



UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

***RANKING* AUTOMÁTICO DE PRODUTOS ATRAVÉS DO
MAPEAMENTO ENTRE ESPECIFICAÇÃO TÉCNICA E
NECESSIDADES DOS USUÁRIOS**

Igor Veloso Custódio

Orientador

Sean Wolfgang Matsui Siqueira

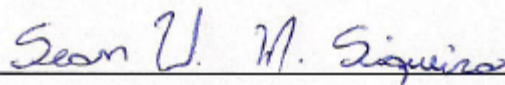
RIO DE JANEIRO, RJ - BRASIL

Setembro de 2016

RANKING AUTOMÁTICO DE PRODUTOS ATRAVÉS DO MAPEAMENTO ENTRE
ESPECIFICAÇÃO TÉCNICA E NECESSIDADES DOS USUÁRIOS

Igor Veloso Custódio

DISSERTAÇÃO APRESENTADA COMO REQUISITO PARCIAL PARA OBTENÇÃO
DO TÍTULO DE MESTRE PELO PROGRAMA DE PÓS-GRADUAÇÃO EM
INFORMÁTICA DA UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO
(UNIRIO). APROVADA PELA COMISSÃO EXAMINADORA ABAIXO ASSINADA.



Sean Wolfgang Matsui Siqueira, D.Sc. - UNIRIO



Bernardo Pereira Nunes, D.Sc. - UNIRIO



Geraldo Bonorino Xexéo, D.Sc. - UFRJ

RIO DE JANEIRO, RJ - BRASIL

Setembro de 2016

C987 Custódio, Igor Veloso.
Ranking automático de produtos através do mapeamento entre especificação técnica e necessidades dos usuários / Igor Veloso Custódio, 2016.
106 f. ; 30 cm

Orientador: Sean Wolfgang Matsui Siqueira.
Dissertação (Mestrado em Informática) - Universidade Federal do Estado do Rio de Janeiro, Rio de Janeiro, 2016.

1. Sistema de recuperação da informação. 2. Aprendizado do computador. 3. Ferramentas de busca na web. 4. Análise multicritério.
I. Siqueira, Sean Wolfgang Matsui. II. Universidade Federal do Estado do Rio de Janeiro. Centro de Ciências Exatas e Tecnológicas. Curso de Mestrado em Informática. III. Título.

CDD - 005.74

À minha esposa Poliana.
Minha outra metade, meu objetivo e minha energia.
Que com amor e paciência compreendeu a importância do meu
esforço. Todo apoio e carinho foram essenciais.

Agradecimentos

Aos professores do PPGI que pude conhecer e pegar emprestado um pouco do conhecimento. Em especial ao meu orientador, que sempre ajudava com as melhores informações para conseguir dar continuidade ao meu trabalho. O Professor Sean soube compreender os momentos tomados pelos compromissos diários e me incentivar na busca pela melhor qualidade possível da nossa pesquisa.

Aos colegas do grupo de pesquisa SaL, pelos conselhos tão necessários de última hora nas reuniões e pelo *WhatsApp*. Em especial ao grande amigo Thiago Procaci, cuja senioridade me ajudou muitas vezes a não tropeçar em erros inocentes.

Por último, e não menos importante, agradeço a minha família que percebia minha ausência física e mental em vários momentos. Em especial minha mãe e minha avó, por defenderem a importância da dedicação aos estudos, e que conhecimento é algo que nunca sobra.

Custódio, Igor Veloso. **Ranking Automático de Produtos através do Mapeamento entre Especificação Técnica e Necessidades dos Usuários**. UNIRIO, 2016. 106 páginas. Dissertação de Mestrado. Departamento de Informática Aplicada, UNIRIO.

RESUMO

O sucesso do comércio *online* depende dos Sistemas de Informação que o apoiam, como: agentes de recomendação, ferramentas sociais e a busca e recuperação de produtos. Atualmente, a busca facetada é a abordagem mais utilizada em sistemas de comércio online para o cliente filtrar as inúmeras alternativas de produtos possíveis. Porém ela exige que o cliente esteja familiarizado, principalmente, com a especificação técnica da categoria desejada, para poder encontrar os produtos que melhor atendam a suas necessidades. O objetivo desta pesquisa é relacionar automaticamente especificações técnicas de produtos com critérios menos técnicos (que correspondem às necessidades/desejos dos clientes). Assim, seria possível substituir os filtros na busca facetada (que é baseada nas especificações disponibilizadas pelos fabricantes), auxiliando o consumidor com dificuldades para realizar a compra. Para atingir esse objetivo, adotamos um método de análise multicritério que ordena as alternativas, abstraindo, mas sem desprezar o que é relevante para o cliente: as características de fabricação do produto. A solução proposta foi avaliada através de um experimento com mais de 230 categorias variadas e de diversas finalidades, tendo como insumo avaliações de produtos feitas por especialistas e coletadas da *Web*. Algumas das métricas mais utilizadas em Sistemas de Recuperação da Informação demonstraram um resultado favorável para a solução, comprovando assim sua viabilidade e eficácia em mais de 92% da amostra utilizada. Sendo assim, a solução proposta poderia ser uma alternativa para auxiliar um cliente com dificuldades em utilizar os filtros tradicionais da busca facetada a encontrar um produto com a melhor relação custo-benefício.

Palavras-chave: busca de produtos, classificação de produtos, avaliações de produtos, AHP, análise multicritério, aprendizado de máquina.

ABSTRACT

The success of e-commerce depends on the support of Information Systems such as: recommendation agents, social tools and product search and retrieval. Currently, faceted search is the most widely used approach for online shopping systems whereby the client filters the set of possible alternatives of products. However, it requires the client to be familiar with the technical specification of the desired category, in order to find the products that best meet their needs. The goal of this research is to automatically relate product's features with less-technical criteria (that correspond the clients' needs/desires). Then, it would be possible to replace the filters in a faceted search (which is based on technical specification provided by the manufactures), helping the customer with problems on completing a purchase. To achieve this goal, we have adopted a multi-criteria analysis method that sorts the alternatives, without neglecting what is relevant to the client: the product manufacturing characteristics. The proposed solution has been evaluated through an empirical experiment with over 230 diversified categories, using product evaluations made by experts and retrieved from the Web as data set. Some of the most commonly metrics used in Information Retrieval systems have demonstrated a positive outcome from the solution, showing their feasibility and efficacy in more than 92% of the used sample. In summary, the proposed solution could be an alternative to help a client with difficulty using traditional filters of the faceted search to find a product with the best cost-benefit relation.

Keywords: *product search, product ranking, product reviews, AHP, multi-criteria analysis, machine learning.*

ÍNDICE DE FIGURAS

Figura 1.1 - Crescimento do comércio online entre 2014 e 2019. Fonte eMarketer.	15
Figura 1.2 - Filtro de busca facetado de DSLRs. Fonte: amazon.com	16
Figura 2.1 - Esquema das atividades de Busca. Fonte: (MARCHIONINI, 2006), traduzido. .	27
Figura 3.1 - Exemplo de uma avaliação de <i>smartphones</i> com notas.....	36
Figura 3.2 - Esquema simplificado da estrutura hierárquica da proposta.	38
Figura 3.3 - Processo de calibragem das arestas entre a CAMADA 1 e 2.	40
Figura 3.4 - Diagrama do Processo do Modelo de <i>Ranking</i> Proposto.....	43
Figura 4.1 - Diagrama de Classes UML representando a estrutura AHP.....	47
Figura 4.2 - Notas para modelos de TV LED de Tela Grande fornecida por um especialista em sua <i>review</i> . Fonte: toptenreviews.com.....	50
Figura 4.3 - Algoritmo do Cálculo de Nota das Alternativa	53
Figura 5.1 - Exemplo de valores de features contidas no critério "Performance" para uma categoria de produto. Fonte: http://meat-grinders-review.toptenreviews.com/	60
Figura 5.2 - Projeto de avaliação e execução da validação cruzada.....	65

ÍNDICE DE TABELAS

Tabela 3.1 - Relação entre Critérios de Necessidades e Especificação Técnica (<i>features</i>).....	37
Tabela 3.2 - Valores de Tempo de Garantia dos Produtos.	42
Tabela 4.1 - Parâmetros de Execução do AG.	50
Tabela 4.2 - Escala de Intensidade. Fonte: (SAATY, 1985), tradução.	50
Tabela 4.3 - Valores Normalizados das Notas do Especialista.	51
Tabela 4.4 - Valores das Notas Geradas pelo RANK2BUY.	51
Tabela 5.1 - Resultado das notas normalizadas do especialista e da nossa solução.	56
Tabela 5.2 - Resultado das notas convertidas para a posição correspondente.	56

