estimação de modelos cujas variáveis respostas expressam preferências individuais para diferentes configurações de um mesmo produto. Um dos atrativos da APC é a possibilidade de construir um modelo de preferência para cada respondente; assim é possível estimar a importância (utilidade parcial) atribuída por um indivíduo para cada nível do atributo.

Como premissa, um modelo de APC assume que a avaliação dos consumidores combina diferentes parcelas de utilidades, ou seja, o valor de preferência é formado pela combinação linear dos atributos considerados na descrição de um estímulo. Por simplificação, assumo que os atributos x_j são definidos conforme a expressão (1.1), ou seja, possuem somente dois níveis, um padrão e outro alternativo.

$$x_{ij}(t) = \begin{cases} 0, & \text{quando o nível padrão é utilizado no } t\text{-ésimo perfil do indivíduo } i, \\ 1, & \text{caso contrário} \end{cases} \quad (1.1)$$

Dessa forma, por exemplo, é possível descrever um modelo de preferência sob forma de uma equação linear, dada pela expressão (1.2). Assume-se aqui que a preferência pode ser descrita sob forma de uma combinação linear dos níveis e decomposta em duas partes, uma fixa, composta pelos termos $Y_i(t) = \alpha_i + \sum_{j=1}^J \beta_{ij}x_{ij}(t)$ e outra aleatória, dada por $\epsilon_i(t)$.

$$y_i(t) = Y_i(t) + \epsilon_i(t) \quad (1.2)$$

$$y_i(t) = \alpha_i + \sum_{j=1}^J \beta_{ij}x_{ij}(t) + \epsilon_i(t), \quad (1.3)$$

no qual

i : é o índice referente ao indivíduo ($i \in [1, I]$);

j : é o índice de atributo ($j \in [1, J]$);

t : identifica o perfil sob avaliação ($t \in [1, T]$);

$y_i(t)$: é o valor de preferência atribuído pelo i -ésimo indivíduo ao perfil t . O valor de preferência, $y_i(t)$, pode ser medido através de uma escala métrica, em que o i -ésimo respondente atribui uma nota variando, por exemplo, de 1 a 10 ao perfil t , ou ainda através da utilização de escalas não-métricas, ou qualitativas, tal como uma escala de 5 pontos de Likert;

$Y_i(t) = \alpha_i + \sum_{j=1}^J \beta_{ij}x_{ij}(t)$ é igual à esperança matemática de $y_i(t)$;

β_{ij} : é o parâmetro que representa a contribuição do j -ésimo atributo na preferência total. É também conhecido como utilidade parcial do atributo j ;

$x_{ij}(t)$: é o valor numérico que representa o nível do atributo j avaliado no instante t ;

α_i : é o valor da preferência quando todos os níveis padrão forem utilizados para descrever o produto, uma vez que se admite que $x_{ij}(t) = 0$ representa o nível padrão;

$\epsilon_i(t)$: representa o erro aleatório do modelo. A distribuição de probabilidade associada ao erro do modelo é identificada a partir da escala de medida de $y_i(t)$. Neste trabalho, assume-se que $y_i(t)$ possua uma escala métrica e que $\epsilon_i(t)$ seja normalmente distribuído ($\epsilon_i(t) \sim N(\mu_i, \sigma_i^2)$).

1.4 Definição dos atributos

A primeira e mais importante etapa em uma análise de preferência trata da escolha de quais atributos serão utilizados para descrever o produto em estudo. É comum a participação de especialistas e grandes conhecedores sobre o produto alvo do estudo nesta fase do projeto. Isto garante não só uma descrição factível do produto como também assegura que todas as conclusões e análises posteriores estejam de acordo com as necessidades do executor da pesquisa.

Por exemplo, suponha que uma organização esteja interessada em identificar os principais fatores de uma função (emprego ou atividade) que mais interferem na preferência ou motivação de seus empregados. Neste caso, um especialista da área de Recursos Humanos seria a pessoa mais indicada para dar suporte à escolha dos atributos e níveis, já que possui conhecimento teórico suficiente para garantir quais atributos podem melhor caracterizar um ambiente de trabalho. Após seu parecer é possível identificar se a remuneração, a jornada de trabalho ou a exposição dos funcionários são suficientes para caracterizar uma atividade ou se além desses, outros fatores como o clima na área, gestor e reconhecimento também podem ser fundamentais na composição da preferência de um funcionário e deveriam estar descritos em um estímulo.

Definir quais e quantos atributos e níveis devem ser escolhidos é o desafio dos pesquisadores, uma vez que o número de estímulos necessários para estimar as utilidades parciais cresce exponencialmente à medida que mais atributos são incorporados ao modelo. Supondo que os seis atributos: Remuneração, Jornada de trabalho, Exposição, Clima na área, Gestor e Reconhecimento sejam selecionados, cada qual descrito por dois níveis (atual e alternativo), sessenta e quatro ($2^6=64$) configurações hipotéticas de uma mesma função seriam formadas.

Neste exemplo, a suposição de que dois níveis descrevem razoavelmente bem cada um dos atributos parece ser bastante restritiva, contudo já se encontra um número total de possíveis estímulos bastante elevado, o que exige maior esforço por parte do respondente no momento da quantificação de sua preferência. Se por acaso mais um nível fosse acrescentado a cada atributo, buscando aproximar-se mais da realidade, cada respondente passaria a avaliar 729 ($3^6=729$) estímulos, tornando a tarefa praticamente inviável.

O problema do excesso de atributos é decorrente tanto no número de níveis,

quanto da quantidade de atributos avaliados. Por exemplo, assumindo que dois níveis sejam suficientes para descrever cada atributo, ao se acrescentar mais dois atributos (*Feedback* e *Desafios*) o total de possibilidades passaria de 64 para 256 ($2^6=256$) configurações, inviabilizando novamente a pesquisa. Logo, o número de atributos e níveis escolhidos na primeira etapa de uma APC definirá qual será a metodologia mais adequada a ser utilizada na formação e apresentação dos estímulos garantindo a qualidade e estimabilidade das utilidades parciais sem gerar fadiga aos respondentes.

Uma forma simples e eficiente para tratar do excesso de atributos é a formação de estímulos com base em delineamentos experimentais fatoriais fracionários, que permitem estimar as utilidades parciais a partir da avaliação de um número menor de estímulos. Alguns delineamentos, como o proposto por Plakett e Burman (1946), possuem propriedades matemáticas que garantem que a estimação de efeitos principais e alguns efeitos de interação de primeira ordem. É possível ainda combinar as avaliações de dois ou mais fatoriais fracionários em um delineamento maior a fim de estimar os fatores de interesse e suas interações.

No entanto, quando o número de atributos for muito elevado mesmo que a quantidade de perfis avaliados seja reduzida, os respondentes podem sentir dificuldades na mensuração de sua preferência. Basta imaginar um produto hipotético caracterizado por dez ou doze atributos. Sua descrição torna-se muito extensa e alguns respondentes podem focar-se em três ou quatro atributos para tomar sua decisão. Conforme posposto por Green (1974), uma simplificação na descrição dos estímulos pode ser feita através da omissão de um ou mais atributos, ou seja, o autor propõe que **perfis incompletos** sejam apresentados aos respondentes, e mais ainda, assume que a ausência de um ou mais atributos não interfere na mensuração da preferência.

Como exemplo ilustrativo, considere uma APC cujo delineamento seja descrito pela Tabela 1.1. Embora o produto seja caracterizado por três atributos com dois níveis cada (0: nível padrão e 1: nível alternativo), o delineamento apresenta a formação de perfis incompletos, pois em cada estímulo omite-se a informação de um dos três atributos. Supondo que o objeto em estudo seja a função desempenhada em uma organização e que os três atributos sejam a Jornada de Trabalho (x_{i1}), Remuneração (x_{i2}) e Frequência de exposição a novos desafios (x_{i3}), o delineamento referente à Tabela 1.1 seria equivalente ao apresentado pela Tabela 1.2.

O primeiro estímulo caracteriza uma função que exige trabalho de 10h diárias

Tabela 1.1: Perfis Incompletos.

Estímulo (t)	Valor de preferência ($y_{ij}(t)$)	Atributos		
		x_{i1}	x_{i2}	x_{i3}
1	$y_{ij}(1)$	1		1
2	$y_{ij}(2)$		0	0
3	$y_{ij}(3)$		0	1
4	$y_{ij}(4)$	0		1
5	$y_{ij}(5)$	1		0
6	$y_{ij}(6)$	0	0	
7	$y_{ij}(7)$	1	0	
8	$y_{ij}(8)$		1	0

Tabela 1.2: Perfis Incompletos.

Estímulo (t)	Valor de preferência ($y_{ij}(t)$)	Atributos		
		Jornada de Trabalho	Remuneração	Desafios
1	$y_{ij}(1)$	10h/dia		constantes
2	$y_{ij}(2)$		sem aumento	raros
3	$y_{ij}(3)$		sem aumento	constantes
4	$y_{ij}(4)$	8h/dia		constantes
5	$y_{ij}(5)$	10h/dia		raros
6	$y_{ij}(6)$	8h/dia	sem aumento	
7	$y_{ij}(7)$	10h/dia	sem aumento	
8	$y_{ij}(8)$		aumento de 20%	raros

e apresenta desafios constantes ao empregado. Note que nada é citado sobre a remuneração. Green (1974) supõe que o respondente não usa de nenhum processo de imputação da informação ausente quando perfis incompletos lhes são apresentados e por isso a omissão de um atributo não afeta a quantificação da preferência de um respondente.

Contudo, tal suposição parece ser bastante questionável, pois é possível que um

respondente, ao avaliar o primeiro estímulo, pondere sua decisão sobre o valor de preferência segundo suas expectativas salariais, caso este atributo seja muito importante para ele. Ou seja, a influência da omissão de um atributo na descrição de um estímulo pode vir a influenciar no grau de importância de um atributo.

Quando um atributo muito importante for omitido na descrição de um estímulo espera-se que os respondentes tendam a compensar sua ausência atribuindo maiores ou menores valores para a sua preferência e até mesmo assumam internamente um valor (imputam) para o nível do atributo ausente. Este processo de **imputação** presente durante a avaliação de um perfil incompleto é feito mentalmente pelo respondente, sendo difícil de ser captado via modelagem pois a cada nova avaliação uma diferente regra de decisão pode ser adotada. A complexidade pode tornar-se ainda maior se a heterogeneidade dos participantes da pesquisa for levada em consideração.

Dentre as diferentes formas de imputação existentes, um indivíduo pode utilizar a imputação via valor padrão, pela média ou ainda ponderar pela recência com que os níveis anteriores do mesmo atributo foram apresentados. Cada um dos procedimentos acima citados serão mais detalhados no próximo capítulo.

Formas de Imputação

2.1 Perfis incompletos e imputação de dados

À medida que mais estudos sobre a utilização de estímulos ou perfis incompletos (ou parciais) como alternativa para diminuir o número de perfis avaliados foram sendo realizados, o número de pesquisadores que passaram a adotar este tipo de método de formação de perfis também aumentou. Isso porque diferentes estudos sugerem que as estimativas das utilidades parciais mostram-se muito similares às aquelas encontradas quando perfis completos são utilizados, como visto por Bradlow, Hu e Ho(2004) em um estudo de preferências aplicado à máquinas fotográficas digitais.

Nestes casos, é preciso assumir que:

1. Não há grandes perdas de informação ao se utilizar perfis incompletos em vez de perfis completos.
2. Que o atributo ausente não influencia na preferência atribuída ao perfil.
3. Há independência entre as respostas das preferências atribuídas para dois perfis diferentes, sendo descritos ou não pelos mesmos atributos.

Tais suposições são questionáveis, uma vez que é natural que um indivíduo, ao classificar um perfil, considere a existência do atributo faltante e acabe por “imputar” algum nível coerente com os demais atributos presentes no perfil. Pode-se pensar que a preferência do respondente é influenciada pela ausência de um atributo e que o maior desafio seja conhecer quais são os processos que são considerados para imputar esta informação na avaliação do perfil.

Assim, surge o interesse em estudar se a ausência de um atributo em um perfil realmente afeta o valor da utilidade a ele atribuída, se a ordem de apresentação dos estímulos interfere nos valores das suas utilidades e de que maneira o respondente imputa a informação do atributo ausente. Cabe lembrar que o processo de imputação é realizado mentalmente pelo respondente o que torna o desafio de expressar matematicamente um modelo que capte este processo tão particular ainda maior.

Uma alternativa para mensurar a influência da presença/ausência de um determinado atributo é acrescentar mais um termo ao modelo (1.2) que indique a presença de cada atributo no estímulo sob avaliação. A variável indicadora da presença do atributo j no t -ésimo perfil respondido pelo i -ésimo indivíduo é denotada por $r_{ij}(t)$ e é descrita pela expressão (2.1).

$$r_{ij}(t) = \begin{cases} 1, & \text{se o atributo } j \text{ estiver presente no perfil } t \text{ do sujeito } i, \\ 0, & \text{caso contrário, ou seja, se for omitido} \end{cases} \quad (2.1)$$

Outro termo que deve ser acrescentado ao modelo é dado por $x'_{ij}(t)$ que representa o nível imputado ao atributo j do t -ésimo perfil respondido pelo indivíduo i , já que se está assumindo que o respondente não ignora a ausência do atributo ao classificar um perfil. A expressão matemática que define $x'_{ij}(t)$ é dada por (2.2).

$$x'_{ij}(t) = \begin{cases} x_{ij}(t), & \text{se } r_{ij}(t) = 1, \\ V(x_{ij}(t)), & \text{se } r_{ij}(t) = 0 \end{cases} \quad (2.2)$$

sendo $V(x_{ij}(t))$ uma variável aleatória que descreve o processo de imputação do nível faltante. Para cada processo de imputação $V(x_{ij}(t))$ assumirá uma forma específica.

Observa-se que quando $r_{ij}(t) = 1$, ou seja, quando o atributo j é um atributo descrito no t -ésimo perfil, nenhum processo de imputação será utilizado, já que toda a informação referente a este atributo está disponível ao respondente. No entanto, caso $r_{ij}(t) = 0$, ou seja, o atributo não está presente na descrição do perfil, pode-se assumir que o respondente i assumirá qualquer nível deste atributo no momento de sua classificação.

Levando em consideração estes novos elementos, o novo modelo de APC passa a ser escrito por (2.3). Os coeficientes β_{ij} , representam os valores das utilidades

para cada atributo. Neste trabalho, está-se considerando atributos com somente dois níveis, conforme apresentado pela expressão (2.2); e β_{ij} representa o valor da utilidade quando $x'_{ij}(t) = 1$, ou seja, quando o nível alternativo for considerado na descrição do estímulo, independentemente da presença ou não deste atributo no perfil t .

Neste caso, avaliar se β_{ij} é significativamente diferente de zero, significa testar se há diferença entre a utilidade atribuída ao nível padrão ou alternativo de um mesmo atributo. O parâmetro β'_{ij} descreve a variação na utilidade parcial do nível do j -ésimo atributo quando j está presente no t -ésimo perfil, ou seja, quando $r_{ij}(t) = 1$.

$$Y_i(t) = \alpha_i + \sum_{j=1}^J [\beta_{ij}x'_{ij}(t) + \beta'_{ij}r_{ij}(t)]. \quad (2.3)$$

Quando o nível alternativo for utilizado na avaliação $x'_{ij}(t) = 1$ e este estiver presente no modelo $r_{ij}(t) = 1$. A utilidade atribuída ao atributo é dada pela soma de $\beta_{ij} + \beta'_{ij}$, ou seja, a soma da utilidade parcial do atributo j com a parcela referente à sua presença na descrição do estímulo. Portanto, este modelo descreve o valor da preferência como a soma dos efeitos dos diferentes atributos acrescidos da informação de sua presença ou ausência no estímulo avaliado.

Por exemplo, suponha um estímulo formado por somente um atributo, $x_1=1$ e que este atributo seja um atributo presente. A expressão (2.3) seria dado por: $Y_i = \alpha_i + \beta_{i1}x_{i1} + \beta'_{i1}r_{i1}$. Substituindo o nível correspondente, o valor de preferência predito será igual à expressão (2.4).

$$Y_i = \alpha_i + \beta_{i1} \times 1 + \beta'_{i1} \times 1 \quad (2.4)$$

Simplificando a expressão (2.4), tem-se $Y_i = \alpha_i + \beta_{i1} + \beta'_{i1}$.