ÍNDICE DE GRÁFICOS

Gráfico 5.1 - Distribuição da quantidade de features por categoria.	61
Gráfico 5.2 - Média da quantidade de features por quantidade de critérios.	62
Gráfico 6.1 - Boxplot geral dos resultados.	67
Gráfico 6.2 - Gráfico de proporção dos resultados das métricas.	68
Gráfico 6.3 - Valores das Métricas por Quantidade de alternativas.	70
Gráfico 6.4 - Valores das Métricas por Quantidade de <i>features</i>	71
Gráfico 6.5 - Valores das Métricas por Quantidade de critérios.	72
Gráfico 6.6 - Valores de DE mínima em função da quantidade de critérios na <i>review</i>	73
Gráfico 6.7 - Valores de DE mínima em função da quantidade de alternativas avaliadas.	73
Gráfico 6.8 - Valores de DE mínima em função da quantidade de <i>features</i> da categoria.	73

LISTA DE SIGLAS

3D	Espaço Tri-dimensional
AG	Algoritmo Genético
AHP	<i>Analytic Hierarchy Process</i>
C2C	<i>Customer to Customer</i>
DCG	Desconto Cumulativo de Ganho
DE	Distância Euclideana
DSLR	<i>Digital Single-Lens Reflex Camera</i>
EKB	Engel, Kollat, Blackwell
eWOM	<i>Eletronic Word of Mouth</i>
GA	<i>Genetic Algorithm</i>
GPS	<i>Global Positioning System</i>
HDMI	High-Definition Multimedia Interface
HTML	HyperText Markup Language
IHC	Interação Humano-Computador
IPS	<i>In-plane Switching</i>
IR	<i>Information Retrieval</i>
ISO	<i>International Organization for Standardization</i>
MP	<i>MegaPixel</i>
LED	Light-emitting diode
NASDAQ	National Association of Securities Dealers Automated Quotations
nDCG	Normalized Discounted cumulative gain
P@K	Precision at K
PWC	Pairwise Comparison
RI	Recuperação da Informação
SC	<i>Spearman Correlation</i>
SUS	<i>System Usability Scale</i>
TV	Televisor
UML	<i>Unified Modeling Language</i>
USB	<i>Universal Serial Bus</i>

SUMÁRIO

1	INTRODUÇÃO	14
1.1	CONTEXTUALIZAÇÃO DO PROBLEMA.....	18
1.1.1	<i>Processo Decisório de Compra</i>	20
1.1.2	<i>Motivação</i>	21
1.2	PROPOSTA DE SOLUÇÃO.....	23
1.3	HIPÓTESE DE PESQUISA.....	24
1.4	METODOLOGIA	24
1.5	ORGANIZAÇÃO DA DISSERTAÇÃO	25
2	FUNDAMENTAÇÃO TEÓRICA	26
2.1	BUSCA EXPLORATÓRIA.....	26
2.2	<i>ANALYTIC HIERARCHY PROCESS - AHP</i>	28
2.3	ALGORITMO GENÉTICO.....	29
2.4	TRABALHOS RELACIONADOS	30
2.5	CONSIDERAÇÕES FINAIS	33
3	RANKING AUTOMÁTICO DE PRODUTOS	34
3.1	RANK2BUY.....	35
3.2	MONTAGEM DA ESTRUTURA INICIAL DO AHP.....	36
3.3	CALIBRAGEM DA IMPORTÂNCIA DAS <i>FEATURES</i> EM RELAÇÃO AOS CRITÉRIOS.....	39
3.4	PROCESSAMENTO DOS VALORES DA <i>FEATURES</i>	41
3.5	CÁLCULO DO <i>RANKING</i>	42
3.6	CONSIDERAÇÕES FINAIS	44
4	ARQUITETURA RANK2BUY.....	45
4.1	ESTRUTURA AHP.....	45
4.2	CALIBRAGEM COM ALGORITMO GENÉTICO	48
4.3	ALGORITMO GERAL RANK2BUY	50
4.4	CONSIDERAÇÕES FINAIS	52
5	PROJETO DE AVALIAÇÃO DA SOLUÇÃO	54
5.1	MÉTRICAS DE AVALIAÇÃO DE <i>RANKING</i>	54
5.1.1	<i>Correlação de Spearman</i>	55
5.1.2	<i>Precisão em k: P@k</i>	56
5.1.3	<i>Normalized Discounted Cumulative Gain: nDCG</i>	57

5.2	FONTE DE DADOS	58
5.2.1	<i>Coleta dos dados</i>	59
5.2.2	<i>Aspecto Geral dos Dados</i>	60
5.2.3	<i>Heurísticas do Tratamento das Features</i>	62
5.3	EXECUÇÃO DOS TESTES	63
5.4	CONSIDERAÇÕES FINAIS	65
6	ANÁLISE DOS RESULTADOS	66
6.1	VISÃO GERAL DOS RESULTADOS	66
6.2	DETALHE DOS RESULTADOS	69
6.2.1	<i>Compilação dos Resultados</i>	69
6.2.2	<i>Relação com Quantidade de Alternativas</i>	70
6.2.3	<i>Relação com Quantidade de Features</i>	71
6.2.4	<i>Relação com Quantidade de Critérios</i>	71
6.2.5	<i>Análise da Distância Euclideana</i>	72
6.3	CONSIDERAÇÕES FINAIS	74
7	CONCLUSÃO	75
7.1	CONTRIBUIÇÕES TEÓRICAS.....	77
7.2	CONTRIBUIÇÕES PRÁTICAS	78
7.3	LIMITAÇÕES.....	79
7.4	TRABALHOS FUTUROS	79
7.5	PROJETOS DE INOVAÇÃO.....	81
7.6	CONSIDERAÇÕES FINAIS	81
	REFERÊNCIAS	83
	APÊNDICES	87
	APÊNDICE A.....	87
	APÊNDICE B	89
	APÊNDICE C	90
	APÊNDICE D.....	91
	APÊNDICE E	102
	APÊNDICE F.....	103
	APÊNDICE G	104
	APÊNDICE H.....	105

1 INTRODUÇÃO

O comércio online é muito competitivo, existindo não somente a concorrência entre os próprios vendedores na *web*, mas também com os canais de venda tradicionais. Os sistemas que apoiam essa atividade têm uma participação fundamental nos fatores que influenciam as vendas que ocorrem através da *web* (PARK e KIM 2003).

Até o final de 2014, um estudo conduzido pela revista *Internet Retailer* (RACHAMIM 2014) estimou a existência de pelo menos 650.000 lojas online com venda acima de mil dólares anuais. Outro estudo realizado pela empresa eMarketer (EMARKETER 2014) aponta que até o final de 2015 seriam gastos dois trilhões de dólares com compra pela internet (25% a mais do que o ano anterior). A Figura 1.1 ilustra esse crescimento estimado até 2019, onde é possível identificar que apesar de desacelerado (linha vermelha), o percentual de vendas somente pela internet aumenta em relação ao valor total do comércio varejista (linha azul), considerando todos os canais de venda.

Desde o seu surgimento, o comércio *online* acompanhou e fez uso das inovações tecnológicas dos Sistemas de Informação (SI) para garantir o seu sucesso. Alguns exemplos mais recentes são:

- Tecnologias da *web* social (KONG e QIN 2015; FRIEDRICH 2015), que compreendem a avaliação de usuários na *web* a respeito de produtos e vendedores, além do compartilhamento dessas informações através de redes sociais.
- Agentes de recomendação (MARTÍNEZ-LÓPEZ et al. 2015), que são capazes de utilizar preferências e histórico comportamental de um determinado usuário ou grupo, a fim de sugerir produtos ou conteúdos mais relevantes para os mesmos.
- Ferramentas de busca e recuperação de informações a respeito de produtos, permitindo uma comparação efetiva entre os resultados e maior relevância dos dados retornados para o usuário.

Este último é onde está inserido nosso trabalho, que tem como objetivo apoiar diretamente o consumidor ao dispor de técnicas mais eficazes para encontrar o produto que melhor atenda suas necessidades.




Figura 1.1 - Crescimento do comércio online entre 2014 e 2019. Fonte eMarketer.

Nos portais de comércio eletrônico, a **navegação facetada** é a abordagem utilizada pela maioria (STOLZ e HEPP 2015) e pelas principais¹ companhias *online*, como *Amazon.com*, *Ebay.com* e *Alibaba.com*. Nesses portais, os mecanismos de busca oferecem ao usuário uma listagem contendo as principais características técnicas do produto como opção de filtro, bem como os possíveis valores de domínio que estes podem assumir. A Figura 1.2 ilustra uma parte do resultado de uma consulta a câmeras fotográficas digitais (DSLR²) em uma loja *online* conhecida - *Amazon.com*. O texto de busca foi "DSLR" e o resultado trouxe mais de 120.000 produtos.

¹ Referente ao valor de mercado (*Market Capitalization*) apresentado pela Bolsa de Valores NASDAQ (www.nasdaq.com, Maio de 2016), que reúne ações de empresas de alta tecnologia em geral, como informática, eletrônica e telecomunicações.

² https://pt.wikipedia.org/wiki/Câmera_reflex_monobjetiva_digital

Figura 1.2 - Filtro de busca facetado de DSLRs. Fonte: amazon.com

É possível perceber pela Figura 1.2 que, para restringir a quantidade de resultados apresentados (lado direito da imagem) para esta categoria de produto, o usuário deve combinar um ou mais filtros disponíveis (lado esquerdo da imagem), o que irá permitir a comparação de um subconjunto menor de câmeras. Nesta navegação facetada tradicional, as características técnicas das alternativas disponíveis são listadas, sem deixar explícita a relação entre um ou mais filtros, nem o impacto que os mesmos podem ter sobre a utilização do produto pelo cliente.

Assim, para buscas em câmeras digitais DSLR, o sistema de busca tradicional (com navegação facetada orientada à *features*³) apresenta diversas opções de filtragem para esta categoria, como: resolução máxima, tamanho da tela do visor, resolução de captura de vídeo,

³ O termo *feature* pode ser traduzido como recurso. Neste trabalho, o estamos utilizando para generalizar qualquer característica que pode ser extraída da especificação técnica do produto, geralmente fornecida pelo fabricante. Essas *features* são inerentes à constituição do produto, desde coisas mais gerais a qualquer categoria, (como peso, tamanho e consumo), até coisas bem específicas (como zoom óptico e ISO, no caso de câmeras digitais).

tamanho do sensor, ISO mínimo e máximo, zoom óptico, velocidade do flash, dentre outros. Para cada uma dessas opções (*features*), são fornecidos intervalos ou sequências de valores que deverão ser escolhidos para gradativamente restringir o resultado da busca.

A busca facetada baseada em *features* possui diversas vantagens para o analista que está construindo o sistema, pois é fácil apresentar um filtro de uma categoria de produto listando todas as características que acompanham a especificação técnica do fabricante. E os valores de domínio são formados pela união de todas as marcas e modelos que existem no catálogo. Para um usuário que conhece o significado das *features* da categoria que deseja adquirir, a busca facetada tradicional tem um funcionamento mais direto, fazendo com que o resultado seja encontrado mais rapidamente.

Apesar de ainda ser a abordagem mais utilizada em sistemas de comércio online, segundo Singh (2015) a busca facetada tradicional pode prejudicar a exploração da informação pelo usuário do sistema. O cliente que não esteja familiarizado com cada *feature* para escolher os produtos que melhor atendam suas necessidades encontra diversas limitações com as opções de filtro disponíveis para "traduzir" os conceitos técnicos em informações mais abstratas e relacionadas com as suas necessidades.

Diversos estudos (por exemplo, LUO e ZHANG 2012; KIM et al. 2012; CHIU et al. 2009) corroboram que um portal de vendas amigável e a qualidade da informação disponível no momento da compra são fatores que influenciam diretamente na decisão de compra pelos consumidores *online*. Portanto, apesar do sucesso expressivo do comércio eletrônico, é importante a evolução contínua dos seus portais.

Por outro lado, a construção de uma busca facetada orientada a critérios de necessidades exige um conhecimento especialista para cada categoria de produto, para determinar uma relação das especificações técnicas com necessidades dos usuários. Um conteúdo significativo com esse tipo de informação pode ser encontrado de forma semi-estruturada na *web*, disponibilizado em sítios de avaliações (*reviews*⁴) de produtos.

Quando as informações disponíveis para escolher um produto não são suficientes, o cliente pode fazer uso destas *reviews* realizadas por especialistas (ou por outros consumidores que já compraram ou conhecem o mesmo produto). Mas para um catálogo de opções extenso,

⁴ Neste trabalho estamos utilizando o termo *reviews* para representar avaliações realizadas por especialista ou através de opiniões de consumidores sobre os produtos. Em geral essas avaliações acompanham uma classificação (nota).

é possível que nem todos os produtos contenham essas *reviews*. Então, o usuário precisa realizar a comparação das alternativas manualmente, usando como referência as informações que conseguiu encontrar e compreender.

Sendo assim, mesmo encontrando a informação (tanto no próprio portal de venda quanto em outro sítio da *web*), a comparação manual é uma atividade desgastante para o consumidor. Um sistema que automatiza esse processo utilizando as mesmas informações consideradas por especialistas não são comuns, e quando disponíveis, atendem a categorias muito específicas de produtos. Acreditamos que os sistemas de comércio *online* poderiam possuir um mecanismo mais efetivo para classificar os produtos automaticamente, facilitando a atividade de comparação pelo consumidor durante sua compra.

Ao longo deste capítulo, detalhamos melhor as limitações da navegação facetada orientada a *features* e a importância de um processo automatizado para classificar os produtos que não possuem avaliações. Após a contextualização do problema, apresentamos uma visão geral da solução proposta. Em seguida, explicamos o método científico utilizado para avaliação da mesma, e a organização do texto desta dissertação.

1.1 Contextualização do Problema

Na busca facetada tradicional, uma categoria de produtos pode ser representada por um conjunto de *features* $F = \{f_1, f_2, f_3, \dots, f_n\}$, onde cada uma delas pode ser utilizada como parâmetro de filtro. Por outro lado, o usuário tem **necessidades**, $N = \{n_1, n_2, n_3, \dots, n_k\}$, que estão diretamente relacionadas com um subconjunto de *features* que irá supri-las. Logo, cada necessidade pode ser representada por um **subconjunto** de F , onde cada *feature* contém uma relevância (peso) diferente em relação a esta necessidade.

Seja P uma categoria de produto comercializada por uma loja *online*, que possui em seu catálogo diversas marcas e modelos (ou seja, $P = \{p_1, p_2, p_3, \dots, p_m\}$). Então, para cada par produto-*feature* temos um valor $V(p_x, f_y)$ que pode ser aplicado como filtro na busca facetada. Ao aplicar V ao conjunto total de alternativas, alguns resultados serão selecionados formando um subconjunto menor de produtos.

Suponha uma situação onde um consumidor deseja comprar um produto da categoria P e que, para atender a sua necessidade n_1 , precisa encontrar alternativas com os melhores valores possíveis em duas *features* (f_1 e f_2). Porém, considerando todas as marcas e modelos na loja, não existe uma opção (p_x) tal que as duas *features* tenham seus valores

simultaneamente iguais ao valor máximo existente no filtro. Ou seja,

$$\nexists p_x \mid V(p_x, f_1) = \text{Max}_{i=1..n} [V(p_i, f_1)] \text{ and } V(p_x, f_2) = \text{Max}_{i=1..n} [V(p_i, f_2)]$$

Exemplificando, suponha que a principal necessidade de um consumidor leigo⁵ em câmeras fotográficas digitais (DSLR) seja o uso em ambientes com pouca luminosidade. Para encontrar o produto mais adequado, este consumidor teria que utilizar como filtro os valores das *features* “(a) Velocidade do Obturador” e “(b) Abertura do Diafragma”, por exemplo. Sem o correto entendimento das *features* (e dos pesos), pode ser difícil perceber que ambas estão relacionadas com sua necessidade e, portanto, seriam relevantes. Ao aplicar o filtro (a), restringindo seu valor, o usuário pode eliminar acidentalmente produtos que possuem um bom valor na *feature* (b), sem conseguir ponderar as duas informações simultaneamente.