Suponha agora outro estímulo, onde o valor do atributo x_1 assumo o valor **0**. O valor de preferência passa a ser escrito por (2.5):

$$Y_i = \alpha_i + \beta_{i1} \times 0 + \beta'_{i1} \times 1, \quad (2.5)$$

ou ainda, pode ser escrito como $Y_i = \alpha_i + \beta'_{i1}$.

Uma vez que o cálculo do valor da utilidade do atributo dá-se pela diferença das utilidades encontradas a partir do maior nível ($x_1=1$) com o menor ($x_1=0$), a utilidade no caso em que o atributo encontra-se presente no estímulo é igual à β_{i1} .

A Tabela 2.1 traz situações de composição das utilidades dependendo do nível e da presença do atributo no perfil sob avaliação.

Tabela 2.1: Possíveis utilidades para um mesmo atributo

Atributo Presente	Nível do Atributo		Alternativo-Padrão
	Alternativo ($x'_{ij}(t) = 1$)	Padrão ($x'_{ij}(t) = 0$)	
Sim ($r_{ij}(t) = 1$)	$\beta_{ij} + \beta'_{ij}$	β'_{ij}	β_{ij}
Não ($r_{ij}(t) = 0$)	β_{ij}	0	β_{ij}

A seguir são apresentados diferentes processos de imputação da informação ausente, que podem ser adotados de forma isolada ou combinados dependendo unicamente da decisão de cada respondente.

2.1.1 Imputação utilizando um valor padrão

A imputação via Valor Padrão assume que um respondente imputa o nível padrão sempre que um atributo estiver ausente na descrição de um perfil. Por exemplo, o segundo estímulo da Tabela 1.2 descreve uma função cuja remuneração não será modificada em relação à atual e que raramente o funcionário será desafiado. Nada é mencionado sobre a jornada diária de trabalho. Dado que o padrão assumido pela maioria das empresas é uma jornada de 8 horas/dia é esperado que um respondente assuma que não deva haver alterações quanto a este atributo e o considere mentalmente, ou seja, impute-o no perfil no momento da quantificação do valor de preferência, mesmo que este atributo esteja ausente na descrição do perfil.

O nível padrão é denotado por $x_{ij}(t) = 0$ e a variável $V(x_{ij}(t))$, que representa o nível imputado sempre que o atributo j estiver ausente, pode ser escrita como:

$$V(x_{ij}(t)) = \begin{cases} x_{ij}(t), & \text{se } r_{ij}(t) = 1, \\ 0, & \text{se } r_{ij}(t) = 0 \end{cases} \quad (2.6)$$

2.1.2 Imputação utilizando a média

É possível ainda que um respondente considere que o nível de um atributo ausente seja dado pela média dos possíveis níveis deste atributo. Assim, se a remuneração

anual oferecida por uma empresa estiver ausente em um estímulo e se o conhecimento prévio do respondente, ou mesmo os valores descritos nos estímulos anteriores, descreverem um salário entre R\$20.000,00 e R\$24.000,00, é provável que o candidato assuma que quando nada for informado sobre o salário uma média de R\$22.000,00 pode estar sendo considerada. Este tipo de imputação é indicada quando os níveis forem descritos de forma quantitativa.

Na imputação pela média, assume-se que todos os níveis do atributo ausente apresentam a mesma influência na preferência dos respondentes e que além disso o estímulo sob avaliação seja igualmente similar aos estímulos anteriormente descritos. Dessa forma, a expressão de $V(x_{ij}(t))$ passa a ser definida por (2.7)

$$V(x_{ij}(t)) = \begin{cases} x_{ij}(t), & \text{se } r_{ij}(t) = 1, \\ \bar{x}_{ij}, & \text{se } r_{ij}(t) = 0 \end{cases} \quad (2.7)$$

2.1.3 Imputação por associação

Embora exista uma forte suposição sobre a similaridade dos perfis no modelo de médias, espera-se que alguns perfis mostrem-se mais influentes, especialmente quando os atributos possuírem alguma correlação. Por exemplo, Huber e McCann (1982) mostram que os indivíduos utilizam suas crenças sobre a correlação entre preço e qualidade quando ao menos um destes atributos estiverem ausentes.

Diferente dos processos descritos anteriormente, a imputação por associação utiliza a informação dos níveis dos atributos presentes no estímulo para definir o nível do atributo ausente. Os padrões de associações podem variar de acordo com a interpretação feita pelo respondente.

No caso de uma função/emprego, pode haver associação entre Jornada de trabalho e Remuneração, uma vez que um indivíduo pode associar uma remuneração maior a uma jornada maior de trabalho. Outra possibilidade é associar Exposição em outras áreas com maior Frequência de Desafios. Em todos os casos, existe bastante influência das experiências pessoais de cada respondente e sua modelagem não possui

uma forma definida.

2.1.4 Imputação via recência

Uma forte similaridade entre o estímulo atual e o último avaliado, associada ao fato de que ambos sejam distintos dos demais são os principais argumentos para a utilização de um padrão de imputação baseado na recência (Lynch e Srull, 1982). Neste caso, o respondente assume que o nível atual seja idêntico ao apresentado no estímulo que o antecede, tal como em um processo de memória curta, uma vez que somente o último estímulo influencia na imputação do nível ausente.

Nestas condições, $V(x_{ij}(t))$ pode ser definida como:

$$V(x_{ij}(t)) = \begin{cases} x_{ij}(t), & \text{se } r_{ij}(t) = 1, \\ x_{ij}(t-a), & \text{se } r_{ij}(t) = 0 \text{ e } r_{ij}(t-a) = 1 \end{cases} \quad (2.8)$$

onde a é o maior inteiro pertencente ao intervalo $[1; t]$ tal que no instante $t - a$ o atributo $x_{ij}(t - a)$ esteja presente no estímulo.

Voltando à Tabela 1.2, o atributo Jornada de Trabalho está ausente no oitavo estímulo, logo, espera-se que ao avaliá-lo o respondente impute o último nível visto deste mesmo atributo em seu julgamento, ou seja, 10 horas/dia. Nestes casos, diz-se que a recência é imediata.

Uma crítica a essa abordagem é que os demais estímulos podem também contribuir no processo de imputação. Para modelar isso pode-se, por exemplo, assumir que o tempo que os distancia do momento presente seja um fator ponderador, tal como proposto por Bradlow, Hu e Ho(2004) em seu modelo de aprendizado, que será melhor detalhado a seguir.

Neste caso, um modelo de médias ponderadas pela recência da ocorrência do nível mostra-se bastante adequado. Ou seja, quanto mais afastados dois níveis estiverem,

no que diz respeito ao tempo de avaliação, menor é a participação ou influência no momento da classificação da preferência.

No caso da ausência ocorrer no primeiro estímulo, assume-se que com probabilidade 0,5 qualquer um dos dois níveis pode ser imputado.

2.1.5 Imputação via aprendizado

À medida que um respondente avalia mais estímulos, toda a informação recebida anteriormente tende a apresentar alguma influência na quantificação de sua preferência, isto porque sua avaliação torna-se mais crítica, dada sua experiência, ou **aprendizado** anterior.

Alba e Cooke (2004) vêem cada estímulo como sendo uma amostra do mundo real que vai sendo descoberto pelo respondente a cada nova avaliação. Aliada a essas descobertas, todo o conhecimento a priori e informações disponíveis vão compor o valor final da preferência de um indivíduo.

Com o intuito de modelar este processo de aprendizagem, Bradlow, Hu e Ho (2004) propõem um modelo, denominado de **modelo de aprendizado**, que procura captar a forma como o respondente infere os níveis ausentes de um atributo combinando elementos de similaridade dos perfis, níveis de conhecimento a priori das características do produto e diferentes conceitos de métodos de imputação.

Uma vantagem desta técnica de imputação é que ela capta a influência não só dos níveis a priori de um mesmo atributo, mas também leva em consideração os níveis dos outros atributos presentes no estudo, útil quando existem atributos naturalmente correlacionados.

Para descrever a forma como o i -ésimo indivíduo imputa a informação, o modelo de aprendizado utiliza conceitos de associação, ou similaridade de perfis (*Pattern Matching*) combinados com elementos apresentados em perfis anteriores, ou seja, baseado em experiências anteriores do indivíduo (*Experience Counts*). Tais conceitos

bem definidos por Hock, Bradlow e Wansink (1999), que descrevem a medida de similaridade entre pares de objetos categóricos e por Camerer e Ho (1999) que descrevem como ocorre o processo de aprendizado e perda de memória ao longo do tempo. Com esses dois elementos, as probabilidades de escolha de cada um dos níveis são derivadas tornando-se possível descrever o processo de recência de memória envolvido durante a classificação da preferência do perfil e como ocorre o enfraquecimento (ou decaimento) da influência dos níveis dos atributos à medida que as comparações com os perfis anteriores são realizadas.

A partir de um exemplo hipotético pretende-se definir e construir um modelo de APC que considera a imputação via aprendizado como método de imputação quando perfis incompletos são apresentados.

Similaridades dos perfis

A similaridade entre dois ou mais perfis (*Pattern Matching*) é medida através da comparação par a par dos atributos, métrica de Hamming, própria para casos em que atributos binários são utilizados. Esta medida de similaridade associa o valor 1 quando dois estímulos possuem o mesmo nível em um determinado atributo e 0 caso contrário. Algebricamente, a métrica de Hamming pode ser traduzida como uma variável indicadora, que será igual a 1 sempre que o atributo, ou os atributos, observados possuírem níveis idênticos em dois momentos distintos. Suponha a e b duas variáveis binárias, a métrica em questão é definida pela expressão (2.9).

$$I[a = b] = \begin{cases} 1, & \text{se } a = b, \\ 0, & \text{se } a \neq b \end{cases} \quad (2.9)$$

Considere um delineamento composto por somente três estímulos e quatro atributos, conforme descrito pela Tabela 2.2. Note que os estímulos não são descritos por todos os atributos simultaneamente ou seja, são perfis incompletos. No primeiro

deles, por exemplo, o atributo 3 é omitido na descrição. No instante seguinte, o quarto atributo é omitido e por fim é a vez do atributo 2 ser omitido na descrição do terceiro perfil.

Suponha também que o interesse seja imputar um nível para o segundo atributo do terceiro estímulo via método de aprendizado e que todos os atributos considerados assumem somente dois níveis (0 ou 1).

Tabela 2.2: Exemplo Ilustrativo: Delineamento com perfis incompletos.

Perfil	Atributo1	Atributo2	Atributo3	Atributo4
1	1	0		1
2	0	1	1	
3	1		1	0

Como primeiro passo do processo de imputação via aprendizado, deve-se contabilizar as semelhanças encontradas entre o terceiro estímulo e seus anteriores, tanto para os atributos individualmente como na combinação entre eles. Para tal, deve-se simular todas as possíveis configurações dos perfis e assim compará-las. Neste exemplo assume-se que o atributo ausente possui somente dois níveis, logo duas novas configurações para o terceiro estímulo são possíveis.

Na primeira delas, Tabela 2.3, admite-se que o respondente impute o nível **0** (valor padrão) sempre que um atributo for omitido da descrição do estímulo, ou seja todos os atributos ausentes recebem o nível **0**.

Tabela 2.3: Delineamento com valor imputado igual ao nível padrão.

Perfil	Atributo1	Atributo2	Atributo3	Atributo4
1	1	0	0	1
2	0	1	1	0
3	1	0	1	0

Suponha que o valor de preferência $Y_i(t)$ seja calculado por:

$$Y_i(t) = \alpha_i + \beta_{i1}x_{i1}(t) + \beta_{i2}x_{i2}(t) + \beta_{i3}x_{i3}(t) + \beta_{i4}x_{i4}(t) \quad (2.10)$$

Observe que ao assumir que o respondente imputa o valor ausente com o nível 0 encontram-se semelhanças entre os atributos 1 e 2 no primeiro e terceiro estímulos, isso porque ambos atributos apresentam os mesmos níveis em instantes diferentes .

Por exemplo, tem-se que $x_{i2}(3)$ representa o nível que o atributo 2 assume no terceiro estímulo e $x_{i2}(1)$ o nível do mesmo atributo para o primeiro estímulo, segundo a Tabela 2.3, $x_{i2}(3) = x_{i2}(1) = 0$. Neste caso, a métrica de Hamming dada por $I[x_{i2}(3) = x_{i2}(1)]$ é igual a 1, pois temos igualdade entre os níveis observados. Quando o interesse é avaliar a similaridade entre dois ou mais atributos simultaneamente a métrica de Hamming é dada pela multiplicação dos termos indicadores. Por exemplo, a expressão matemática que mede a similaridade dos atributos 1 e 2 no primeiro e terceiro estímulos é dada por:

$$I[x_{i2}(3) = x_{i2}(1)]I[x_{i1}(3) = x_{i1}(1)] = 1 \quad (2.11)$$

No comparativo entre o segundo e terceiro estímulo há similaridade de perfis entre para os atributos 3 e 4, que assumem respectivamente os níveis 1 e 0 em ambos os momentos. Como neste caso os níveis do atributo 2 não coincidem, a similaridade entre os atributos 3 e 4 é ignorada.

O mesmo raciocínio é utilizado considerando agora que o respondente imputa o nível **1** (ver Tabela 2.4) sempre que um atributo estiver ausente no estímulo.

Similaridades entre os atributos 2 e 3 são encontradas no segundo e terceiro estímulos. Há coincidências entre os atributos 1 e 3 no primeiro e terceiro estímulos, contudo o atributo 2 não possui o mesmo nível em ambos estímulos, logo, tal coincidência é ignorada.

Tabela 2.4: Exemplo ilustrativo - Imputação do nível 1.

Perfil	Atributo1	Atributo2	Atributo3	Atributo4
1	1	0	1	1
2	0	1	1	1
3	1	1	1	0

Número de Coincidências

Admite-se que além da similaridade, a distância no tempo entre os estímulos avaliados também influencia no nível imputado e que tal influência decresce exponencialmente à medida que um maior afastamento no tempo seja observado. Tal efeito representa um efeito de memória no processo de imputação, que será modelada através de parâmetros λ_i ($\lambda_i \in [0; 1]$).

Dessa forma, é possível combinar os conceitos de similaridade de perfis, aqui representado pela métrica de Hamming, com o efeito de memória (λ) para que seja possível quantificar as experiências anteriores (*Experiences Counts*) de um indivíduo, ou seja, o número de coincidências entre estímulos. As comparações devem ser feitas entre o estímulo sob avaliação e todos os estímulos anteriormente apresentados bem como entre o atributo ausente e os demais atributos considerados no estudo.

Considere o terceiro estímulo da Tabela 2.4. Neste caso, assumimos que o entrevistado i imputou o valor 1 ao atributo ausente 2. Para modelar o processo mental que o levou a essa imputação, precisamos medir quanto os estímulos anteriores influenciaram nessa escolha. Como os valores dos níveis do atributo 2 diferem entre o primeiro e o terceiro estímulos, temos que o primeiro estímulo não influenciou na decisão e sua parcela na medida de influência será nula. Já ao comparar os estímulos 2 e 3, temos igualdade entre os níveis do atributo 2 o que também ocorre entre os níveis do atributo 3. A medida da influência dos estímulos 1 e 2 sobre o estímulo 3, ao imputar o valor 1 no terceiro estímulo, será igual à influência do estímulo 2 sobre

o estímulo 3 sendo dada por (2.12).

$$N_{i2}(3, 1) = \lambda_2 + \lambda_{23} \quad (2.12)$$

sendo

λ_2 a intensidade com que a coincidência de níveis atributo 2 entre o segundo e terceiro estímulos influencia na imputação.

λ_{23} a intensidade com que a coincidência entre níveis dos atributos 2 e 3 para o segundo e terceiro estímulos influencia na imputação.