Em outra situação, um consumidor que deseja encontrar a melhor câmera digital capaz de tirar fotografias para "posterior impressão em tamanho grande (mantendo a qualidade da imagem)", poderia escolher erroneamente valores altos no filtro "Zoom Óptico". Assim, a busca facetada retornaria câmeras com boa "capacidade de aproximar a imagem a ser fotografada", mas que não possui relação direta com a *feature* correta, que no caso seria “Resolução Máxima em *Megapixels*”.

Em linhas gerais, a navegação facetada com essas características pode limitar a capacidade de avaliação das alternativas retornadas pelo sistema de busca, impedindo a exploração adequada da informação. O usuário deve então adquirir conhecimento a respeito da categoria de produto, recorrendo a outras fontes de informação compiladas por especialistas, por exemplo.

De acordo com Huang (2015), avaliações de produtos (*reviews*) disponibilizadas na *web* têm aumentado significativamente e podem influenciar a decisão de compra do consumidor. Muitas vezes, quando uma *review* de produto é realizada por especialistas, as informações sobre as opções avaliadas são apresentadas de forma que fique claro para o consumidor quais *features* estão relacionadas⁶ a determinados aspectos do produto. Mas é

⁵ Neste trabalho, consideramos leigo o usuário que não possui total conhecimento técnico a respeito das *features* de uma determinada categoria de produto, nem de todas as necessidades que as mesmas podem atender.

⁶ Diversos portais de avaliação (*review*) de produtos contém essa abstração. Por exemplo: *cnet.com*, *toptenreviews.com*, *buscape.com.br*, *digitaltrends.com*, *consumersearch.com*, *argos.co.uk* e *gsmarena.com*.

possível que não exista uma avaliação para todas as marcas e modelos disponíveis, então o consumidor deve realizar uma comparação manual dos produtos.

Em outras palavras, esses dados semi-estruturados das *reviews* podem ser utilizados para treinar um modelo que faça a comparação automaticamente, levando em consideração as *features* e os aspectos utilizados pelo especialista.

Os sistemas de comércio eletrônico que utilizam apenas a busca facetada tradicional (orientada a *features*), não permitem uma comparação amigável de produtos pelo usuário leigo. Na próxima seção demonstraremos que os critérios de necessidade são relevantes no momento de tomada de decisão do consumidor, assim como as características técnicas do produto.

1.1.1 Processo Decisório de Compra

Um dos modelos mais utilizados para representar o processo decisório de um consumidor no momento da compra foi proposto por Engel et al. (1968), conhecido como Modelo EKB. Apesar de não ser um modelo recente, segundo Ashman et al. (2015), "[o modelo EKB] ainda fornece informações valiosas e explicações sobre a tomada de decisão do consumidor". Outros trabalhos também corroboram com esta afirmativa, como (FRUTOS et al. 2014; DARLEY et al. 2010). Este modelo consiste em cinco passos exercidos pelo comprador, que são: (i) Reconhecimento do Problema ou Necessidade, (ii) Busca por Informações, (iii) Avaliação das Alternativas, (iv) Compra e (v) Comportamento Pós-Compra. Como o foco da nossa pesquisa é apenas na busca do produto mais adequado, os dois últimos passos (iv e v) não fazem parte do escopo.

Assim, em uma situação hipotética, um consumidor sem muito conhecimento técnico em *smartphones*, seguiria os seguintes passos para realizar uma compra com bom custo-benefício:

- ✓ **Passo 1:** Reconhecimento do Problema/Necessidade: "Gostaria de comprar um *smartphone* que fosse muito bom principalmente em questões de **autonomia**."
- ✓ **Passo 2:** Busca por Informações: "Dentre todas as opções que a loja tem, qual é (ou quais são) a(s) *feature(s)* capaz(es) de atender esta necessidade?"

Neste momento, sem a informação explícita na loja online, este consumidor deverá buscar por outras fontes (*wikis*, sítios de tutoriais na *web* e/ou *reviews*) tentando compreender

a utilidade de cada *feature* apresentada pela interface facetada. Tais *features* poderiam ser: número de núcleos do processador, sistema operacional, memória interna e duração da bateria, por exemplo.

Após o estudo, o consumidor descobre que as *features* mais relevantes para sua necessidade são: memória interna e duração da bateria. Com isso é possível seguir ao próximo passo do processo de compra:

- ✓ **Passo 3:** Avaliação das Alternativas: “Quais *smartphones* possuem os melhores valores de memória interna e duração da bateria, dentro do meu poder de compra?”.

Somente então o consumidor estará habilitado a comparar as especificações técnicas de cada alternativa considerando os valores destas duas *features*. Esse processo pode ser exaustivo para um consumidor leigo, mesmo em posse das informações adequadas. Nossa pesquisa está melhor contextualizada nos passos 2 e 3 do processo apresentado, pois acreditamos que os mesmos possam ser realizados por uma solução que avalie de forma automática as alternativas para o usuário que identificou as suas necessidades.

1.1.2 Motivação

O trabalho de Häubl e Trifts (2000) sugere que "ajudar o consumidor na comparação dos produtos disponíveis em um ambiente de comércio *online* pode gerar fortes efeitos favoráveis na qualidade e eficiência da decisão de compra". Diversos trabalhos na literatura têm como foco o problema da busca e comparação de produtos em um sistema de comércio *online*. A seguir apresentamos algumas dessas pesquisas demonstrando a relevância do tema do nosso trabalho.

Ward e Lee (2011) fizeram um estudo sobre comércio online, afirmando que quanto mais experiente é o usuário, mais a informação sobre um determinado produto sobrepõe à marca: “A Internet pode levar a um aumento da qualidade dos produtos, pois marca é um mecanismo imperfeito para assegurar qualidade”. Assim, acreditamos que seja importante auxiliar o usuário no momento da busca de um produto, fornecendo o máximo de informação a respeito das características técnicas e de como estas podem atender as necessidades do cliente que está fazendo sua escolha.

Diversos trabalhos, (como ZIN et al. 2014; DEVI e SAINI 2015), têm como foco a evolução da busca de produtos da *web*, com o objetivo de entender e explicar o

comportamento dos usuários no momento de realizar uma compra. Nestes trabalhos, é apresentada a importância do tema no contexto atual e das mudanças que podem surgir no futuro.

Outros trabalhos na literatura (AGRAWAL et al. 2009; CAPANNINI et al. 2011; OUNIS et al. 2015; HU et al. 2015) demonstram o interesse pela diversificação de busca na *web* e também pela personalização destas buscas (VALLET e CASTELLS 2012; LIANG et al. 2014; MAKEEV et al. 2014; CARTER et al. 2011). Carter et al. (2011) mudam o foco da busca de produtos para uma visão orientada a tarefas, ou seja, as motivações de utilização do produto, propondo um método que através de um pequeno questionário, direciona o consumidor para produtos com as características que deseja ou precisa. Nossa proposta se diferencia ao levar em consideração o valor de todas as *features* e não apenas se um produto possui ou não um recurso. O trabalho de Carter et al. (2011) também tenta facilitar a busca para o usuário, ao solicitar que o mesmo informe quais atividades deseja exercer, mas não propõe uma classificação automática de produto que possam suprir essas necessidades.

Em (VANDIC et al. 2012) é proposta a utilização de recursos da *web* semântica para anotação de produtos em sites de venda. Com isso, uma *string*⁷ de busca é convertida em consulta SPARQL⁸, apresentando um filtro multifacetado para o usuário. Apesar de ser uma solução expansível, Vandic et al. (2012) não propuseram uma modelagem conceitual da relação entre requisitos e especificações técnicas. Mas nós entendemos que a consulta de produtos baseado somente em *features* dificulta o consumidor leigo na categoria que deseja comprar. Portanto, propomos uma solução que traduza as necessidades em um nível mais abstrato e classifique os resultados em função das *features* relacionadas.

O trabalho de Ghose et al. (2012) consiste em aperfeiçoar os resultados em uma busca através de critérios de parada, minimizando a quantidade de resultados e assim, permitindo um esforço menor do usuário em comparar as opções. A comparação dos produtos também está no contexto da nossa solução, mas avaliamos uma solução que faça essa comparação automaticamente, fornecendo ao usuário somente a classificação final baseada em suas necessidades.

A utilização de recursos visuais, como adequação de interface e enriquecimento de usabilidade, também é um tema explorado em soluções de busca na *web*: Parameswaran et al.

⁷ Termo utilizado pelo usuário em uma consulta textual.

⁸ Linguagem de consulta em banco de dados semânticos.

(2014) utilizam diferentes formatos de entrada (áudio, vídeo e texto) como parâmetros de busca, enquanto Lee et al. (2010) e Khan et al. (2015) realizam uma clusterização⁹ visual dos resultados de acordo com o valor das *features*. Ren et al. (2015) realizam um estudo sobre a importância de minerar e ordenar a intenção do usuário através dos termos de busca. Mottin et al. (2014) apresentam um novo paradigma considerando o termo de busca do usuário como um exemplo do dado em que está interessado. Nossa proposta também tem como foco facilitar a comparação das alternativas pelo usuário, porém com menor necessidade de conhecimento sobre o significado das *features*, ao relacionar estas com critérios menos técnicos e mais fáceis de serem compreendidos por um usuário leigo.

Apesar de diversas propostas para tentar minimizar o esforço do usuário em encontrar os produtos que melhor atendem a suas necessidades, a abordagem mais utilizada nos sistemas de busca em comércio *online* é a busca facetada orientada à *features*.

1.2 Proposta de Solução

Consideramos que os filtros utilizados na busca facetada são insuficientes quando o consumidor não possui conhecimento técnico a respeito das *features* na categoria de produto que deseja comprar. Por outro lado, pode ser impossível encontrar avaliações de especialistas ou opiniões de usuários a respeito de todas as marcas e modelos disponíveis, obrigando a comparação manual entre as alternativas. Nossa pesquisa pretende possibilitar um *ranking*¹⁰ automático de produtos, levando em consideração as necessidades do cliente e os valores das *features* de cada alternativa, alinhado com o Processo Decisório de Compra.

Nossa solução abstrai o entendimento de cada *feature* (individualmente), focando nas necessidades e desejos que as mesmas (coletivamente) representam para o cliente. Sendo assim, os filtros são substituídos por um significado mais próximo ao consumidor leigo na categoria do produto, com menos foco em conceitos técnicos. Essa abstração permite que o cliente compreenda a utilidade de cada *feature* em relação às suas necessidades, possibilitando a comparação dos produtos.

Em outras palavras, queremos que o usuário oriente sua consulta através de suas necessidades e desejos, sem a complexidade de comparar os valores de cada *feature*

⁹ Clusterização é uma forma de agrupar por similaridades.

¹⁰ *Ranking* é o processo de classificação, ou ordenação do resultado da busca.

manualmente. Para isso, utilizamos um método de decisão multicritério¹¹, para realizar o cálculo de priorização das alternativas¹² automaticamente, tendo como insumo *reviews* de especialistas coletadas da *web*. Ou seja, apesar de grande parte da informação estar disponível *online*, propomos uma solução capaz de estruturar e processar esses dados. Por outro lado, informações que não estão presentes na especificação técnica do produto (nem nas *reviews* de especialistas) foram determinadas através de uma técnica de aprendizagem de máquina (SHAPIRO 2001) junto com o método de decisão multicritério.

1.3 Hipótese de Pesquisa

Durante a avaliação da nossa proposta, pretendemos investigar a seguinte hipótese:

- H1: **SE** um método multicritério for utilizado com *reviews* de produtos, relacionando *features* com critérios agrupadores **ENTÃO** haverá uma **correlação** minimamente forte entre o *ranking* calculado e o fornecido pelo especialista.

Também serão analisadas a precisão e o ganho de informação do *ranking* calculado em relação ao *ranking* do especialista. Se a hipótese não for descartada, podemos afirmar que a solução é viável como modelo de *ranking* automático de produtos. Assim, o usuário que não encontra *reviews* de especialista para todos os produtos da categoria desejada, poderia utilizar nosso modelo ao invés de realizar a comparação dos mesmos manualmente no momento da compra.

1.4 Metodologia

Para avaliar a solução proposta, um experimento foi conduzido com diversas categorias de produtos, a fim de coletar dados que permitam uma análise quantitativa para investigar nossa hipótese. Utilizamos, como dados de teste, *reviews* realizadas por especialistas nessas categorias e extraídas de um sítio da *web* que disponibiliza esse conteúdo de forma detalhada. Os aspectos levados em consideração pelo especialista (para agrupar as *features*) foram utilizados para representar os critérios de necessidades dos usuários.

¹¹ Métodos de decisão (ou análise) multicritério são técnicas para apoiar a decisão de escolha da melhor opção dentre um conjunto de alternativas disponíveis, levando em consideração critérios conflitantes. Uma explicação mais detalhada sobre as características desses métodos é abordada no Capítulo 2 de Fundamentação Teórica desta dissertação.

¹² Neste trabalho, cada alternativa é um produto que está avaliado e disponível para classificação. Em um método de decisão multicritério, o processo de *ranking* das alternativas é chamado também de priorização.

Os resultados obtidos com a nossa solução foram comparados com a nota (*rating*) atribuída pelos especialistas nas *reviews*. Através da análise quantitativa pretendemos avaliar se o *ranking* da nossa solução pode ser capaz de substituir o *ranking* do especialista, demonstrando sua viabilidade e eficácia.

Para fazer a avaliação, utilizamos três métricas muito comuns em medições de sistemas de Recuperação da Informação (*Information Retrieval*). Essas métricas têm como objetivo medir a correlação entre os *ranks*, a precisão e o ganho de informação, respectivamente. Em outras palavras, nossa pesquisa analisa se a solução proposta é capaz de fornecer ao usuário uma nota coerente para produtos que ainda não foram avaliados por especialistas. Essa nota deve estar de acordo com a especificação técnica e as necessidades de usuários, tal como os produtos que foram avaliados nas *reviews*.

1.5 Organização da Dissertação

Os próximos capítulos desta dissertação estão organizados conforme a seguir. O Capítulo 2 apresenta a fundamentação teórica que embasou nossa pesquisa, bem como os trabalhos relacionados. O capítulo 3 formaliza nossa proposta de solução, enquanto o Capítulo 4 aprofunda no detalhamento da arquitetura de implementação que foi utilizada na avaliação. O Capítulo 5 apresenta o projeto de avaliação, os dados de teste e o processamento destes. O Capítulo 6 analisa os resultados das medições do experimento que investigam as nossas hipóteses. E, por fim, o Capítulo 7 conclui o nosso trabalho, apresentando propostas de trabalhos futuros e nossas contribuições práticas e teóricas.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, apresentamos o embasamento teórico que nos ajudou a identificar o problema dentro do contexto de Sistemas de Informação. Durante a elaboração da solução recorreremos a técnicas bem consolidadas na academia e no mercado que também serão brevemente explicadas. Além disso, fazemos uma revisão de trabalhos relacionados que propuseram soluções semelhantes para o mesmo problema.

Primeiramente explicamos o conceito de Busca Exploratória e seu foco na construção de sistemas de busca que unem usabilidade com a melhoria na recuperação de informações. Em seguida, as duas principais técnicas que fazem parte da arquitetura da nossa solução: Processo Analítico Hierárquico e Algoritmo Genético. Finalizamos o capítulo com os diferenciais da nossa solução em relação a propostas atuais para *ranking* automático de produtos.

2.1 Busca Exploratória

De acordo com Marchionini (2006), a tendência atual de uma navegação mais rica na web e, portanto, um engajamento mais ativo no processo de busca, conduz a pesquisas que combinam a interação humano-computador (IHC) com recuperação de informação (RI). Esta navegação mais rica envolve estratégias de seleção e tentativa e erro, que aumentam a expectativa da utilização da web como fonte de **aprendizagem e investigação**.