Vamos repetir o exercício para os dados da Tabela 2.3. Neste caso, o valor imputado foi zero. Considerando apenas o atributo 2, encontramos coincidência apenas no estímulo 1 (o estímulo 2 será então desconsiderado). Ao comparar os estímulos 1 e 3 temos coincidência entre os atributos 1 e 2. Desse modo, a medida da influência do estímulo 1 sobre o estímulo 3, quando o indivíduo i imputou o valor 0 no atributo 2 será dada por:

$$N_{i2}(3, 0) = \lambda_2^2 + \lambda_{21}^2 \quad (2.13)$$

sendo

λ_2^2 a intensidade com que a coincidência de nível do atributo 2 nos estímulos 1 e 3 influencia na imputação.

λ_{21}^2 a intensidade com que a coincidência entre níveis dos atributos 1 e 2 quando compara-se o segundo e terceiro estímulos influencia na imputação.

O expoente 2 é uma penalização uma vez que o estímulo 3 foi o segundo atributo apresentado ao entrevistado após o atributo 1. Caso estivéssemos comparando os estímulos 2 e 5, todos os parâmetros deveriam ser elevados à terceira potência. Como esses parâmetros (λ_{ij}) estão entre zero e um temos que quanto mais próximos forem os estímulos, maior será a influência na imputação.

A notação utilizada é :

$\lambda_{j,k}^{|t-s|}$: efeito de memória quando os atributos j e k assumem o mesmo valor nos estímulos t e s .

$N_{ij}(t, l)$: influência dos estímulos anteriores sobre a imputação do nível l no atributo j no estímulo t .

Para a obtenção da expressão geral, retome à Tabela 2.4. O cálculo das contagens, inicia-se avaliando se o atributo 2 assume o nível 1 tanto no primeiro quanto no terceiro estímulos ($I[x'_2(3) = x_2(1)]$). Na sequência, parte-se para a comparação de similaridades entre o atributo 2 com os demais atributos. Repete-se tal procedimento até que todas as comparações do terceiro estímulos com seus anteriores sejam feitas.

$$\begin{aligned}
 N_{i2}(3, 1) = & \lambda_2^2 I[x'_2(3) = x_2(1)] \\
 & + \{ \lambda_{21}^2 I[x'_1(3) = x_1(1)] I[x'_2(3) = x'_2(1)] \\
 & + \lambda_{23}^2 I[x'_3(3) = x_3(1)] I[x'_2(3) = x'_2(1)] \\
 & + \lambda_{24}^2 I[x'_4(3) = x_4(1)] I[x'_2(3) = x'_2(1)] \} \\
 & + \lambda_2 I[x'_2(3) = x_2(2)] \\
 & + \{ \lambda_{21} I[x'_1(3) = x_1(2)] I[x'_2(3) = x'_2(2)] \\
 & + \lambda_{23}^2 I[x'_3(3) = x_3(2)] I[x'_2(3) = x'_2(2)] \\
 & + \lambda_{24}^2 I[x'_4(3) = x_4(2)] I[x'_2(3) = x'_2(2)] \}
 \end{aligned} \tag{2.14}$$

Note que somente níveis idênticos de um mesmo atributos irão influenciar na imputação do nível ausente. Quanto maior for a similaridade entre dois perfis avaliados, maior também será a influência exercida sobre a imputação do nível sob avaliação.

Substituindo os respectivos valores para a comparação entre os tempos 1 e 3 tem-se que:

$$I[x'_2(3) = x_2(1)] = I[1 = 0] = 0$$

$$\begin{aligned}
I[x'_2(3) = x'_2(1)] &= I[1 = 0] = 0 \\
I[x'_1(3) = x_1(1)] &= I[1 = 1] = 1 \\
I[x'_3(3) = x_3(1)] &= I[1 = 1] = 1 \\
I[x'_4(3) = x_4(1)] &= I[0 = 1] = 0
\end{aligned}$$

No que diz respeito à comparação entre os tempos 2 e 3, tem-se:

$$\begin{aligned}
I[x'_2(3) = x_2(2)] &= I[1 = 1] = 1 \\
I[x'_2(3) = x'_2(2)] &= I[1 = 1] = 1 \\
I[x'_1(3) = x_1(2)] &= I[1 = 0] = 0 \\
I[x'_3(3) = x_3(2)] &= I[1 = 1] = 1 \\
I[x'_4(3) = x_4(2)] &= I[0 = 1] = 0
\end{aligned}$$

Assim, a expressão (2.14) passa a ser escrita como:

$$\begin{aligned}
N_{i2}(3, 1) &= \lambda_2^2 \times 0 \\
&+ \{\lambda_{21}^2 \times 1 \times 0 + \lambda_{23}^2 \times 1 \times 0 + \lambda_{24}^2 \times 0 \times 0\} \\
&+ \lambda_2 \times 1 \\
&+ \{\lambda_{21} \times 0 \times 1 + \lambda_{23}^2 \times 1 \times 1 + \lambda_{24}^2 \times 0 \times 1\}
\end{aligned} \tag{2.15}$$

No exemplo acima, não existe similaridade entre os níveis do segundo atributo para o primeiro e terceiro estímulos, isto porque está-se assumindo que $x'_2(3) = 1$ e temos que $x_2(1) = 0$, o que torna nulo o primeiro termo da expressão.

Encontram-se similaridades nos estímulos 2 e 3 para o atributo 2 ($x'_2(2) = 1$ e $x_2(3) = 1$) e para o atributo 3 ($x'_3(2) = 1$ e $x_3(3) = 1$), logo, $N_{i2}(3, 1)$ será descrito pela soma da influência do segundo e terceiro atributos, representados respectivamente por λ_2 e λ_{23} . Finalmente, pode-se escrever a expressão (2.15) como:

$$N_{i2}(3, 1) = \lambda_2 + \lambda_{23}. \tag{2.16}$$

Analogamente, quando se supõe que o nível imputado seja o nível padrão, $x'_{i2}(3) = 0$, $N_{i2}(3, 0)$ passa a ser dada por:

$$\begin{aligned}
N_{i2}(3, 0) = & \lambda_2^2 I[x'_2(3) = x_2(1)] \\
& + \{\lambda_{21}^2 I[x'_1(3) = x_1(1)] I[x'_2(3) = x'_2(1)] \\
& + \lambda_{23}^2 I[x'_3(3) = x_3(1)] I[x'_2(3) = x'_2(1)] \\
& + \lambda_{24}^2 I[x'_4(3) = x_4(1)] I[x'_2(3) = x'_2(1)]\} \\
& + \lambda_2 I[x'_2(3) = x_2(2)] \\
& + \{\lambda_{21} I[x'_1(3) = x_1(2)] I[x'_2(3) = x'_2(2)] \\
& + \lambda_{23}^2 I[x'_3(3) = x_3(2)] I[x'_2(3) = x'_2(2)] \\
& + \lambda_{24}^2 I[x'_4(3) = x_4(2)] I[x'_2(3) = x'_2(2)]\}
\end{aligned} \tag{2.17}$$

Calculando-se as similaridades e ponderando-se pela distância entre os estímulos avaliados, tem-se que $N_{i2}(3, 0) = \lambda_2^2 + \lambda_{21}^2$, uma vez que se encontram coincidências entre os níveis dos atributos 1 e 2 entre os estímulos 3 e 1.

Uma vez que os estímulos 3 e 1 estão afastados em duas unidades de tempo, o parâmetro λ aparece elevado ao quadrado, simbolizando o efeito de memória do modelo. Assume-se que λ varie no intervalo $[0;1]$. Logo, tomar a diferença entre os tempos de avaliação dos estímulos por meio do expoente de λ , significa assumir que a lembrança, ou associação, entre dois estímulos enfraquece exponencialmente.

Assim, quanto mais próximo de zero for o valor de λ , menor será a influência dos níveis anteriores no momento da imputação, o que caracteriza um processo de memória curta. Por outro lado, quanto mais próximo de 1 for o valor de λ , maior será a influência dos níveis anteriormente apresentados, similar ao que ocorre em um modelo de imputação pela média. Ainda, λ_{23} e λ_{21} procuram captar o efeito de interação dos atributos 3 e 1 com o atributo 2. Quando houver grande associação entre dois atributos e um deles estiver ausente, espera-se que o efeito de interação

seja elevado, com λ próximo a 1.

Probabilidade de imputação

Definidas as contagens das experiências anteriores ($N_{i2}(3, 1) = \lambda_2 + \lambda_{23}$ e $N_{i2}(3, 0) = \lambda_2^2 + \lambda_{21}^2$), o próximo passo é calcular a probabilidade de imputação de cada um dos níveis. Intuitivamente, aquele nível que apresentar uma maior similaridade entre estímulos e atributos será o imputado.

A probabilidade de imputação de cada um dos níveis é calculada seguindo conceitos de probabilidades condicionais. No exemplo, a expressão (2.18) apresenta o cálculo da probabilidade de imputação quando o nível imputado é 1.

$$P[x'_{i0}(3) = 1] = \frac{\lambda_2 + \lambda_{23}}{(\lambda_2^2 + \lambda_{21}^2) + (\lambda_2 + \lambda_{23})} \quad (2.18)$$

A probabilidade de imputação do nível padrão (nível **0**) é dada pela probabilidade complementar, $1 - P[x'_{i0}(3) = 1]$. O nível a ser imputado será aquele que possuir maior valor para $P[x'_{ij}(t) = l^*]$.

Modelo Geral

De uma maneira mais geral, as expressões utilizadas pelo procedimento de imputação via aprendizado são definidas pelas expressões (2.19) a (2.22). No que diz respeito às contagens, dadas por $N_{ij}(t^*, l^*)$, os autores propõe também a inclusão de um termo referente ao conhecimento a priori do respondente sobre o produto e o peso que um ou outro nível pode exercer antes mesmo de que qualquer estímulo seja avaliado. Na expressão (2.19) o termo referente ao conhecimento a priori é identificado por $N_{ij}(0, l^*)$.

$$\begin{aligned}
N_{ij}(t^*, l^*) &= N_{ij}(0, l^*) \\
&+ \sum_{t'=0}^{t-1} (\lambda_{i(j,j')}^{(t-t')} I[x'_{ij}(t) = x_{ij}(t')]) \\
&+ \sum_{j'=1, j' \neq j}^J \lambda_{i(j,j')}^{t-t'} I[x_{ij'}(t) = x_{ij'}(t')] I[x'_{ij}(t) = x_{ij}(t')]
\end{aligned} \tag{2.19}$$

O processo de imputação via o modelo de aprendizado também pode ser visto como uma tabela de contingência variante no tempo, cujas contagens são dadas por $N_{ij}(t^*, l^*)$. Dessa forma, probabilidade de imputação de um determinado nível l_j no t -ésimo perfil pode ser calculada condicionando tais contagens conforme apresentado em (2.20).

$$P[x'_{ij}(t) = l^*] = \begin{cases} 1, & \text{se } r_{ij}(t) = 1 \text{ e } x'_{ij}(t) = l^* \\ 0 & \text{se } r_{ij}(t) = 1 \text{ e } x'_{ij}(t) \neq l^* \\ \frac{N_{ij}(t=t^*, l_j=l^*)}{N_{ij}(t=t^*, l_j=0) + N_{ij}(t=t^*, l_j=1)} & \text{se } r_{ij}(t) = 0 \end{cases} \tag{2.20}$$

O vetor de valores imputados em um instante t é dado pelo vetor $\mathbf{x}'_i(t) = [x'_{i1}(t), x'_{i2}(t), \dots, x'_{iJ}(t)]$. Para um delineamento com J atributos, em que cada atributo tiver dois níveis, o vetor $\mathbf{x}'_i(t)$ pode assumir um dos $K=2^J$ possíveis perfis, também conhecidos como perfis potenciais ($\mathbf{Z}_k$, $k=1, \dots, K$). O perfil imputado será aquele cuja probabilidade de que $\mathbf{x}'_i(t)$ seja igual a um determinado perfil $\mathbf{Z}_k$, dada pela expressão (2.21), seja maximizada.

$$P[\mathbf{x}'_i(t) = \mathbf{Z}_k] = \prod_j^J P[x'_{ij}(t) = l_j] \tag{2.21}$$

A expressão matemática do modelo de APC adotado neste caso é idêntica à (2.3) com inclusão de um termo auto-regressivo no erro do modelo, a fim de captar uma possível correlação nos erros ao longo do tempo, visto que muitas pessoas podem

corrigir seu julgamento anterior, ou compensar um valor de preferência menor/maior atribuído no último estímulo avaliado. O processo auto-regressivo é caracterizado por (2.22).

$$\epsilon_i(t) = \gamma_i \epsilon_i(t-1) + u_i(t), \quad (2.22)$$

onde $u_i(t) \sim N(0, \sigma_i^2)$.

2.2 Modelo Bayesiano

Verossimilhança

A verossimilhança do modelo de aprendizado, dada pela expressão (2.23), combina elementos do modelo de regressão da APC com conceitos do modelo de imputação via aprendizado, ponderados pela probabilidade de imputação de cada um dos níveis dentro dos possíveis de perfis. Uma vez que o modelo possui um termo auto-regressivo no erro, torna-se mais fácil escrever a expressão da verossimilhança em função do próprio erro ($\epsilon_i(t)$). Além disso, cabe lembrar que o valor que o erro assume é condicionalmente dependente do valor imputado quando o atributo j está ausente no t -ésimo perfil, daí a razão para a presença do termo $P[\mathbf{x}'_i(t) = \mathbf{Z}_k]$ estar presente na expressão da verossimilhança.

$$L(\alpha_i, \beta_i, \beta'_i, \lambda_i, \gamma_i, \sigma_i^2, \mathbf{y}_i) = \prod_{t=1}^T \left\{ \sum_{k=1}^{2^J} \left[\frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left(-\frac{[\epsilon_i(t)]^2}{2\sigma_i^2}\right) \times P[\mathbf{x}'_i(t) = \mathbf{Z}_k] \right] \right\} \quad (2.23)$$

Prioris

Conforme sugestão dos autores Bradlow, Hu e Ho (2004) as distribuições a priori consideradas neste estudo são não informativas e são apresentadas na Tabela 2.5.

Além das prioris dos parâmetros, suas hiperprioris também são descritas na mesma tabela.

Tabela 2.5: Distribuições a priori.

Parâmetro	¹ Priori	Hiperpriori
$u_i(t)$	$N(0; \sigma^2)$	$\sigma^2 \sim \Gamma - \text{Inv}(a, b)$
γ_i	$U[m; n]$	
λ_{im}	$Beta(a_m, b_m)$	$a_m \text{ e } b_m \sim U[k; l]$
β_{ij}	$N(\bar{\beta}_j, \sigma_{j\beta}^2)$	$\bar{\beta}_j \sim N(r, s) \text{ e } \sigma_{j\beta}^2 \sim \Gamma - \text{inv}(c, d)$
β'_{ij}	$N(\bar{\beta}'_j, \sigma_{j\beta'}^2)$	$\bar{\beta}'_j \sim N(u, v) \text{ e } \sigma_{j\beta'}^2 \sim \Gamma - \text{inv}(e, f)$
α_i	$N(\bar{\alpha}, \sigma_{j\alpha}^2)$	$\bar{\alpha} \sim N(z, w) \text{ e } \sigma_{j\alpha}^2 \sim \Gamma - \text{inv}(g, h)$

Por exemplo, o erro aleatório do modelo $u_i(t)$ segue uma distribuição Normal($0; \sigma^2$) enquanto que o termo auto-regressivo do erro γ_i segue uma distribuição a priori Uniforme que varia no intervalo $[-1; 1]$. As prioris dos parâmetros λ_{im} , são dadas por $\lambda_{im} \sim Beta(a_m, b_m)$. Como hiperprioris, assume-se que a_m e b_m distribuem-se uniformemente no intervalo $[1; 100]$. Os coeficientes da regressão β_{ij} , β'_{ij} e α_i seguem uma distribuição Normal.

No que diz respeito às informações à priori, $N_{ij}(t = 0, l_j = l^*)$, assume-se que $N_{ij}(t = 0, l_j = l^*) = 0$, ou seja, que não existe influência sobre o conhecimento a priori sobre a preferência.

¹ $N(\mu; \sigma^2)$: Distribuição Normal com média μ e variância σ^2 ; $\Gamma - \text{Inv}(a, b)$: Distribuição Gama Inversa com parâmetros a e b ; $U[k; l]$: Distribuição Uniforme no intervalo $[k; l]$; $Beta(a, b)$: Distribuição Beta com parâmetros a e b .