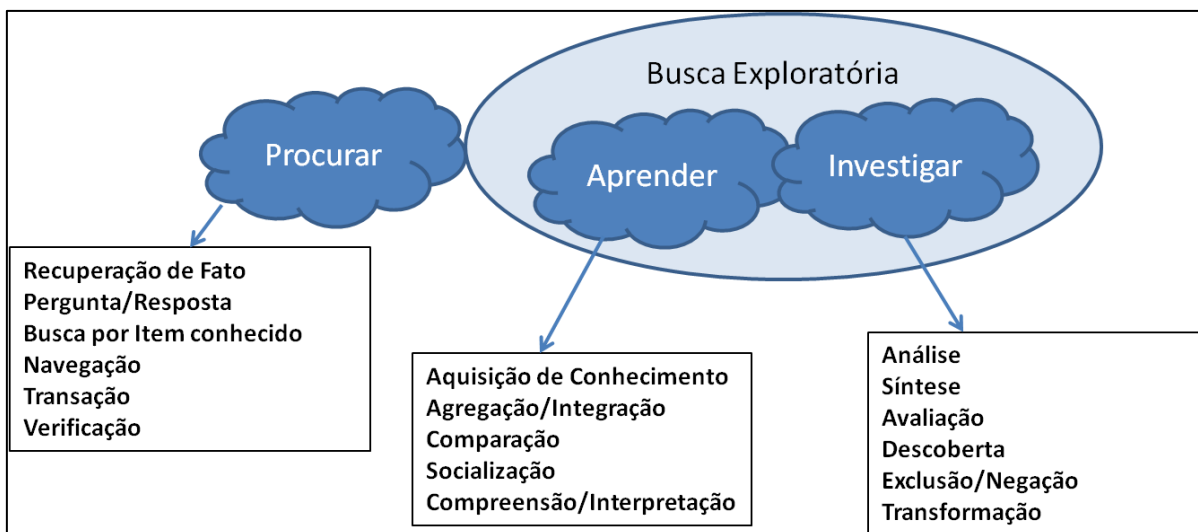


Figura 2.1 - Esquema das atividades de Busca. Fonte: (MARCHIONINI, 2006), traduzido.

A Figura 2.1 ilustra o contexto da Busca Exploratória em relação às atividades de busca em geral sendo que ações mais simples, como "Pergunta e Resposta" e "Busca por Item conhecido" não fazem parte do contexto de Busca Exploratória. Esta consiste em um retorno (*feedback*) para o usuário bem mais complexo e completo, desde a "Aquisição de Conhecimento" até a "Transformação" da informação recuperada.

Ainda segundo Marchionini (2006), para suportar esta variedade de atividades, "a comunidade [de pesquisas] de RI está aprimorando IHC para descobrir maneiras de aproximar os humanos a uma forma mais ativa no processo de busca". Baseado nestas propriedades, e nas limitações que a navegação facetada tradicional pode apresentar no contexto de busca de produtos, direcionamos nossa solução para o enriquecimento do processo de exploração da informação.

Alinhado com o Processo Decisório de Compra, consideramos que um usuário leigo em uma categoria de produtos deve adquirir conhecimento a respeito desta, a fim de fazer a melhor escolha conforme suas necessidades. Portanto, mais do que simplesmente fornecer uma classificação de produtos, a solução precisa ser enriquecida com conhecimento, ao mesmo tempo em que sua estrutura e de seu comportamento sejam transparentes para o usuário.

Apesar de não ser escopo desta pesquisa avaliar o grau deste *feedback* para o usuário, tivemos a preocupação de encontrar uma solução que permita a comparação efetiva de produtos baseada não somente na especificação técnica dos mesmos, mas também em

critérios que são mais abstratos. O objetivo é, de certa forma, traduzir conceitos complexos para um usuário leigo, a um entendimento mais simples e próximo do cotidiano.

2.2 *Analytic Hierarchy Process - AHP*

Diversos trabalhos na literatura (VELASQUES e HESTER 2013; SINGH e MALIK 2014; ZAVADSKAS et al. 2014; ALIAS et al. 2008) consideram o AHP como um dos métodos de análise multicritério mais populares na indústria e centros de pesquisa. As principais vantagens e possíveis razões para isso estão na flexibilidade da sua estrutura e na clareza da importância de cada elemento que a compõe (ARULDOSS et al. 2013).

A característica mais comum do AHP está em decompor um problema complexo de decisão em problemas menores (SAATY 2008), facilitando a análise de quem está tomando a decisão. Quanto mais inferior é o nível da hierarquia, mais específicos são os **critérios**. Em nossa proposta, substituímos o julgamento de um especialista em produtos, por um processo automatizado de avaliação das alternativas. Mas a decomposição do problema (que tem como resultado construir a estrutura hierárquica do AHP) é totalmente baseada nas informações que este mesmo especialista considerou em sua avaliação.

Na estrutura hierárquica AHP, o julgamento em cada camada é feito através de um processo chamado Comparação Pareada (*Pairwise Comparison*). Neste, os elementos de cada nível são comparados dois a dois¹³, atribuindo um valor que representa o grau de priorização dado a cada um deles. A informação resultante deste processo de comparação é uma matriz¹⁴.

Para exemplificar, suponha que um critério esteja associado a três subcritérios (SC_1 , SC_2 , SC_3). Portanto a comparação é feita para 3 pares: (SC_1 , SC_2), (SC_1 , SC_3) e (SC_2 , SC_3). Um valor $X_{a,b}$ é atribuído a cada um desses pares, formando uma Matriz ($M_{3 \times 3}$) da seguinte forma:

$$M_{3 \times 3} = \begin{bmatrix} 1 & X_{1,2} & X_{1,3} \\ 1/X_{1,2} & 1 & X_{2,3} \\ 1/X_{1,3} & 1/X_{2,3} & 1 \end{bmatrix}, \text{ onde}$$

¹³ Os pares de elementos são comparados em grupos, onde cada grupo é formado por itens que estejam relacionados com o mesmo critério de uma camada imediatamente superior na estrutura hierárquica.

¹⁴ Matriz de Comparação pareada (do Inglês, *Pairwise Comparison Matrix*).

- $X[n,n] = 1$, ou seja, a comparação de um elemento com ele mesmo é sempre igual a 1 (um).
- $X[n,m] = (X[m,n])^{-1}$, ou seja, a comparação entre dois elementos (n e m) é igual ao inverso da comparação entre m e n .
- $X_{a,b}$ é um número diferente de zero, por exemplo¹⁵ entre 1/9 e 9.

Ao atribuir um valor $X_{a,b}$ para um par, estamos informando o quanto a é melhor do que b , de uma maneira mais subjetiva. Então, se $(SC_1, SC_2) = 5$, isso significa que foi dado um grau de valor 5 para esta comparação, onde SC_1 é melhor do que SC_2 , e conseqüentemente, o inverso $(SC_2, SC_1) = 1/5$, ou 0,2.

Cada matriz de comparação pareada é convertida em um vetor (W) normalizado de pesos (prioridades), indicando o quanto cada **subcritério** tem influência no **critério** ao qual está associado.

Na nossa solução, a comparação entre as *features* de um produto não é subjetiva. Esses valores são calculados diretamente através das especificações técnicas fornecidas pelo fabricante. O capítulo 3 explica em detalhes como isso é feito.

2.3 Algoritmo Genético

Em nosso trabalho, um valor numérico informa o quanto determinada *feature* é relevante para um critério ao qual está associada, formando também uma Matriz de Comparação. Infelizmente, esse dado pode não existir no momento de construir o modelo, pois o especialista não informa o método que utilizou para atribuir o peso de cada *feature*. Então, para contornar este problema, recorreremos a uma técnica de aprendizagem de máquina (SHAPIRO 2001) utilizando algoritmo genético (Mitchell 1998) capaz de encontrar automaticamente a melhor solução para cada cenário (processo que chamamos de calibragem). A escolha de algoritmo genético ao invés de outras opções estatísticas (como Redes Bayesianas ou Máquina de Vetores de Suporte) se deu pela pouca quantidade de produtos avaliados em cada categoria.

Um algoritmo genético (AG) é composto por elementos e operações análogas ao processo evolutivo natural. Nele, uma solução possível (e válida) é representada por um **cromossomo** (indivíduo). Este cromossomo é formado por um conjunto de **genes**, sendo cada

¹⁵ Este exemplo dado é conhecido como Escala Saaty (Saaty, 1977).

um deles correspondente a um valor que é utilizado no contexto ao qual o AG está sendo aplicado. No nosso caso, cada gene representa um valor no vetor de pesos (**W**) AHP, conforme explicado na seção anterior deste capítulo.

Ao conjunto de cromossomos dá-se o nome de **população**, ou seja, diversas soluções viáveis que serão utilizadas para formar uma nova **geração** de cromossomos. Após se definir uma população inicial, o AG é executado iterativamente para que, através de **operações genéticas**, novas soluções sejam criadas. As principais operações são:

- *Acasalamento*: dois indivíduos são selecionados para reproduzirem.
- *Crossing-over*: um novo indivíduo é formado a partir da combinação dos valores de outros cromossomos já existentes.
- *Mutação*: são pequenas alterações realizadas diretamente em um indivíduo, para gerar um novo cromossomo.