Estimação

O uso de procedimentos bayesianos vem crescendo muito nos últimos anos em pesquisas de marketing, principalmente depois da década de 80, quando os primeiros trabalhos utilizando métodos de simulação de Monte Carlo via Cadeias de Markov (MCMC) foram publicados (Allembly et al., 1995). Em 2004 Allembly, Bakken e Rossi exploram os avanços nas pesquisas em Marketing quanto à utilização de técnicas bayesianas, enfatizando os benefícios destas técnicas.

O argumento que suporta tal decisão refere-se ao fato dos métodos bayesianos serem menos restritivos que os métodos clássicos. Acompanhando esta tendência, e seguindo a forma de estimação proposta por Bradlow, Hu e Ho (2004), serão adotados procedimentos bayesianos para estimação dos parâmetros não só pela complexidade do procedimento de imputação adotado como pela grande heterogeneidade das respostas e das formas de imputação que podem ser utilizadas pelos indivíduos pesquisados.

Para a estimação dos parâmetros utilizou-se o pacote WinBugs que dentre as suas vantagens constrói internamente a expressão para a distribuição a posteriori. Neste caso tal expressão apresenta-se bastante complexa, dada a grande quantidade de parâmetros considerados no modelo. O método diagnóstico de convergência adotado é o sugerido por Gelman e Rubin (1992) e posteriormente modificado por Brooks e Gelman(1998).

Aplicação: A Motivação no Ambiente de Trabalho

3.1 Propósito do estudo

Pretende-se avaliar a performance do modelo de imputação via aprendizado, proposto por Bradlow, Hu e Ho (2004), através de sua aplicação em estudo sobre motivação no trabalho. Diferente da maioria dos trabalhos já publicados não só pela metodologia de imputação, mas também pela área escolhida, Recursos Humanos, pretende-se estudar, nesta dissertação, a percepção de indivíduos quanto às características de um emprego a fim de identificar o perfil da equipe bem como direcionar ações motivacionais adequadas para o grupo em estudo .

3.1.1 Motivação

Nas últimas décadas, a preocupação com a satisfação na qualidade de vida dos funcionários aumentou, isso porque a produtividade de um indivíduo está atrelada à sua capacitação e à sua motivação. Muitas empresas nacionais e multinacionais desenvolvem campanhas de motivação pois acreditam que uma equipe motivada possui maior propensão a desenvolver novos projetos e inovar tecnologicamente, o que

gera vantagem competitiva da companhia em relação às suas concorrentes. Segundo artigo publicado na página da internet da Federação das Indústrias do Estado do Rio de Janeiro - ¹FIRJAN, os fatores motivacionais têm uma contribuição direta na qualidade de vida das pessoas e na qualidade de produtos, sendo a força motriz que impulsiona a participação do colaborador e desenvolve um compromisso duradouro com responsabilidade além de um relacionamento frutífero e produtivo, satisfazendo os interesses de ambas as partes.

Segundo Robbins (2002), a motivação de um indivíduo ao desempenhar uma tarefa é fruto da persistência, vontade e satisfação com que ela é realizada e muitas teorias motivacionais levantam diferentes fatores que, isoladamente ou em conjunto, afetam na motivação de um indivíduo. Maslow (1970), em sua obra intitulada *Motivation and Personality*, apresentou uma teoria segundo a qual as necessidades humanas estão dispostas em níveis de importância e influência. A representação mais comum desta hierarquia dá-se através da Pirâmide de Maslow, apresentada na Figura 3.1. Maslow reconhece a existência de um estado permanente de busca do equilíbrio pessoal como fonte da psicodinâmica motivacional.

Outros especialistas em motivação foram Herzberg et al. (1959), que em sua Teoria dos Dois Fatores (Teoria da Higiene-Motivação), afirma existirem dois grupos para motivação de equipes: fatores higiênicos e motivacionais. Segundo este autor, a motivação de um indivíduo pode estar vinculada a fatores motivacionais que a façam sentir bem no trabalho, tais como: responsabilidade, progresso, a função desempenhada, reconhecimento. Ou ainda, a motivação pode também estar associada a fatores, cuja ausência provoque mal-estar, estando relacionados à organização e ao ambiente externo: salário, condições de trabalho, supervisão, vida pessoal, diretrizes de administração da empresa, segurança, dentre outros.

Outras teorias motivacionais, citadas por Robbins (2002) em seu livro *Compor-*

¹www.firjan.org.br. Acessado em janeiro de 2006

Figura 3.1: Pirâmide de Maslow

tamento organizacional, são apresentadas na Tabela 3.1, são o suporte teórico para a identificação dos principais fatores a serem estudados nesta pesquisa.

3.2 A seleção dos atributos

A definição dos fatores foi baseada na obra de Robbins (2002), cuja tabela resumo é a Tabela 3.1, em conjunto com um profissional da área de Recursos Humanos. Foram selecionados os fatores que se destacam na maioria das teorias e aqueles que foram julgados importantes para o desenvolvimento de ações motivacionais nos indivíduos avaliados. Os Fatores pré-selecionados foram:

1. Remuneração
2. Reconhecimento
3. Exposição
4. Jornada de trabalho

Tabela 3.1: Teorias motivacionais e principais fatores.

Teoria	Autor	Principais Fatores
Pirâmide de Maslow	Maslow (1943)	Necessidades Fisiológicas, Segurança, Sociais, Auto-estima e Auto-realização
Dois Fatores	Herzberg (1959)	Fatores Motivadores -trabalho, progresso, responsabilidade, crescimento, realização Fatores Higiênicos -políticas, supervisão, salário, Vida Pessoa, Status, Segurança
Necessidades	McClelland (1962)	Responsabilidade, Feedback, Risco, Poder e Associação
Avaliação Cognitiva	Deming (1990)	Remuneração, Relação com supervisores, Realização, Responsabilidades, Competência
ERG	Clayton Alderfer (1962)	Existência, Relacionamento, Crescimento
Expectativa	Vitor Vroom (1964)	Esforço, Desempenho e Recompensa

5. Gestor

6. Clima na área

7. Desafio

3.2.1 Descrição dos atributos

A escolha dos níveis e a definição de qual seria o nível padrão baseou-se nas características de trabalho de empresas do ramo financeiro, uma vez que funcionários deste segmento da economia foram os participantes deste estudo, bem como contou com o apoio de um profissional da área de Recursos Humanos, especialista em motivação no trabalho.

Remuneração: O que a princípio pode parecer um atributo óbvio quanto à preferência de um respondente, sua utilidade parcial pode revelar traços do perfil do funcionário. Interessa estudar até que ponto a questão financeira interfere na preferência por um emprego ou motiva a troca de emprego. Se duas funções diferenciarem-se somente pela remuneração, espera-se que aquela que possuir um montante maior seja a mais preferida. Contudo, dependendo dos anseios profissionais do respondente, a remuneração pode perder importância frente a questões como exposição, crescimento pessoal e desafios. Para medir o efeito da remuneração, o perfil pode possuir dois níveis, o padrão, onde não há aumento na remuneração, ou alternativamente apresenta-se uma proposta de 20% de aumento no salário anual. A remuneração, ou salário é mais um fator proposto por Herzberg. As descrições dos níveis padrão e alternativo são:

Padrão: Sem aumento no salário anual.

Alternativo: Aumento de 20% no salário anual.

Reconhecimento: O Reconhecimento pelo trabalho desenvolvido é mais um fator avaliado neste estudo. Utilidades parciais elevadas para este atributo dão indícios de que o reconhecimento de um trabalho através de um elogio pode motivar a equipe aumentando seu ego e conseqüentemente a satisfação no ambiente de trabalho. Para representar melhor este atributo, optou-se por separar elogios vindo por colegas de mesmo nível hierárquico ou feitos por seus gestores. Este atributo está relacionando indiretamente com o fator motivacional Realização citado tanto pelas teorias das necessidades de McClelland quanto da Avaliação Cognitiva de Deming. Os níveis padrão e alternativo são assim descritos:

Padrão: Trabalho reconhecido pelo gestor.

Alternativo: Trabalho reconhecido pelos colegas.

Exposição: A apresentação da exposição de um funcionário dentro de seu ambiente de trabalho procura medir o nível de exposição desejada e conseqüentemente

a confiança do funcionário na qualidade de seu trabalho. A exposição é descrita de duas formas: horizontal e vertical. A exposição horizontal trata da exposição junto a seus colegas de trabalho (mesmo nível hierárquico), enquanto que a vertical permite ao funcionário relacionar-se com níveis sênior da organização, tais como: comissões executivas, diretorias, etc. Uma exposição vertical, além de permitir contatos mais influentes, pode também estar associada a riscos maiores e com certeza exigirá um preparo muito maior daquele necessário no caso de uma exposição horizontal. A descrição deste atributo é feita pelos seguintes níveis:

Padrão: Exposição horizontal.

Alternativo: Exposição vertical.

Jornada de trabalho: A carga excessiva de trabalho é um fator muito presente em diversas pesquisas de satisfação. Em tempos de concorrência acirrada, o dito popular “tempo é dinheiro” convive diariamente com todos funcionários de qualquer organização e as 8 horas diárias de trabalho podem não ser suficientes para cumprir todas as tarefas. Enquanto para alguns a carga excessiva de trabalho possa parecer um transtorno, por outro lado, se o funcionário gostar de suas atividades e se sentir motivado com a sua função a ser desempenhada, este atributo pode não apresentar uma importância relativa muito grande. Duas cargas horárias são apresentadas: 40 a 50 horas semanais, descrevendo uma carga normal de trabalho, e acima de 50 horas semanais, que exige uma dedicação de aproximadamente acima de 10h de trabalho/dia. A carga horária é citada indiretamente pelas teorias de Herzberg, que cita a vida pessoal como sendo um fator higiênico de motivação. Os níveis apresentados foram:

Padrão: Jornada de trabalho de 40 a 50 horas semanais.

Alternativo: Jornada de trabalho superior a 50 horas semanais.

Gestão: A proximidade e empatia com o tipo de gestão feita pelo supervisor da área pode influenciar na motivação de uma equipe. Dessa maneira, o atributo Gestor

procura medir a atuação no gestor na satisfação de um funcionário. Uma equipe ou determinadas funções exigem uma gestão mais participativa, enquanto outras tendem a preferir uma gestão mais omissa. Este atributo visa medir a importância da forma da gestão na motivação dos funcionários. Quanto à forma de gestão os níveis foram:

Padrão: Gestor Omissa.

Alternativo: Gestor participativo.

Clima na área As condições de trabalho, citada pela Teoria de Avaliação Cognitiva, aparece neste estudo através do atributo clima na área. Muitas vezes, o relacionamento com colegas de trabalho mostra-se um fator importante no momento da escolha ou troca de emprego. Para estimar a importância relativa deste fator, considera-se na formação dos estímulos duas equipes diferentes: competitiva ou colaborativa. Uma equipe competitiva pode estimular o ambiente, fazendo com que os funcionários sintam-se estimulados a apresentar sempre resultados melhores, ou ainda despertar desentendimentos internos, o que pode ser prejudicial à área como um todo. Optou-se por considerar como nível padrão do atributo clima na área o clima competitivo, dado que o local onde a pesquisa foi conduzida é muito competitivo.

Padrão: Clima da área competitivo entre os colegas.

Alternativo: Clima colaborativo na área entre os colegas.

Desafio: Através da avaliação da pré-disposição de enfrentar desafios, pretende-se medir quão aberto a novos desafios está o funcionário e até mesmo a equipe. A frequência de exposição a novos desafios, medida por dois níveis: Constantemente desafiado e Raramente desafiado está bastante relacionada com a estabilidade no emprego, uma vez que na maioria dos casos à medida que o desafio aumenta há uma tendência de aumento na cobrança sobre o desempenho do funcionário ao exercer tal atividade. Uma vez que público pesquisado desempenha atividades que o expõe a desafios com muita frequência, optou-se por descrever o nível padrão do atributo desafio como frequentes. A seguir caracteriza-se, respectivamente, o nível padrão e

o nível alternativo do atributo desafio:

Padrão: Desafios freqüentes.

Alternativo: Raros desafios.

3.2.2 Planejamento da pesquisa e apresentação dos estímulos

Sete atributos, com dois níveis cada, foram selecionados, o que gerou 128 ($2^7=128$) estímulos compostos por diferentes combinações de atributos e níveis. Dado o elevado número de estímulos, torna-se inviável a avaliação do delineamento completo por parte dos indivíduos (Bradlow, Hu e Ho, 2004). A estratégia adotada para a formação dos estímulos contou com utilização de delineamentos fatoriais fracionários, muito útil para a redução no número de perfis apresentados aos respondentes (Plackett e Burman, 1946). Com isso, 20 estímulos foram selecionados: 16 para estimação das utilidades e 4 para validação (*holdouts*) todos eles ortogonais, o que garante a estimabilidade dos efeitos principais sem que seja necessário testar todas as combinações dos níveis dos fatores. O delineamento utilizado neste estudo, exibido na Tabela 3.2, considera o nível 0 como sendo o nível padrão dos fatores e 1 o nível alternativo.

Por exemplo, o primeiro estímulo caracteriza uma função, ou atividade que não oferece aumento na remuneração anual em relação à atual, cujos colegas reconhecem o trabalho desenvolvido e em que existe uma exposição a níveis superiores da organização acompanhado de uma jornada de 40 a 50 horas semanais. Além disso, o gestor por sua vez tem um papel omissor no dia-a-dia e o clima da área mostra-se bastante competitivo com desafios freqüentes ao funcionário.

Para comparar as estimativas das utilidades parciais sob diferentes métodos de estimação, e verificar a influência da omissão de um ou mais atributos na preferência dos respondentes optou-se por realizar a pesquisa em duas etapas, respeitando procedimentos de um estudo cross-over (Agresti, 1990). Assim, na primeira etapa da pesquisa um grupo de respondentes avaliou estímulos completos, ou seja, estímulos

Tabela 3.2: Delineamento Fatorial Fracionário.

Estímulo	Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima	Desafios
1	0	1	1	0	0	0	1
2	0	1	0	1	1	0	0
3	0	0	0	0	0	0	0
4	1	0	0	1	0	1	1
5	1	1	1	1	0	0	1
6	0	0	0	0	0	1	1
7	1	0	0	1	0	0	0
8	1	1	0	0	1	0	0
9	0	0	1	1	1	0	1
10	0	1	1	0	0	1	0
11	0	0	1	1	1	1	0
12	1	1	1	1	0	1	0
13	0	1	0	1	1	1	1
14	1	1	0	0	1	1	1
15	1	0	1	0	1	0	1
16	1	0	1	0	1	1	0
17	1	0	0	1	1	0	0
18	0	1	0	0	0	0	1
19	1	1	0	0	1	0	1
20	0	1	1	1	0	1	1

descritos por todos os atributos considerados no estudo, tal como apresentado na Tabela 3.2.

Enquanto isso, o segundo e terceiro grupo avaliou atributos, formados pelo mesma combinação de níveis de atributos exceto pela omissão de um ou mais atributos em cada um dos estímulos. As Tabelas 3.3 e 3.4 a seguir apresenta o delineamento com um e dois atributos ausentes por estímulo, respectivamente.

Na etapa seguinte aqueles respondentes que receberam estímulos completos passaram a avaliar estímulos incompletos (com um ou dois atributos ausentes) e vice-versa. Optou-se ainda pela não omissão dos atributos Remuneração e Reconhecimento, isso porque eles são freqüentemente confundidos pelos indivíduos ao questionar sobre quais fatores são importantes em um ambiente de trabalho. O primeiro refere-se mais ao aspecto financeiro e o segundo ao reconhecimento ou elogio recebido por uma atividade bem desempenhada.

Na formação dos estímulos incompletos, a omissão dos atributos foi feita de forma arbitrária tomando o devido cuidado de não gerar combinações repetidas entre os

Tabela 3.3: Delineamento incompleto com a omissão de 1 atributo.