O processo iterativo tem como objetivo avaliar as novas soluções encontradas e determinar se estão mais **adaptadas** ao cenário. Isso é medido através de uma função (*Fitness Function*) que fornece um valor para cada indivíduo da população: quanto maior o valor, mais adaptado é o indivíduo (cromossomo). A cada iteração, indivíduos passam por um processo de reprodução (acasalamento, *crossing-over* e mutação) e uma nova geração é formada com os indivíduos mais adaptados, e a população é modificada¹⁶.

Sem a utilização do AG junto com o AHP, o resultado final da classificação dos produtos seria relativo apenas aos valores das *features*. Mas na prática, determinadas *features* são mais relevantes do que outras em relação ao critério de necessidade que estão associadas.

2.4 Trabalhos Relacionados

Nesta seção, discutimos como alguns trabalhos relacionados apresentam soluções que podem ser utilizadas para o problema de *ranking* automático de produtos, a fim de facilitar a comparação de alternativas feitas por um usuário na *web*. Em geral, os trabalhos encontrados propõem soluções para identificar e classificar os diferentes **aspectos** de um produto, baseado em mineração de opiniões (*opinion-mining*).

¹⁶ Este processo pode ocorrer até que não se encontre uma solução melhor, ou então que um critério de parada o interrompa. Um critério de parada possível pode ser um valor mínimo aceitável para a função de adaptação ou a quantidade de evoluções de uma população.

Diversos trabalhos (NAJMI et al. 2015; ZHA et al. 2014; YU et al. 2011; ZHANG et al. 2010; TIAN et al. 2009) abordam esse direcionamento na possibilidade de sintetizar um grande volume de informações em conhecimento para o usuário. Todos eles ressaltam a importância das revisões de produtos feitas por usuário dentro de um ambiente de comércio eletrônico, bem como estas revisões podem ter influência no processo de compra por outros consumidores. Estes trabalhos também têm em comum soluções que levam em consideração algumas características, tais como:

- Extração de texto contendo opiniões de consumidores na web a respeito de uma marca ou modelo específico de produto.
- Identificação dos aspectos dos produtos, contidos nestas revisões.
- Análise de Sentimento para classificar esses aspectos (positiva ou negativamente).
- Processo que calcula o peso da relevância dos aspectos encontrados dentro dos textos de opiniões e a influência que estes têm sobre a nota geral atribuída para os produtos avaliados. Por exemplo: solução probabilística¹⁷ (ZHA et al. 2014) ou algoritmo *PageRank*¹⁸ (ZHANG et al. 2010).

Apesar de algumas diferenças entre as soluções, todas têm como objetivo agregar as opiniões de todos os usuários que fizeram uma revisão sobre um mesmo produto (marca e modelo). Com exceção do trabalho de Najmi¹⁹ et al. (2015), os demais não fizeram uma avaliação da qualidade final do *ranking* produzido, focando mais nas características da proposta de identificar, analisar e valorar os aspectos. Mesmo assim, as propostas afirmam que os produtos poderiam ser classificados em relação a um determinado aspecto, por exemplo: *design*, *performance*, peso ou garantia.

Segundo Najmi et al. (2015), as opiniões e revisões feitas por usuários ganhou muita importância com o advento da web social. Porém esse tipo de informação existe geralmente de forma não estruturada (texto-livre). Possivelmente, por esta razão, os aspectos identificados sobre os produtos podem conter tanto *features* propriamente ditas, quanto

¹⁷ Leva em consideração a frequência que determinado aspecto é citado em uma opinião.

¹⁸ Algoritmo baseado em grafos, criado e utilizado pela Google™ para *ranking* de páginas relevantes indexadas na web.

¹⁹ Najmi *et al.* (2015) avançaram na avaliação da proposta, realizando experimentos para medir a utilidade do *ranking* gerado.

critérios de necessidades mais abstratos, ou seja, sem a discriminação/categorização dos mesmos.

Nossa proposta se diferencia destes trabalhos em diversas características. Nossa solução usa uma fonte de dados mais estruturada, fornecida por especialistas nas categorias de produtos, ao invés de usuários consumidores. O objetivo foi possibilitar que, através de um conhecimento especializado, seja possível treinar um modelo que possa ser generalizado para outros produtos que não possuem avaliação.

Os trabalhos acima referenciados não levam em consideração os valores das *features* dos produtos. Já a nossa proposta utiliza essa informação também, além do que foi explicitado pelo especialista. Entretanto, a maior diferença da nossa pesquisa em relação a estes trabalhos está no fato de que eles só podem classificar e gerar um *ranking* para os produtos que tiveram alguma avaliação ou opinião de especialistas e/ou consumidores. Nossa proposta trata essa limitação construindo um modelo que permita a inclusão de um produto ainda não avaliado, para fornecer uma classificação deste em relação aos demais. Por essa razão que consideramos importante não desprezar as informações da especificação técnica dos produtos, fornecida pelo fabricante.

O trabalho de Feng (2009) apresenta uma solução para classificação e *ranking* de produtos em ambientes de venda consumidor-para-consumidor (C2C). Porém a abordagem converge menos com a nossa solução do que aqueles apresentados anteriormente. Isso se dá uma vez que o foco deste último é classificar produtos idênticos (mesma marca e modelo) vendidos por lojas diferentes. Neste caso, os critérios de comparação não são os aspectos ou *features* dos produtos, mas sim características mais relacionadas com o vendedor, por exemplo: preço, tempo de entrega, quantidade desejada e confiança na loja.

Por fim, Li et al. (2011) propuseram um modelo de *ranking* de produtos através de característica em comum (afinidade). Para isso, aspectos do produto são extraídos de opiniões de consumidores para "prever um *ranking* de produtos de acordo com a afinidade entre eles". Porém seu foco são os sistemas de recomendação (de empresas de marketing e estratégia de negócio) que podem fazer uso da classificação por afinidade, prevendo um *ranking* para um momento futuro.

2.5 Considerações Finais

Neste capítulo, o objetivo foi fornecer insumos teóricos, relacionados com o nosso problema e com a solução proposta. Assim, além de descrever alguns trabalhos relacionados, que foram encontrados na literatura, apresentamos algumas estratégias tecnológicas que apoiaram a construção de um modelo de *ranking* automático de produtos.

Não menos importante, foi apresentada também neste capítulo uma comparação do nosso trabalho com outros que estão inseridos no mesmo campo de pesquisas em Busca e Recuperação da Informação.

O próximo capítulo contém a explicação da solução proposta, todos os seus elementos e premissas, para o processo de *ranking* de produtos.

3 RANKING AUTOMÁTICO DE PRODUTOS

Durante o desenvolvimento da solução, conduzimos um questionário com 37 voluntários sobre a usabilidade de uma interface²⁰ *online* simulando²¹ a busca de produtos em um sítio de compras *online*. Nesta interface, cada participante visualizava três opções de busca facetada.

- i. Busca facetada tradicional orientada a *features*.
- ii. Busca facetada orientada a critérios de necessidade (utilizadas em *reviews*).
- iii. Busca mista com as duas opções acima.

As três opções de busca continham filtros específicos para algumas categorias de produto (Cadeira de Montanhismo, Servidor e Celular Smartphone). O APÊNDICE E contém a tela com as opções de categorias que podiam ser escolhidas pelo participante. O APÊNDICE F ilustra um exemplo das três opções de busca para uma das categorias selecionadas pelo participante (celular). Por fim, o APÊNDICE G apresenta o formulário no qual cada participante informou o grau de conhecimento que possui a respeito das categorias disponíveis.

Após navegar pela interface, quantas vezes desejassem, os voluntários responderam um Questionário de Usabilidade de Sistema (SUS - *System Usability Survey*, vide APÊNDICE H). Este questionário tem como objetivo calcular o índice de satisfação do usuário (BROOKE 1996), a partir do qual verificamos que (em relação aos participantes):

- existe uma preferência pela interface da busca facetada orientada a critérios de necessidades (opção b), quando o usuário declarava que não era familiarizado com a categoria;

²⁰ Código-fonte em <https://github.com/Tivor/qop>

²¹ Um experimento semelhante foi conduzido por Felix et al. (2002), mas com apenas uma categoria de produto e somente com usuários leigos nesta categoria.

- quando o participante declarava que conhecia a categoria de produto, a busca facetada tradicional (opção a) era preferida sobre as demais.