Estímulo	Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima	Desafios
1	0	1		0	0	0	1
2	0	1	0		1	0	0
3	0	0	0	0	0		0
4	1	0	0	1		1	1
5	1	1	1	1	0	0	
6	0	0		0	0	1	1
7	1	0	0	1	0	0	
8	1	1	0		1	0	0
9	0	0	1	1	1		1
10	0	1	1	0	0		0
11	0	0	1	1		1	0
12	1	1		1	0	1	0
13	0	1	0		1	1	1
14	1	1	0	0		1	1
15	1	0	1		1	0	1
16	1	0	1	0	1	1	
17	1	0		1	1	0	0
18	0	1	0	0		0	1
19	1	1	0	0	1	0	
20	0	1	1	1	0		1

demais níveis presentes no estímulo para não confundir os respondentes durante o processo de quantificação das preferências. A omissão dos níveis foi controlada de tal forma que os níveis devessem aparecer em um número igual de vezes, ou muito próximos no total dos estímulos avaliados.

Segundo o método de estimação das utilidades via aprendizado proposto por Bradlow, Hu e Ho (2004), a ordem de apresentação dos estímulos pode modificar a percepção do respondente sobre o produto sob avaliação e para verificar tal suposição embaralharam-se os estímulos de quatro maneiras distintas. Dessa forma, cada um dos três diferentes delineamentos apresenta estímulos ordenados de maneiras distintas.

Foram pesquisados 74 funcionários de distintas instituições financeiras e áreas de negócio. Na primeira fase da pesquisa, além da classificação das preferências, coletou-se algumas variáveis demográficas tais como sexo, idade, tempo de empresa e escolaridade, a fim de verificar se a maturidade de um funcionário pode alterar substancialmente suas preferências.

Tabela 3.4: Delineamento incompleto com a omissão de 2 atributos.

Estímulo	Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima	Desafios
1	0	1		0	0		1
2	0	1	0			0	0
3	0	0	0	0	0		
4	1	0	0			1	1
5	1	1	1	1	0		
6	0	0			0	1	1
7	1	0		1	0	0	
8	1	1	0			0	0
9	0	0		1	1		1
10	0	1	1	0			0
11	0	0		1		1	0
12	1	1		1	0	1	
13	0	1	0		1		1
14	1	1		0		1	1
15	1	0	1		1	0	
16	1	0	1	0	1		
17	1	0			1	0	0
18	0	1	0			0	1
19	1	1	0	0	1		
20	0	1	1	1			1

Na fase de classificação e quantificação de suas preferências, os respondentes foram convidados a atribuir uma nota de 0 a 100 para cada estímulo apresentado tomando o cuidado de não repetir a mesma nota para estímulos distintos.

A apresentação dos estímulos foi antecedida por uma breve descrição dos atributos e níveis avaliados, bem como uma avaliação de um estímulo composto por todos os níveis alternativos. Para a quantificação da preferência, foram utilizados os dezesseis primeiros estímulos para a estimação das utilidades parciais e os quatro restantes para validação (estímulos *holdout*). O questionário (apresentado no Anexo A.3) foi entregue pessoalmente a cada um dos funcionários porém a classificação dos estímulos foi feita sem a presença da pesquisador, podendo ser realizada tanto durante o expediente como em um horário fora do ambiente de trabalho.

As duas etapas de classificação propostas pelo delineamento *cross-over* foram espaçadas por 30 dias, o que pode minimizar o efeito de memória de um questionário para o seguinte. Na primeira fase da pesquisa, o retorno de questionários foi substancial, contudo, na segunda fase, poucos participantes entregaram o instrumento da

pesquisa preenchido, o que gerou uma perda significativa no número final de entrevistados. Decidiu-se, então, pelo envio de mais questionários, via correio eletrônico para mais alguns funcionários. Neste caso, quase que em sua totalidade retornou com resposta positiva. A Tabela 3.5 apresenta o número de respondentes para cada um dos tipos de questionários avaliados em ambas as fases da pesquisa.

Tabela 3.5: Distribuição dos questionários.

Omissões	Fase 1	Fase 2	Total
Completo	30	18	48
1 omissão	27	9	36
2 omissões	12	10	22

As estimativas dos parâmetros dos modelos foram geradas no pacote estatístico R com auxílio da rotina BRugs, que permite utilizar toda gama de procedimentos de estimação bayesiana disponíveis no software WinBugs, com a interface do R. Os resultados aqui apresentados estão baseados em uma amostra 100.000 repetições e um período de amostragem igual a 15. Alguns questionários foram excluídos da análise por erro no auto-preenchimento.

Estimação dos Modelos e Comparação de Métodos

Neste capítulo serão apresentados os principais resultados obtidos com a aplicação dos diferentes métodos de estimação. Pretende-se detectar eventuais diferenças ou similaridades entre as estimativas das utilidades parciais, além de identificar os principais fatores que afetam a preferência dos funcionários.

Os modelos de APC foram estimados a partir da adaptação do código de ¹programação do pacote WinBugs para a interface do software R, através da rotina BRugs (ver Apêndice A.2). Uma vantagem da utilização do pacote R é a sua praticidade e facilidade de manuseio dos resultados, contudo, o tempo de processamento, principalmente quando a imputação foi realizada segundo o procedimento de aprendizado, permaneceu bastante elevado, chegando a mais de uma hora por indivíduo, tal como obtido quando somente o pacote WinBugs fora utilizado.

Para a estimação dos parâmetros dos modelos optou-se por distribuições a priori e hiperprioris iguais àquelas apresentadas pela Tabela 4.1

¹[http : //mktgweb.wharton.upenn.edu/ebradlow/research_files.htm](http://mktgweb.wharton.upenn.edu/ebradlow/research_files.htm)

Tabela 4.1: Distribuições a priori adotadas neste trabalho.

Parâmetro	Priori	Hiperpriori
$u_i(t)$	$N(0; \sigma^2)$	$\sigma^2 \sim \Gamma - Inv(0.1, 0.1)$
γ_i	$U[-1; 1]$	
λ_{im}	$Beta(a_m, b_m)$	$a_m \sim U[1; 100]$ e $b_m \sim U[1; 100]$
β_{ij}	$N(\bar{\beta}_j, \sigma_{j\beta}^2)$	$\bar{\beta}_j \sim N(0; 0.01)$ e $\sigma_{j\beta}^2 \sim \Gamma - inv(0.1, 0.1)$
β'_{ij}	$N(\bar{\beta}'_j, \sigma_{j\beta'}^2)$	$\bar{\beta}'_j \sim N(0; 0.01)$ e $\sigma_{j\beta'}^2 \sim \Gamma - inv(0.1, 0.1)$
α_i	$N(\bar{\alpha}, \sigma_{j\alpha}^2)$	$\bar{\alpha} \sim N(0; 0.01)$ e $\sigma_{j\alpha}^2 \sim \Gamma - inv(0.1, 0.1)$

4.1 Medidas de diagnóstico do ajuste dos modelos

Modelos distintos quanto à regra de imputação e a forma funcional foram considerados na estimação das utilidades parciais com a finalidade de comparar os resultados quanto às medidas de ajuste, estimativas dos parâmetros e importâncias relativas e ao ajuste do modelo. Os seguintes modelos foram testados:

1. Modelo de perfis completos

O modelo de regressão proposto para estimar as utilidades parciais para a situação em que perfis completos são avaliados é um modelo de regressão linear tradicional. A expressão neste caso é idêntica à expressão (1.2)

2. Modelo de perfis incompletos

Como primeira alternativa de estimação para perfis incompletos, utilizou-se um modelo cuja forma funcional é idêntica ao modelo proposto na situação anterior

$$(y_i(t) = \alpha_i + \sum_{j=1}^J \beta_{ij} x_{ij}(t) + \epsilon_i(t)).$$

Como segunda opção, incluiu-se um termo indicador da presença/ausência do atributo no estímulo avaliado (β'), tal como proposto pela expressão (2.3).

No caso de modelos com perfis incompletos, o fato de o modelo possuir um ou dois atributos ausentes não altera sua forma funcional nem a regra de imputação utilizada. A única diferença é que em vez de imputar um único valor por perfil estarão sendo imputados dois valores simultaneamente. Em todos os modelos optou-se por considerar o componente auto-regressivo no erro (expressão (2.22)).

As regras de imputação utilizadas neste estudo foram:

1. Valor Padrão: Sempre que um atributo estiver ausente, o valor imputado será o nível padrão do atributo. A expressão que rege este processo é idêntica à (2.6).
2. Recência: O valor imputado será igual ao último nível visto para o atributo ausente, conforme expressão (2.8).
3. Aprendizado: O procedimento segue as regras apresentadas na Seção 3.1.5.

No geral todos os modelos apresentaram um bom ajuste. Quanto à convergência, cerca de 5% dos casos de estimação segundo o modelo de aprendizado apresentaram algum problema, principalmente quando os valores de preferência (y_{ij}) eram muito similares. Já os demais modelos não apresentaram problemas de convergência. Estão disponíveis no apêndice A.5 alguns gráficos de densidades e de critérios de convergência avaliados.

A Tabela 4.2 traz informações de algumas medidas utilizadas para comparar o ajuste do modelo completo com os modelos que possuem a omissão da descrição de um atributo em um perfil. Foram calculados, além da estatística de Akaike(AIC), os erros de estimação (erro quadrático médio e erro absoluto médio) para as amostras

de estimação e validação do modelo. Para fins comparativos, calculou-se o percentual de variação dos erros em relação ao modelo com perfis completos e a correlação de Spearmann entre o valor observado e o valor estimado para cada um dos modelos. O parâmetro que mede o efeito médio de auto-correlação no erro (γ) também foi apresentado, e como se pode observar, exceto para o modelo de perfis completos não apresentou grandes variações.

Tabela 4.2: Resumo das medidas de ajuste dos modelos com 1 omissão.

Medidas de ajuste		Completo	Padrão	Padrão	Recência	Recência	Aprendizado
				(β')		(β')	
	$\ln(L)$	-2,91	-2,97	-2,96	-2,93	-3,01	-2,26
	AIC	186,1	190,2	331,9	187,5	337,6	307,5
EAM	Estimação	7,69	9,90	10,36	8,47	10,78	6,58
	(%)		28,7%	34,7%	10,1%	40,2%	-14,4%
	Validação	15,55	18,36	13,35	15,97	14,87	15,19
	(%)		18,1%	-14,1%	2,7%	-4,4%	-2,3%
EQM	Estimação	116,59	204,83	204,80	136,65	217,92	140,52
	(%)		75,7%	75,7%	17,2%	86,9%	20,5%
	Validação	439,21	500,61	322,59	381,76	335,45	384,02
	(%)		14,0%	-26,6%	-13,1%	-23,6%	-12,6%
Corr	(y e $\hat{y}$)	77%	79%	74%	81%	78%	90%
	γ	0,09	0,19	0,18	0,18	0,18	0,10

O modelo de Aprendizado apresentou o menor erro absoluto médio (EAM), cerca de 14% inferior ao erro encontrado para o modelo completo. Também é no modelo de Aprendizado que se encontra a maior correlação de Spearmann entre o valor de preferência observado e o esperado, cerca de 90%. Isto pode ser devido ao fato do modelo de aprendizado possuir um número de parâmetros maior que os demais modelos.

Outro modelo que também apresentou bons resultados foi o modelo cuja estimação deu-se através da imputação via recência, sem a utilização do termo indicador de presença/ausência do atributo no estímulo(β'). Além de possuir um baixo valor para a estatística AIC apresentou bons resultados para os erros EQM , EAM tanto na amostra de estimação quanto na validação e correlação alta entre valor de preferência observado e estimado.

Os resultados dos modelos estimados quando duas omissões foram realizadas em cada um dos estímulos são apresentados pela Tabela 4.3. Encontram-se bons resultados para os modelos que utilizam a imputação via recência estando ou não presente o termo β' . Observando a estatística AIC o modelo de recência, sem o termo β' , apresenta melhores resultados, isso porque possui um número menor de parâmetros a estimar. Em todos os casos, as correlações entre valores de preferência observados e estimados continuam superiores a 70%.

Embora seja possível aplicar o modelo de aprendizado mesmo no caso onde mais que um atributo é omitido simultaneamente, o tempo de processamento necessário é muito elevado, tornando baixa a relação custo-benefício. Por esse motivo não se utilizou neste trabalho tal forma de imputação no caso da omissão de dois atributos.

Para o caso específico do modelo de aprendizado mais um parâmetro, λ , deve ser avaliado. Este parâmetro procura mensurar a influência das demais variáveis no nível imputado de um atributo ausente. Em todos os atributos, as estimativas de λ apresentam média próxima 0,5 sugerindo que o procedimento de imputação via aprendizado difere de procedimentos, tais como o de imputação via valor padrão, ou ausência de imputação, uma vez que o peso da informação anteriormente avaliada pelo respondente tende a alterar o julgamento da preferência.

As estimativas das utilidades parciais exibidas pelas Tabelas 4.4 e 4.5, no geral, apresentam similaridades no que diz respeito ao sinal dos coeficientes dos atributos Reconhecimento e Jornada de Trabalho, ambos negativos. O sinal negativo representa

Tabela 4.3: Resumo das medidas de ajuste dos modelos com 2 omissões.

Medidas de ajuste		Completo	Padrão	Padrão (β')	Recência	Recência (β')
$\ln(L)$		-2,908	-2,958	-2,915	-2,889	-2,954
AIC		186,11	189,31	326,48	184,90	330,85
EAM	Estimação	7,87	7,42	8,17	7,00	7,94
	(%)		-5,7%	3,8%	-11,1%	0,9%
	Validação	17,7	15,23	13,7	15,04	12,51
	(%)		-14,0%	-22,6%	-15,0%	-29,3%
EQM	Estimação	110,72	99,36	119,03	92,5	122,64
	(%)		-10,3%	7,5%	-16,5%	10,8%
	Validação	254,59	361,52	344,43	399,61	269,34
	(%)		42,0%	35,3%	57,0%	5,8%
Corr	(y e $\hat{y}$)	75,6%	74,3%	74,5%	73,3%	72,3%
γ		0,09	0,08	0,19	0,16	0,18

respectivamente que a preferência dos funcionários é menor quando o reconhecimento vem dos colegas e/ou quando a jornada de trabalho proposta supera as 50 horas semanais.

Tabela 4.4: Utilidades Parciais dos modelos de APC com 1 omissão (n=16).

Modelo		Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima na área	Desafios	Intercepto
Completo	Média	22,76	-2,44	5,90	-4,47	11,37	2,79	9,29	28,46
	d.p.	16,13	13,13	6,62	13,15	10,47	12,97	4,70	18,60
Padrão	Média	24,02	-1,32	9,06	-5,58	4,65	13,86	10,98	28,36
	d.p.	15,34	5,57	10,36	12,64	9,09	7,42	6,91	14,08
Padrão + β'	Média	24,17	-2,47	5,99	-10,37	7,69	8,93	9,67	8,72
	d.p.	11,23	1,21	4,61	2,52	1,57	2,12	5,44	7,51
Recência	Média	22,56	0,07	8,76	-3,81	11,00	10,92	12,19	21,69
	d.p.	15,95	6,37	9,97	9,98	8,38	9,65	7,86	13,09
Recência + β'	Média	23,18	-2,10	7,19	-5,94	10,61	8,44	7,11	7,06
	d.p.	9,89	1,55	3,64	1,57	2,54	4,36	2,83	4,15
Aprendizado	Média	20,92	-0,23	7,48	-6,02	8,50	10,47	11,10	8,72
	d.p.	17,62	3,78	7,71	9,66	7,60	8,73	7,93	7,51

Tabela 4.5: Utilidades Parciais dos modelos de APC com 2 omissões (n=15).

Modelo		Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima na área	Desafios	Intercepto
Completo	Média	19,26	-1,31	3,37	-5,44	6,84	1,20	9,95	31,58
	d.p.	12,93	7,55	6,40	7,45	10,07	9,10	7,63	17,98
Padrão	Média	27,74	-2,87	3,97	-1,73	7,36	5,94	9,23	30,15
	d.p.	17,35	7,50	10,59	7,77	11,62	11,20	9,96	20,30
Padrão + β'	Média	23,52	-3,68	1,27	-2,48	9,95	4,33	11,97	12,47
	d.p.	17,20	2,54	1,31	3,42	4,19	6,92	9,02	14,71
Recência	Média	24,50	-1,30	0,79	-0,48	7,85	6,83	11,13	22,82
	d.p.	16,56	8,00	8,05	10,45	9,27	9,43	11,82	23,44
Recência + β'	Média	23,74	-1,99	1,72	-0,85	8,07	3,38	12,21	7,66
	d.p.	17,27	1,01	1,78	3,66	1,18	3,68	9,93	15,44

A Tabela 4.6, contém as informações dos parâmetros β' . Para o modelo de aprendizado, os parâmetros que mensuram a influência da presença do atributo em um estímulo possuem grande variabilidade enquanto que os dois últimos apresentam desvios padrões menores.

Tabela 4.6: Estimativas para β' quando há a omissão de 1 atributo (n=16).

Modelo	Coeficientes		Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão na área	Clima	Desafios	Int.
Completo	β	Média	22,76	-2,44	5,90	-4,47	11,37	2,79	9,29	28,46
		d.p.	16,13	13,13	6,62	13,15	10,47	12,97	4,70	18,60
Aprendizado	β	Média	20,92	-0,23	7,48	-6,02	8,50	10,47	11,10	8,72
		d.p.	17,62	3,78	7,71	9,66	7,60	8,73	7,93	7,51
	β'	Média			4,54	6,33	2,47	6,00	3,02	
		d.p.			5,19	4,59	3,43	5,20	5,24	
Padrão + β'	β	Média	24,17	-2,47	5,99	-10,37	7,69	8,93	9,67	8,72
		d.p.	11,23	1,21	4,61	2,52	1,57	2,12	5,44	7,51
	β'	Média			6,15	15,02	2,50	5,60	2,20	
		d.p.			1,17	1,70	1,31	0,78	2,11	
Recência+ β'	β	Média	23,18	-2,10	7,19	-5,94	10,61	8,44	7,11	7,06
		d.p.	9,89	1,55	3,64	1,57	2,54	4,36	2,83	4,15
	β'	Média			4,16	8,73	4,01	6,43	4,34	
		d.p.			1,75	2,11	0,86	1,38	1,85	

4.1.1 Concordância entre as estimativas dos modelos

Além das medidas de ajuste dos modelos, é importante verificar se as estimativas dos diferentes modelo para o valor de preferência ($\hat{y}_i(t)$) são ou não concordantes entre si.

O cálculo da concordância dos modelos sobre o atributo de maior preferência aponta que a maioria dos indivíduos pesquisados apontam o atributo Remuneração (atributo 1) como sendo aquele de maior importância, conforme resultados apresentados pela Tabela 4.7. No caso do modelo de perfis completos, dos 48 respondentes, 70% apontam a Remuneração como principal fator de preferência por um emprego, sendo que os demais atributos não foram os mais importantes em mais de 10% dos casos.

Tabela 4.7: Atributos de maior preferência

Modelo	n	Atributos						
		Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima na área	Desafios
Completo	48	70,8%	6,3%	2,1%	4,2%	6,3%	4,2%	6,3%
1 Omissão								
Padrão	35	37,1%		5,7%	8,6%	11,4%	22,9%	14,3%
Padrão+ β'	35	57,1%				31,4%	11,4%	
Recência	35	40,0%	2,9%		2,9%	25,7%	17,1%	11,4%
Recência+ β'	35	54,3%				31,4%	8,6%	5,7%
Aprendizado	30	40,0%			16,7%	16,7%	16,7%	10,0%
2 Omissões								
Padrão	22	72,7%			4,5%	9,1%	4,5%	9,1%
Padrão+ β'	22	54,5%				18,2%		27,3%
Recência	22	50,0%	4,5%	4,5%	4,5%	13,6%	4,5%	18,2%
Recência+ β'	22	63,6%				9,1%		27,3%

Tabela 4.8: Atributos de maior preferência por quantidade de omissões

		Atributos						
Modelo	n	Remuneração	Reconhecimento	Exposição	Jornada de Trabalho	Gestão	Clima na área	Desafios
1 Omissão								
Completo	16	75,0%	12,5%			6,3%	6,3%	
Padrão		50,0%		6,3%	18,8%	6,3%	12,5%	6,3%
Padrão+ β'		93,8%					6,3%	
Recência		50,0%	6,3%		6,3%	18,8%	12,5%	6,3%
Recência+ β'		87,5%					12,5%	
Aprendizado		42,9%		14,3%	14,3%	14,3%	14,3%	
2 Omissões								
Completo	15	60,0%	6,7%	6,7%		6,7%	6,7%	13,3%
Padrão		73,3%			6,7%	6,7%	6,7%	6,7%
Padrão+ β'		60,0%				13,3%		26,7%
Recência		53,3%	6,7%	6,7%	6,7%	13,3%	6,7%	6,7%
Recência+ β'		66,7%				13,3%		20,0%

Para os modelos de perfis incompletos com um atributo omitido, embora a remun-

neração tenha sido encontrada mais freqüentemente como o atributo mais importante, de 37% a 54% dos casos, outros atributos como a Forma de Gestão, Clima na Área e Desafios também se destacam.

Ainda no que diz respeito à preferência dos atributos, outra medida interessante é o percentual de concordância do estímulo preferido. A Tabela 4.8 apresenta a concordância do modelo completo com os demais resultados encontrados para os modelos com 1 e 2 estímulos omitidos.

Aplicação

Neste capítulo são apresentados os principais resultados encontrados no estudo sobre preferências no trabalho, tais como as importâncias relativas de cada um dos atributos e também a segmentação do grupo de funcionários avaliados segundo suas preferências.

5.1 Principais resultados

O cálculo das importâncias relativas dos atributos envolvidos no estudo é mais uma das etapas de um estudo de análise de preferência conjunta. Através de sua análise, é possível identificar um ou mais atributos que mais influenciam na preferência dos respondentes.

A importância relativa do j -ésimo atributo é obtida conforme a expressão (5.1).

$$IR\% = \frac{\beta_{ij}}{\sum_j \beta_{ij}} \times 100 \quad (5.1)$$

Comparando as utilidades geradas pelos modelos de perfis completos com aquelas geradas pelo modelo de aprendizado, exibidas na Figura 5.1, observa-se que há grande similaridade entre os seus resultados, quando os mesmos indivíduos são avaliados. A

Remuneração aparece como o atributo de maior importância, cerca de 30% do total.

Figura 5.1: Importância média relativa dos Modelos Completo e Aprendizado com 1 omissão.

As utilidades parciais estimadas a partir dos estímulos que possuíam um atributo ausente para os diferentes modelos novamente apontam a Remuneração como o atributo de maior importância, seguido pelos atributos Gestão, Clima da Área e Frequência de Desafios.

Figura 5.2: Importância Relativa - Perfis Incompletos - 1 omissão.

Figura 5.3: Importância Relativa - Perfis Incompletos - 1 omissão + β' .

Para o caso em que dois atributos foram omitidos na descrição do estímulo, novamente ocorre a prevalência da Remuneração como o atributo de maior importância.

Figura 5.4: Importância Relativa - Perfis Completos.

No geral, em todos os modelos a remuneração, gestão e desafios acumulam grande proporção da preferência dos entrevistados. Com um pouco menos de influência, o clima do ambiente de trabalho e a forma de exposição dentro da instituição também se destacam.

A fim de melhor descrever os resultados encontrados bem como tentar encontrar padrões de comportamento quanto à preferência no trabalho, realizou-se uma análise de agrupamento (*Cluster Analysis*) a partir das importâncias relativas de cada um dos indivíduos estimadas através do modelo de Aprendizado.

Figura 5.5: Importância Relativa - Perfis Incompletos - 2 omissões.

Figura 5.6: Importância Relativa dos modelos Padrão e Recência com o termo β' - 2 omissões.

A formação dos grupos foi feita através de um agrupamento hierárquico, obtido pelo método de Ward, cujo dendrograma é o apresentado pela Figura 5.7. Identificou-se quatro grupos de respondentes que apresentam comportamentos diferenciados quanto às Importâncias relativas, conforme visto na Figura 5.8.

Os resultados descritivos dos grupos encontrados estão detalhados na Tabela 5.1. O Grupo 1, formado por 10 indivíduos que apontam a Remuneração como atributo de sua maior preferência. Em sua maioria possuem Pós Graduação (50%) com idade média de 27 anos. Estes respondentes estão no seu emprego atual há 25 meses em

Figura 5.7: Análise de Agrupamento - Dendrograma.

média e atuam no mercado há aproximadamente 6 anos e meio em média. As teorias de Herzberg e Deming, apresentadas na Tabela 3.1, citam a remuneração como fator motivacional.

A teoria dos Dois Fatores de Herzberg aponta a Vida Pessoal como um dos fatores higiênicos de motivação. Segundo a análise de agrupamentos, o segundo grupo é composto por pessoas que têm como atributo de maior importância relativa a Jornada de trabalho(31,5%) seguida pela forma de Gestão (19,5%). Em sua maioria, este grupo é formado por indivíduos do sexo feminino, com ensino superior completo e com 26,5 anos em média. Seu tempo médio de atuação no mercado é de 7,4 anos e estão na empresa atual há 17 meses, em média.

O terceiro grupo encontrado constitui-se de indivíduos que julgam o clima da área

Figura 5.8: Análise de Agrupamento - Importâncias Médias para cada Grupo.

Tabela 5.1: Descrição dos Grupos.

	Grupos			
	1	2	3	4
Tamanho do Grupo	10	5	5	10
Formação	POS	ESC	ESC/POS	ESI/POS
Idade (anos)	27,4	26,5	24,2	29,5
Tempo de Mercado (anos)	6,6	7,4	3,4	3,8
Tempo de Empresa (meses)	25	17	17	15
Sexo predominante	Masculino	Feminino	Masculino	Feminino

e a remuneração como atributos muito importantes, respectivamente 36% e 21%, respectivamente. Este grupo apresenta idade média um pouco inferior aos demais, 24 anos, e também é aquele com menor tempo médio de experiência no mercado, 3,4 anos. A Teoria ERG de motivação cita o Relacionamento, aqui presente através do atributo clima na área, como um dos fatores importantes de motivação.

Por fim, o último grupo considera a forma de gestão e a frequência de novos desa-

fios como os atributos de maior importância, acompanhados pela remuneração. Segundo a teoria motivacional de avaliação cognitiva, proposta por Deming (ver Tabela 3.1, estes são fatores importantes na motivação das pessoas. Este grupo é formado por mulheres (60%) e embora possua a maior média de idade, 29,5 anos, o tempo médio no mercado(3,8 anos) e o tempo médio que está no trabalho atual (15 meses) estão entre os menores encontrados, talvez pelo fato de que 40% dos indivíduos que pertencem a este grupo possuem ensino superior incompleto.

Considerações finais e futuros estudos

Neste trabalho foram apresentados diferentes métodos de estimação das utilidades parciais para o caso em que perfis incompletos são utilizados em estudos de APC. Em especial, avaliou-se o desempenho do método de imputação via aprendizado, proposto por Bradlow, Hu e Ho (2004), que mostrou bons resultados quando comparado aos demais métodos mais conhecidos na literatura.

Os respondentes em muitos casos sentem falta de um atributo quando este não está descrito no estímulo, principalmente se este for aquele de sua preferência e tendem a compensar esta ausência seja através de conhecimentos anteriores ou via associação aos demais atributos apresentados.

O desafio de aplicar a metodologia de APC em um estudo sobre preferências no trabalho tem por objetivo ampliar a utilização desta metodologia de pesquisa em outras áreas de conhecimento, uma vez que tal técnica já tem boa aceitação nos estudos de marketing e desenvolvimento de produtos.

Além disso, percebeu-se durante a realização da pesquisa, que os entrevistados tiveram uma dificuldade maior em quantificar suas preferências quanto ao objeto em estudo, talvez pelo fato de não ser um produto físico e sim um serviço ou uma

atividade. E a exemplo do que ocorre em avaliações de produtos comercializados, o custo, ou ganho, aqui representado pela Remuneração, exerce um papel importante no valor de preferência do indivíduo.

No que se refere à estimação dos modelos, a utilização de perfis incompletos na estimação das utilidades parciais parece ser uma boa saída nos casos onde muitos atributos ou níveis são testados simultaneamente. Mesmo que ao avaliar um estímulo com atributos omitidos (perfil incompleto) um respondente tenda a compensar a ausência de informação utilizando algum procedimento de imputação, as estimativas das utilidades parciais encontradas não se mostram muito diferentes daquelas encontradas quando perfis completos são avaliados.

Neste estudo sobre preferências no ambiente de trabalho, o modelo de Aprendizado, embora tenha apresentado bons resultados, demandou um tempo de processamento muito superior aos demais métodos, o que o deixa em desvantagem frente ao modelo de imputação via recência, por exemplo. O modelo de recência, além de resultados muito próximos ao modelo de perfis completos possui formulação relativamente simples, além de apresentar um baixo tempo de processamento, mostrando-se assim um bom método de imputação para estes dados.

No que diz respeito à implementação computacional, encontrou-se dificuldades com a implementação e estimação dos modelos, dado que são poucos os softwares estatísticos disponíveis que já possuem ferramental próprio para a aplicação de estudos de preferência, ainda mais no que diz respeito à estimação através de métodos bayesianos. Isto cria uma demanda maior de tempo dedicado ao desenvolvimento e programação de rotinas de análise. Neste trabalho utilizou-se o pacote BRugs do software estatístico R que utiliza todo o ferramental bayesiano disponibilizado pelo pacote WinBugs através da linguagem de programação do R. Os procedimentos já disponíveis, em sua maioria, não diferenciam a estimação quando o delineamento utilizado for composto por perfis completos ou incompletos, não havendo a possibilidade,

logo a princípio, de trabalhar com procedimentos de imputação mais sofisticados.

Como primeira impressão, embora a implementação e a estimação do modelo exija um tempo relativamente maior do que os métodos clássicos, a estimação por métodos bayesianos mostrou-se uma ferramenta muito promissora em estudos de APC, uma vez que é menos restritiva do que os métodos clássicos, principalmente em estudos onde a heterogeneidade entre respondentes é grande, sendo também robusta, mesmo quando poucos estímulos são avaliados. Foram encontradas dificuldades em estimar o modelo de aprendizado quando dois atributos estavam ausentes em um único perfil, isso porque o tempo de processamento aumentava consideravelmente.

Por fim, embora a aplicação proposta contivesse somente dois níveis para cada atributo, o modelo proposto suporta que um número maior de níveis seja avaliado não necessariamente sendo o mesmo entre todos os atributos. Sendo assim estudos futuros podem ser realizados aumentando o número de níveis dos atributos ou ainda aumentando o número de omissões dos estímulos. Outra sugestão seria a utilização simultânea de diferentes procedimentos de imputação em um único modelo tornando o modelo mais flexível e abrangente do que o atual.

Apêndice

A.1 Cadeias de Markov e Algoritmo de Metropolis-Hasting

A simulação via cadeias de Markov consiste em simular um processo de Markov sobre o estado do parâmetro θ que após um número mínimo de simulações converge para uma distribuição estacionária que é também a distribuição conjunta a posteriori $(p(\theta/y))$. ($p(\theta/y)$ é dita como sendo a distribuição alvo e será utilizada para fazer as inferências do estudo).

Alguns algoritmos de convergência podem ser aplicados a fim de acelerar a convergência. O Algoritmo Metropolis-Hastings é utilizado para gerar seqüências de amostras a partir de uma distribuição de probabilidade previamente definida e de difícil integração. Este algoritmo é amplamente utilizado em processos de estimação bayesiana que utilizam métodos de Monte Carlo via Cadeia de Markov.

A idéia deste método consiste em, através de uma distribuição de probabilidade $(p(x))$, gerar um processo aleatório para então extrair amostras espaçadas em t unidades de tempo. Por exemplo, dada a distribuição alvo $p(\theta/y)$, o algoritmo Metropolis cria uma seqüência de pontos aleatórios $(\theta_1, \theta_2, \theta_3, \dots)$ cuja distribuição converge para a distribuição alvo. Cada seqüência pode ser considerada como um passeio aleatório

cuja distribuição estacionária é $p(\theta/y)$. As principais etapas do algoritmo são:

1. Amostrar um ponto inicial θ^0 a partir da distribuição p_0
2. Amostrar um novo ponto, θ^* a partir da distribuição obtida t passos depois do ponto inicial ($J_t(\theta^*/\theta^{t-1})$). A distribuição $J_t(\theta^*/\theta^{t-1})$ deve ser simétrica, ou seja, para todos pontos espaçados em t unidades, $\theta_a, \theta_b, J_t(\theta^a/\theta^b) = J_t(\theta^b/\theta^a)$
3. Calcula-se a razão das densidades, $r = \frac{p(\theta^*/y)}{p(\theta^{t-1}/y)}$
4. Define-se θ^t como:

$$\theta^t = \begin{cases} \theta^*, & \text{com probabilidade } \min(r, 1), \\ \theta^{t-1}, & \text{caso contrário} \end{cases} \quad (\text{A.1})$$

para um dado o valor atual θ^{t-1} , a distribuição de transição da cadeia de Markov $T_t(\theta^t/\theta^{t-1})$ é uma mistura da distribuição de $J_t(\theta^*/\theta^{t-1})$ com o ponto da densidade $\theta^t = \theta^{t-1}$.

5. Calcular a razão R dada por (A.2).

$$R = \frac{p(\theta^*/y)/J_t(\theta^*|\theta^{t-1})}{p(\theta^{t-1}/y)/J_t(\theta^{t-1}|\theta^*)}. \quad (\text{A.2})$$

A convergência ocorre quando a razão R estiver próxima de 1, sugerindo que ambas as distribuições estão muito próximas. Para a razão ser aceitável, ela precisa estar acima de 60%.

A.2 Rotina Computacional

O programa utilizado para a estimação das utilidades parciais via modelo de aprendizado foi escrito inicialmente em linguagem de programação do WinBugs e posteriormente adaptada ao R. Uma explicação mais detalhada da rotina é feita a seguir para um modelo com 20 estímulos e 7 atributos cada.

```

1) Inicialização do modelo: Calibração para todos os indivíduos (ii). model {
  for(ii in 1:I)
    rating[(ii-1)*T+1] dnorm(mu[(ii-1)*T+1], tau.rating[ii])
    mu[(ii-1)*T+1]~ beta[ii,13]+
    (beta[ii,1]*Xprime[(ii-1)*T+1,1])+
    (beta[ii,2]*Xprime[(ii-1)*T+1,2])+
    (beta[ii,3]*Xprime[(ii-1)*T+1,3])+
    (beta[ii,4]*Xprime[(ii-1)*T+1,4])+
    (beta[ii,5]*Xprime[(ii-1)*T+1,5])+
    (beta[ii,6]*Xprime[(ii-1)*T+1,6])+
    (beta[ii,7]*Xprime[(ii-1)*T+1,7])+
    (beta[ii,8]*(R[(ii-1)*T+1,3]))+
    (beta[ii,9]*(R[(ii-1)*T+1,4]))+
    (beta[ii,10]*(R[(ii-1)*T+1,5]))+
    (beta[ii,11]*(R[(ii-1)*T+1,6]))+
    (beta[ii,12]*(R[(ii-1)*T+1,7]))

    for(jj in 1:7)
      Xprime[(ii-1)*T+1,jj]~R[(ii-1)*T+1,jj]*X[(ii-1)*T+1,jj]+
      (1-R[(ii-1)*T+1,jj])*missingdraw[(ii-1)*T+1,jj]

      missingdraw[(ii-1)*T+1,jj] dbern(0.5)
    for(tt in 2:(T-4)) rating[(ii-1)*T+tt] dnorm(mu[(ii-1)*T+tt], tau.rating[ii])
    mu[(ii-1)*T+tt]~ beta[ii,13]+
    (beta[ii,1]*Xprime[(ii-1)*T+tt,1])+
    (beta[ii,2]*Xprime[(ii-1)*T+tt,2])+
    (beta[ii,3]*Xprime[(ii-1)*T+tt,3])+
    (beta[ii,4]*Xprime[(ii-1)*T+tt,4])+
    (beta[ii,5]*Xprime[(ii-1)*T+tt,5])+
    (beta[ii,6]*Xprime[(ii-1)*T+tt,6])+
    (beta[ii,7]*Xprime[(ii-1)*T+tt,7])+
    (beta[ii,8]*(R[(ii-1)*T+tt,3]))+
    (beta[ii,9]*(R[(ii-1)*T+tt,4]))+
    (beta[ii,10]*(R[(ii-1)*T+tt,5]))+
    (beta[ii,11]*(R[(ii-1)*T+tt,6]))+
    (beta[ii,12]*(R[(ii-1)*T+tt,7]))+
    (gamma[ii]*(rating[(ii-1)*T+tt-1]-mu[(ii-1)*T+tt-1]))
    for(tp in 1:(tt-1))
      2) cálculo das contagens ( $N_{ij}(t, l^*)$ )
      for(jp in 1:7)
        v1[(ii-1)*T+tt,tp,jp]~ (pow(lambda1[ii,jp], tt-tp)*equals(X1[(ii-1)*T+tt,jp],
        X[(ii-1)*T+tp, jp])*(1-R[(ii-1)*T+tt,jp]) + pow(lambda2[ii], tt-tp)*equals(X1[(ii-1)*T+tt,jp],
        X[(ii-1)*T+tp, jp])*R[(ii-1)*T+tt,jp])*equals(X1[(ii-1)*T+tt,miss1[(ii-1)*T+tt]],
        X[(ii-1)*T+tp,miss1[(ii-1)*T+tt]])
        v0[(ii-1)*T+tt,tp,jp]~(pow(lambda1[ii,jp], tt-tp)*equals(X0[(ii-1)*T+tt,jp],

```

```

X[(ii-1)*T+tp, jp])*(1-R[(ii-1)*T+tt,jp]) + pow(lambda2[ii], tt-tp)*equals(X0[(ii-1)*T+tt,jp],
X[(ii-1)*T+tp, jp])*R[(ii-1)*T+tt,jp])*equals(X0[(ii-1)*T+tt,miss1[(ii-1)*T+tt]],
X[(ii-1)*T+tp,miss1[(ii-1)*T+tt]])

for(jj in 1:7)
missingdraw[(ii-1)*T+tt,jj] dbern(pp[(ii-1)*T+tt,jj])
pp[(ii-1)*T+tt,jj]~N1[(ii-1)*T+tt,jj]/(N1[(ii-1)*T+tt,jj]+N0[(ii-1)*T+tt,jj])
N1[(ii-1)*T+tt,jj]~sum(v1[(ii-1)*T+tt,1:(tt-1),1])+sum(v1[(ii-1)*T+tt,1:(tt-1),2])
+sum(v1[(ii-1)*T+tt,1:(tt-1),3])+sum(v1[(ii-1)*T+tt,1:(tt-1),4])+sum(v1[(ii-1)*T+tt,1:(tt-1),5])
+sum(v1[(ii-1)*T+tt,1:(tt-1),6])+sum(v1[(ii-1)*T+tt,1:(tt-1),7])+0.0001+prior1[ii,jj]

N0[(ii-1)*T+tt,jj]~sum(v0[(ii-1)*T+tt,1:(tt-1),1])+sum(v0[(ii-1)*T+tt,1:(tt-1),2])
+sum(v0[(ii-1)*T+tt,1:(tt-1),3])+sum(v0[(ii-1)*T+tt,1:(tt-1),4])+sum(v0[(ii-1)*T+tt,1:(tt-1),5])
+sum(v0[(ii-1)*T+tt,1:(tt-1),6])+sum(v0[(ii-1)*T+tt,1:(tt-1),7])+0.0001+prior1[ii,jj]
Xprime[(ii-1)*T+tt,jj]~R[(ii-1)*T+tt,jj]*X[(ii-1)*T+tt,jj]+(1-R[(ii-1)*T+tt,jj])*missingdraw[(ii-1)*T+tt,jj]

3) Distribuições a priori
gamma[ii] dunif(-1,1)
tau.rating[ii] dgamma(0.1,0.1)
for(k in 1:13)
beta[ii,k] dnorm(mu.beta[k], tau.beta[k])

aaa2 dunif(1,100)
bbb2 dunif(1,100)
meanlambda2i-aaa2/(aaa2+bbb2)

for(jj in 1:7)
aaa1[jj] dunif(1,100)
bbb1[jj] dunif(1,100)
meanlambda1[jj]~aaa1[jj]/(aaa1[jj]+bbb1[jj])

omega[jj,1] dnorm(0.0,0.1)
omega[jj,2] dnorm(0.0,0.1)

for(ii in 1:I)

zeta[ii] dnorm(0.0,0.1)
for(jp in 1:7)
lambda1[ii,jp] dbeta(aaa1[jp], bbb1[jp])

lambda2[ii] dbeta(aaa2, bbb2)

for(jj in 1:7)
prior1[ii,jj] dpois(ggg1[ii,jj])
prior0[ii,jj] dpois(ggg0[ii,jj])

ggg1[ii,jj]~exp(zeta[ii]+omega[jj,1])
ggg0[ii,jj]~exp(zeta[ii]+omega[jj,2])

meangammaj~sum(gamma[])/I

```

```

for(jj in 1:13)
mu.beta[jj] dnorm(0,0.01)
tau.beta[jj] dgamma(0.1,0.1)

4) Cálculo da verossimilhança
for(ii in 1:I) for(tt in 1:(T-4)) loglike[(ii-1)*(T-4)+tt]- 0.5*log(tau.rating[ii])-0.5*pow((rating[(ii-1)*T+tt]
-mu[(ii-1)*T+tt]),2)*tau.rating[ii]
loglikelihoodj-sum(loglike[])

5) Cálculo dos estímulos de validação do modelo
for(ii in 1:I) for(tt in (T-3):T) for(tp in 1:(tt-1)) for(jp in 1:7)
v1[(ii-1)*T+tt,tp,jp]-(pow(lambda1[ii,jp], tt-tp)*equals(X1[(ii-1)*T+tt,jp],
X[(ii-1)*T+tp, jp])*(1-R[(ii-1)*T+tt,jp]) + pow(lambda2[ii], tt-tp)*equals(X1[(ii-1)*T+tt,jp],
X[(ii-1)*T+tp,jp])*R[(ii-1)*T+tt,jp])*equals(X1[(ii-1)*T+tt,miss1[(ii-1)*T+tt]],X[(ii-1)
T+tp,miss1[(ii-1)*T+tt]])
v0[(ii-1)*T+tt,tp,jp]-(pow(lambda1[ii,jp], tt-tp)*equals(X0[(ii-1)*T+tt,jp],
X[(ii-1)*T+tp, jp])*(1-R[(ii-1)*T+tt,jp]) + pow(lambda2[ii], tt-tp)*equals(X0[(ii-1)*T+tt,jp],
X[(ii-1)*T+tp, jp])*R[(ii-1)*T+tt,jp])*equals(X0[(ii-1)*T+tt,miss1[(ii-1)*T+tt]],
X[(ii-1)*T+tp,miss1[(ii-1)*T+tt]]) for(jj in 1:7) Xprime[(ii-1)*T+tt,jj]- R[(ii-1)*T+tt,jj]*X[(ii-1)*T+tt,jj]+(1-R[(ii-1)*T+tt,jj])
missingdraw[(ii-1)*T+tt,jj]
missingdraw[(ii-1)*T+tt,jj] dbern(pp[(ii-1)*T+tt,jj])
pp[(ii-1)*T+tt,jj]-N1[(ii-1)*T+tt,jj]/(N1[(ii-1)*T+tt,jj]+N0[(ii-1)*T+tt,jj])
N1[(ii-1)*T+tt,jj]-sum(v1[(ii-1)*T+tt,1:(tt-1),1])+sum(v1[(ii-1)*T+tt,1:(tt-1),2])
+sum(v1[(ii-1)*T+tt,1:(tt-1),3])+sum(v1[(ii-1)*T+tt,1:(tt-1),4])+sum(v1[(ii-1)*T+tt,1:(tt-1),5])
+sum(v1[(ii-1)*T+tt,1:(tt-1),6])+sum(v1[(ii-1)*T+tt,1:(tt-1),7])+0.0001+prior1[ii,jj]
N0[(ii-1)*T+tt,jj]-sum(v0[(ii-1)*T+tt,1:(tt-1),1])+sum(v0[(ii-1)*T+tt,1:(tt-1),2])
+sum(v0[(ii-1)*T+tt,1:(tt-1),3])+sum(v0[(ii-1)*T+tt,1:(tt-1),4])+sum(v0[(ii-1)*T+tt,1:(tt-1),5])
+sum(v0[(ii-1)*T+tt,1:(tt-1),6])+sum(v1[(ii-1)*T+tt,1:(tt-1),7])+0.0001+prior1[ii,jj]

6) Cálculo da performance do modelo for(ii in 1:I) mean1[ii]-beta[ii,13]+
beta[ii,1]*Xprime[(ii-1)*T+T-3,1]+
beta[ii,2]*Xprime[(ii-1)*T+T-3,2]+
beta[ii,3]*Xprime[(ii-1)*T+T-3,3]+
beta[ii,4]*Xprime[(ii-1)*T+T-3,4]+
beta[ii,5]*Xprime[(ii-1)*T+T-3,5]+
beta[ii,6]*Xprime[(ii-1)*T+T-3,6]+
beta[ii,7]*Xprime[(ii-1)*T+T-3,7]+
beta[ii,8]*(R[(ii-1)*T+T-3,3])+
beta[ii,9]*(R[(ii-1)*T+T-3,4])+
beta[ii,10]*(R[(ii-1)*T+T-3,5])+
beta[ii,11]*(R[(ii-1)*T+T-3,6])+
beta[ii,12]*(R[(ii-1)*T+T-3,7])+
gamma[ii]*(rating[(ii-1)*T+T-3]-mu[(ii-1)*T+T-3-1])

error[(ii-1)*4+1]-abs(rating[(ii-1)*T+T-3]-mean1[ii])
mean2[ii]-beta[ii,13]+
beta[ii,1]*Xprime[(ii-1)*T+T-2,1]+
beta[ii,2]*Xprime[(ii-1)*T+T-2,2]+
beta[ii,3]*Xprime[(ii-1)*T+T-2,3]+
beta[ii,4]*Xprime[(ii-1)*T+T-2,4]+
beta[ii,5]*Xprime[(ii-1)*T+T-2,5]+
beta[ii,6]*Xprime[(ii-1)*T+T-2,6]+
beta[ii,7]*Xprime[(ii-1)*T+T-2,7]+
beta[ii,8]*(R[(ii-1)*T+T-2,3])+
beta[ii,9]*(R[(ii-1)*T+T-2,4])+

```

```

beta[ii,10]*(R[(ii-1)*T+T-2,5])+
beta[ii,11]*(R[(ii-1)*T+T-2,6])+
beta[ii,12]*(R[(ii-1)*T+T-2,7])+
gamma[ii]*(rating[(ii-1)*T+T-3]-mean1[ii])

error[(ii-1)*4+2]-abs(rating[(ii-1)*T+T-2]-mean2[ii])
mean3[ii]-beta[ii,13]+
beta[ii,1]*Xprime[(ii-1)*T+T-1,1]+
beta[ii,2]*Xprime[(ii-1)*T+T-1,2]+
beta[ii,3]*Xprime[(ii-1)*T+T-1,3]+
beta[ii,4]*Xprime[(ii-1)*T+T-1,4]+
beta[ii,5]*Xprime[(ii-1)*T+T-1,5]+
beta[ii,6]*Xprime[(ii-1)*T+T-1,6]+
beta[ii,7]*Xprime[(ii-1)*T+T-1,7]+
beta[ii,8]*(R[(ii-1)*T+T-1,3])+
beta[ii,9]*(R[(ii-1)*T+T-1,4])+
beta[ii,10]*(R[(ii-1)*T+T-1,5])+
beta[ii,11]*(R[(ii-1)*T+T-1,6])+
beta[ii,12]*(R[(ii-1)*T+T-1,7])+
gamma[ii]*(rating[(ii-1)*T+T-2]-mean2[ii])
error[(ii-1)*4+3]-abs(rating[(ii-1)*T+T-1]-mean3[ii])
mean4[ii]-beta[ii,13]+
beta[ii,1]*Xprime[(ii-1)*T+T,1]+
beta[ii,2]*Xprime[(ii-1)*T+T,2]+
beta[ii,3]*Xprime[(ii-1)*T+T,3]+
beta[ii,4]*Xprime[(ii-1)*T+T,4]+
beta[ii,5]*Xprime[(ii-1)*T+T,5]+
beta[ii,6]*Xprime[(ii-1)*T+T,6]+
beta[ii,7]*Xprime[(ii-1)*T+T,7]+
beta[ii,8]*(R[(ii-1)*T+T,3])+
beta[ii,9]*(R[(ii-1)*T+T,4])+
beta[ii,10]*(R[(ii-1)*T+T,5])+
beta[ii,11]*(R[(ii-1)*T+T,6])+
beta[ii,12]*(R[(ii-1)*T+T,7])+
gamma[ii]*(rating[(ii-1)*T+T-1]-mean3[ii])
error[(ii-1)*4+4]-abs(rating[(ii-1)*T+T]-mean4[ii])
meanpersonoos[ii]-(error[(ii-1)*4+1]+error[(ii-1)*4+2]+error[(ii-1)*4+3]+error[(ii-1)*4+4])/4

meanerroroosj-sum(error[])/(4*I)

for(i in 1:I)
meanpersonerror[i]-(error[(i-1)*4+1]+error[(i-1)*4+2]+error[(i-1)*4+3]+error[(i-1)*4+4])/4

for(ii in 1:I)

for(tt in 1:(T-4))

inerror[(ii-1)*(T-4)+tt]-abs(rating[(ii-1)*T+tt]-mu[(ii-1)*T+tt])

meanerrorinsj-sum(inerror[])/(I*(T-4))

```

A.3 Questionário

O questionário apresentado aos respondentes contém além de uma breve descrição de cada atributo, uma exemplificação com um perfil completo de como será conduzida a pesquisa. A seguir apresenta-se um questionário com um estímulo ausente.

PREFERÊNCIAS NO TRABALHO

A seguir você responderá a uma pesquisa sobre preferências no trabalho. Diferentes funções lhes serão apresentadas e você deverá classificá-las segundo a sua preferência, através de uma nota que varia de 0 a 100. Para descrever as diferentes funções serão utilizadas as seguintes características:

Remuneração Anual: Remuneração anual recebida pelo funcionário. a) Não há aumento na remuneração anual em relação a atual. b) Remuneração Anual 20

Reconhecimento: Reconhecimento recebido pelo trabalho realizado dentro da instituição. a) O reconhecimento do trabalho realizado é feito pelo próprio gestor b) O reconhecimento do trabalho realizado é feito pelos colegas de trabalho

Exposição: Exposição profissional e pessoal do funcionário dentro da instituição. a) Horizontal: Exposição para colegas de trabalho de mesmo nível hierárquico b) Vertical: Exposição para níveis hierárquicos superiores ao seu (comissões executivas, diretorias, presidência,...)

Jornada de Trabalho: Jornada de trabalho semanal demandada do funcionário. a) 40 a 50 horas semanais (equivalente a uma jornada de 8 a 10 horas/ dia) b) Acima de 50 horas semanais (jornada superior a 10 horas /dia)

Gestor: Papel do gestor no acompanhamento das atividades exercidas pelo funcionário. a) Gestor omissor: não o acompanha em suas tarefas diárias nem dá feedback constante de seu trabalho. b) Gestor participativo: acompanhamento constante e feedback freqüente.

Clima na área: Clima do ambiente de trabalho entre os colegas de trabalho. a) Competitivo: clima bastante competitivo entre os colegas de trabalho. b) Colaborativo: clima colaborativo entre os colegas de trabalho.

Desafios: Frequência de exposição a novos desafios demandada pela função. a) Frequentes: funcionário frequentemente desafiado a realizar novas tarefas. b) Raros: função que raramente desafia o funcionário.

Instruções para o preenchimento do questionário:

As diferentes funções descritas a seguir deverão ser classificadas respeitando uma escala de preferência de vai de 0 a 100. Sendo que a nota 0 sugere que a função NÃO desperta sua preferência, enquanto que a nota 100 refere-se a uma função de sua TOTAL preferência. Tome cuidado para não classificar duas funções com a MESMA nota.

Por exemplo, avalie a seguinte função segundo a sua preferência:

*Aumento salarial de 20% em relação ao seu salário atual.
Seus colegas reconhecem o seu trabalho..
Existe uma exposição vertical.
Jornada de trabalho acima de 50 horas semanais
Gestor participativo no dia-a-dia.
Clima colaborativo entre os colegas.
Desafios frequentes.*

Escreva aqui sua
nota de preferência

5. Sem aumento do salário anual.
Trabalho reconhecido pelo gestor.
Exposição horizontal.
Jornada de trabalho de 40 a 50 horas/semana.
Gestor omissivo.
Desafios Raros.
6. Sem aumento do salário anual.
Trabalho reconhecido pelos colegas.
Exposição horizontal.
Gestor participativo.
Clima da área competitivo entre os colegas.
Desafios Raros.
7. Sem aumento no salário anual.
Trabalho reconhecido pelos colegas.
Exposição vertical.
Jornada de trabalho de 40 a 50 horas semanais.
Gestor omissivo.
Raros desafios.
8. Sem aumento no salário anual.
Trabalho reconhecido pelos colegas.
Exposição vertical.
Jornada de trabalho acima de 50 horas semanais.
Gestor omissivo.
Desafios freqüentes.
9. Aumento de 20% no salário anual.
Trabalho reconhecido pelo gestor.
Exposição vertical.
Gestor participativo.
Clima da área competitivo entre os colegas.
Desafios freqüentes.
10. Sem aumento no salário anual.
Trabalho reconhecido pelos colegas.
Exposição horizontal.
Gestor participativo.
Clima da área colaborativo entre os colegas.
Desafios freqüentes.

11. Aumento de 20% no salário anual.
Trabalho reconhecido pelo gestor.
Exposição horizontal.
Jornada de trabalho superior a 50 horas semanais.
Gestor omissivo.
Clima da área competitivo entre os colegas.
12. Aumento de 20% no salário anual.
Trabalho reconhecido pelo gestor.
Jornada de trabalho superior a 50 horas semanais.
Gestor participativo.
Clima da área competitivo entre os colegas.
Raros desafios.
13. Aumento de 20% no salário anual.
Trabalho reconhecido pelos colegas.
Jornada de trabalho superior a 50 horas semanais.
Gestor omissivo.
Clima da área colaborativo entre os colegas.
Raros desafios.
14. Aumento de 20% no salário anual.
Trabalho reconhecido pelos colegas.
Exposição horizontal.
Jornada de trabalho de 40 a 50 horas semanais.
Gestor participativo.
Clima da área competitivo entre os colegas.
15. Aumento de 20% no salário anual.
Trabalho reconhecido pelos colegas.
Exposição horizontal.
Jornada de trabalho de 40 a 50 horas semanais.
Clima da área colaborativo entre os colegas.
Desafios frequentes.

16. Sem aumento no salário anual.
Trabalho reconhecido pelo gestor.
Exposição vertical.
Jornada de trabalho superior a 50 horas semanais.
Clima da área colaborativo entre os colegas.
Raros desafios.
17. Sem aumento do salário anual em relação ao salário atual.
Trabalho reconhecido pelos colegas.
Jornada de trabalho de 40 a 50 horas/semanais.
Gestor omissivo.
Clima da área competitivo entre os colegas.
Desafios Frequentes.
18. Sem aumento no salário anual.
Trabalho reconhecido pelos colegas.
Exposição horizontal.
Jornada de trabalho de 40 a 50 horas semanais.
Clima da área competitivo entre os colegas.
Desafios frequentes.
19. Aumento de 20% no salário anual.
Trabalho reconhecido pelo gestor.
Exposição vertical.
Jornada de trabalho de 40 a 50 horas semanais.
Gestor participativo.
Clima da área colaborativo entre os colegas.
20. Aumento de 20% no salário anual.
Trabalho reconhecido pelo gestor.
Exposição vertical.
Gestor participativo.
Clima da área competitivo entre os colegas.
Desafios frequentes.

A.4 Erros de ajuste do modelo

Adota-se, como medida de ajuste o Erro Absoluto Médio (EAM), calculado utilizando-se as expressões (A.3) e (A.4) e o Erro Quadrático Médio (EQM), cujas expressões são (A.5) e (A.6), para avaliar os erros de estimação das amostras de estimação e validação, respectivamente.

$$MAE_{estima} = \frac{\sum_{t=1}^{T-4} |y_i(t) - \hat{y}_i(t)|}{(T-4)} \quad (A.3)$$

$$MAE_{valida} = \frac{\sum_{t=T-4+1}^T |y_i(t) - \hat{y}_i(t)|}{(4)} \quad (A.4)$$

$$EQM_{estima} = \frac{\sum_{t=1}^{T-4} (y_i(t) - \hat{y}_i(t))^2}{(T-4)} \quad (A.5)$$

$$EQM_{valida} = \frac{\sum_{t=T-4+1}^T (y_i(t) - \hat{y}_i(t))^2}{(4)} \quad (A.6)$$

Outra medida observada é a correlação entre os coeficientes obtidos com os diferentes modelos estimados com a finalidade de identificar se há concordância entre as estimativas dos diferentes modelos para um mesmo conjunto de dados. Será utilizada correlação de Spearman como medida de similaridade das estimativas dos coeficientes.

A.5 Gráficos de convergência do modelo de aprendizado

A Figuras A.1 a A.4 trazem os resultados gráficos de ajuste e estimação de um modelo de aprendizado para um indivíduo em particular. A densidade das utilidades parciais (β_{ij}) estimada neste caso (Figura A.1) exibe distribuições unimodais cuja forma de sino assemelha-se à distribuição normal.

Figura A.1: Densidade estimada de β

Tem-se que a convergência foi alcançada dado que os valores exibidos pela Figura A.2 encontram-se concentrados em torno de um mesmo intervalo de valores e, além disso, a estatística R, representada pela linha vermelha da Figura A.3, possui valores muito próximos a 1.

A autocorrelação das estimativas dos valores utilizados para estimar as utilidades é muito pequena, conforme observa-se na Figura A.4.

Além das utilidades parciais, outros parâmetros foram estimados e tiveram seus

Figura A.2: Convergência - Cadeia de Markov gerada

resultados observados a fim de garantir o bom ajuste do modelo. Os parâmetros são $\mu(\beta_{ij})$, τ_i , γ_i e λ_j e foram adotados mesmos critérios de ajuste e convergência do caso de β_{ij} .

Informações adicionais podem ser encontradas no CD encontrado no final deste trabalho.

Figura A.3: Convergência - estatística modificada de Gelman e Rubin

Figura A.4: Auto-correlação da Cadeia de Markov

Referências Bibliográficas

- [1] Agresti, A. (1990). *Categorical Data Analysis*. New York: John Wiley and Sons.
- [2] Alba, J. W. e Cooke, A. D. J. (2004). When Absence Begets Inference in Conjoint Analysis. *Journal of Marketing Research*, (41): 382-387.
- [3] Allenby, G.M., Arora, N., Ginter, J.L. (1995). Incorporating Prior knowledge into the analysis of conjoint studies. *Journal of Marketing Research*, (XXXII): 152-162 .
- [4] Allenby, G. M., Bakken, D. G., Rossi, P.E. (2004). The HB Revolution: How Bayesian Methods Have Changed the Face of Marketing Research. *Journal of Marketing Research*, XVI(2): 20-25.
- [5] Artes, R. (1991). *Análise de Preferência (“Conjoint Analysis”)*. Dissertação de mestrado. Instituto de Matemática e Estatística da Universidade de São Paulo (IME-USP). São Paulo .
- [6] Bradlow, E.T, Hu. Y. e Ho, T.(2004). A Learning-Based Model for Imputin Missing Levels in Partial Conjoint Profiles. *Journal of Marketing Research*, (XLI): 369-381.
- [7] Broniarczyk, S. M. e Alba, J. A. (1994). The Role of Consumers’Intuitions in Inference Making. *Journal of Consumer Research*, (XXI): 393-407.
- [8] Brooks, S.P. e Gelman A. (1998). Alternative Methods for Monitoring Convergence of Iterative Simulations. *Journal of Computational and Graphical Statistics*, (7): 434-455.
- [9] Camerer, C. e Ho, T.H. (1998). EWA Learning in Condination Games: Probability

- Rules, heterogeneity, and Time Variation. *Journal of Mathematical Psychology*, (42): 305-326.
- [10] Feldman, J.M. e Lynch, J. G. (1988). Self-generated Validity and Other Effects of Measurement on Belief, Attitude, Intention and Behavior. *Journal of Applied Psychology*, (73): 421-435.
- [11] Friedmann, L. S. (1998). *Análise de Preferência*. Dissertação de Mestrado. Escola de Administração de Empresas da Fundação Getúlio Vargas (FGV - EAESP). São Paulo.
- [12] Gelman, A. and Rubin, D. (1992). Inference from Iterative Simulation using Multiple Sequences. *Statistical Science*, (7): 457-511.
- [13] Green, P.E. (1974). On the Design of Choice Experiments Involving Multifactor Alternatives. *Journal of Consumer Research*, (1): 61-68.
- [14] Green, P. E.(1984). Hybrid Model for Conjoint Analysis: An Expository Review. *Journal of Marketing Research*, (XXI): 155-169.
- [15] Green, P.E., Carrol, J.D. e Carmone, F.J. (1978). Some New Types of Fractional Factorial Designs for Marketing Experiments. *Research in Marketing*, (1): 99-122.
- [16] Green, P. e Rao, V. (1971). Conjoint Measurement for Quantifying Judgmental Data. *Journal of Marketing Research*, (8): 355-363 .
- [17] Green, P. E. e Savitz, J.(1994). Applying Conjoint analysis to Product Assortment and Pricing in Retailing Research. *Pricing Strategy and Practice Journal* , (2): 4-19.
- [18] Green, P. E. e Srinivasan, V. (1978). Conjoint Analysis in Consumer Research”Issues and Outlook. *Journal of Consumer Research*, (5): p 103-123.
- [19] Green, P. E. e Srinivasan,V. (1990). Conjoint Analysis in Marketing: New Developments with implications for Research and Practice. *Journal of Marketing*, (54): 3-19.
- [20] Herzberg, F., Mausner, B., and Snyderman, B. B. (1959). *The Motivation to Work*. New York: John-Wiley Sons, 2nd ed.

- [21] Ho, T.H. e Chong, J.K (2003). A Parsimonious Model of SKU Choice. *Journal of Marketing Research*, (40): 351-365.
- [22] Hoch, S.J., Bradlow, E. T. e Wansink, B (1999). The variety of an Assortment. *Marketing Science*, 18(4): 527-546.
- [23] Huber, J. e McCann, J. W. (1982). The Impact of Inferential Beliefs on Product Evaluations. *Journal of Marketing Research*, (XIX): 324-333.
- [24] Luce, R. D. e Tukey, J.W. (1964). Simultaneous Conjoint Measurement: A New Type of Fundamental Measurement. *Journal of Mathematical Psychology*, (1): 1-27.
- [25] Lynch, J. G., Jr e Srull, T.K.(1982). Memory and Attentional Factors in Consumer Choice: Concepts and Research Methods. *Journal of Consumer Research*, (9): p18-37.
- [26] Maslow, A. H. (1970). *Motivation and Personality*. (2nd ed.). New York: Harper and Row.
- [27] Montgomery, D. C. (1996). *Design and Analysis of Experiments*. (4nd ed.). John&Wiley Sons.
- [28] Plackett, L. R. e Burman, J.P. (1946). The Design of Optimum Multifactorial Experiments. *Biometrika*, (XXXIII): 305-325.
- [29] Robbins, S.P.(2002). *Comportamento organizacional I*. (9 ed.) São Paulo: Prentice Hall.
- [30] Rubin, D. B. (2004). Design and Modeling in Conjoint Analysis with Partial Profiles. *Journal of Marketing Research*, (41): 392-396.
- [31] Srinivasan, V., Jarin, A.K. e Malhorta, N. (1983). Improving Predictive Power of Conjoint Analysis by Constrained Parameter Estimation. *Journal of Marketing Research*, (20): 433-438.
- [32] Yamagishi, T. e Hill, C.T.(1981). Adding Versus Averaging Models Revisited: A test of a Path-Analytic Integration Model. *Journal of Personality and Social Psychology*, 41(1): 13-25.