Nosso trabalho tem como foco o usuário que está buscando um produto que atende suas necessidades, em uma categoria que se considera leigo. Portanto, seria importante considerar esses critérios de necessidade na construção do modelo apresentado neste capítulo.

O objetivo principal da nossa pesquisa é propor uma solução de *ranking* automático para produtos não avaliados por especialistas, tendo como informação disponível apenas a especificação técnica dos mesmos. Então, chegamos a um modelo capaz de integrar os valores das *features* com critérios de necessidades do usuário.

3.1 RANK2BUY

Nossa proposta (RANK2BUY²²) utiliza um modelo de análise multicritério para cada categoria de produto e, como dados de entrada, *reviews* realizadas por especialistas para algumas opções desta categoria. O objetivo da solução é permitir que outros produtos que ainda não foram avaliados possam ser devidamente classificados em relação aos demais. Além disso, o modelo proposto mantém um agrupamento de *features* por necessidades do cliente, permitindo uma comparação das alternativas orientada a critérios menos técnicos. Portanto, seria mais fácil para o consumidor que não esteja familiarizado com os detalhes técnicos da categoria que está querendo comprar busca produtos e selecionar o mais adequado.

O modelo proposto neste trabalho tem como vantagem manter explícita a relação entre especificação técnica de produtos e critérios de necessidades. Mas o principal objetivo é permitir um *ranking* automático de produtos não avaliados em um sistema de comércio *online*, a partir de outros produtos que já foram avaliados. Como resultado, a solução evitaria o esforço manual do usuário em realizar uma comparação "produto a produto".

Nas próximas seções, explicamos o modelo conceitual da solução proposta, através de cada etapa do processamento dos dados de entrada. Estas etapas são respectivamente: a montagem da estrutura do método de análise multicritério e o seu preenchimento com a calibragem da importância das *features* em relação aos critérios e processamento dos valores

²² Uma tradução de "classificar para comprar" no inglês, *Rank to Buy*.

das *features* de cada produto. Finalizamos o capítulo explicando como esses componentes se integram e como o *ranking* é realizado.

3.2 Montagem da Estrutura Inicial do AHP

Suponha que para a categoria de *Smartphones*, o especialista tenha realizado uma avaliação completa com dez modelos diferentes, tendo definido alguns critérios pertinentes e informado quais *features* estão relacionadas a cada critério, chegando a um resultado, através de notas, conforme ilustrado na Figura 3.1.

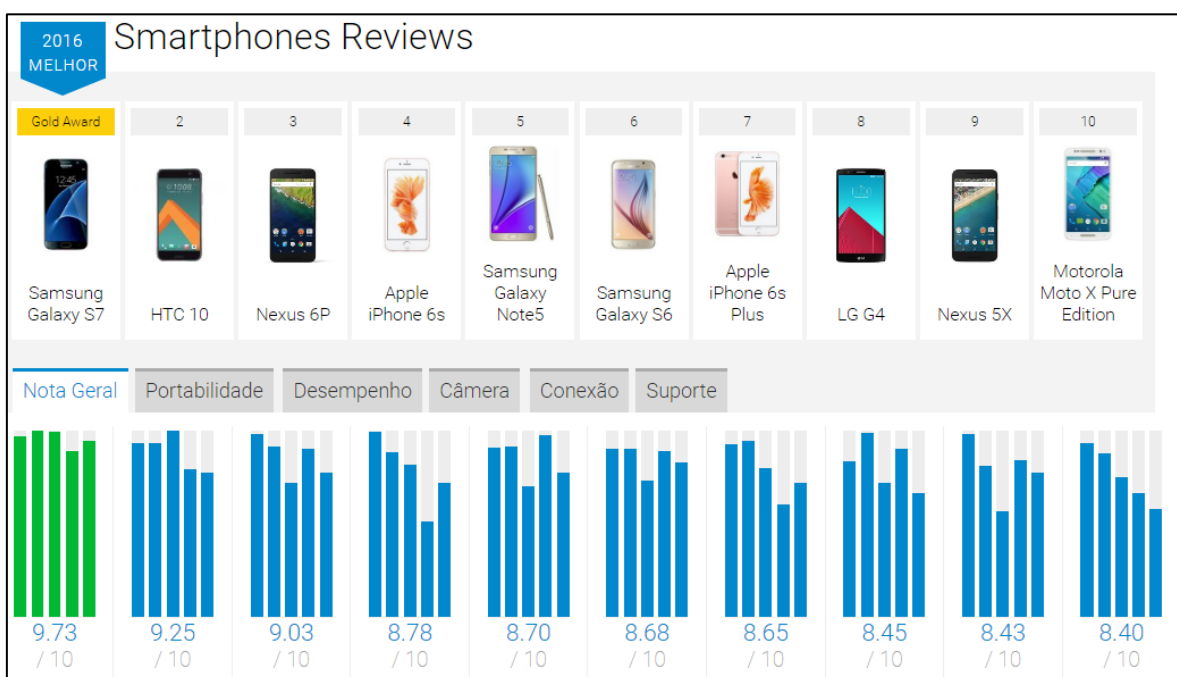


Figura 3.1 - Exemplo de uma avaliação de *smartphones* com notas.

Na parte mais inferior da Figura 3.1, podemos verificar que cada produto avaliado recebeu uma nota geral, podendo chegar até dez. No gráfico de barras logo acima das notas, estão ilustradas as avaliações dos produtos em relação a cada critério individualmente (uma barra por critério).

Esta categoria de produto (*smartphones*) contém diversas características técnicas (*features*) que podem ser quantificadas e agrupadas em critérios mais abstratos. Ainda através da Figura 3.1, podemos verificar que o especialista decidiu agrupar as *features* em cinco critérios de necessidades, que são:

- **Portabilidade:** nível de mobilidade do dispositivo em uso, facilidade no deslocamento.

- **Desempenho:** velocidade de execução do *software* (sistema operacional e aplicações) instalado no dispositivo.
- **Câmera:** qualidade de imagem capturada pela(s) câmera(s) do dispositivo para foto e vídeo.
- **Conexão:** interfaces de comunicação do dispositivo com outros aparelhos.
- **Suporte:** apoio e contato técnico em caso de problemas ou dúvidas.

Assim, o especialista levou em consideração as *features* que correspondem corretamente a cada um desses critérios. Os valores dessas *features* são disponibilizados pelo fabricante, mas a organização através dos critérios mencionados exigiu um conhecimento que o consumidor pode não possuir completamente ao realizar uma busca no sistema de comércio eletrônico.

Na Tabela 3.1, temos uma possível situação do relacionamento de algumas *features* com cada critério definido pelo especialista para esta categoria de *Smartphones*.

Tabela 3.1 - Relação entre Critérios de Necessidades e Especificação Técnica (*features*).

Critério	<i>Features</i> Relacionadas
Portabilidade	Duração da bateria, Peso, Tamanho e Memória Interna.
Desempenho	Clock do Processador, Nº de Núcleos e Memória RAM.
Câmera	Resolução Frontal, Resolução Traseira e Vídeo em Full HD.
Conexão	USB, 3G/4G, Wi-Fi e Bluetooth.
Suporte	Tempo de Garantia, Help-Desk, Chat e Telefone.

É possível identificar através da Tabela 3.1, que os Critérios exigem um entendimento mais genérico a respeito da capacidade do produto em atender as necessidades do cliente. Já as *Features* Relacionadas são os elementos mais técnicos, que em conjunto, representam estas necessidades, segundo a visão do especialista.

Em linhas gerais, esta visão do especialista finda por representar (mesmo que parcialmente) as necessidades do consumidor. Levamos isso em consideração, uma vez que essa abstração é útil para alguém que não retém conhecimento completo a respeito da especificação técnica, independente da categoria em questão.

Esta organização (entre critério e *features*) definida por um especialista pode ser feita de forma diferente por um segundo especialista. Mas escolhemos esta estrutura para nossa proposta, pois, além de ser comumente encontrada em portais de avaliação de produto, sua característica hierárquica permite contemplar mais níveis de abstração das *features*.

Dadas essas informações extraídas da avaliação do especialista (critérios de necessidades, *features* e alternativas), podemos treinar um modelo de análise multicritério para posteriormente calcular a nota de um produto que não pertence ao conjunto inicial de alternativas. Portanto, definimos uma estrutura hierárquica para nosso modelo, com o objetivo de representar a abstração feita pelo especialista, que também será útil para o usuário consumidor. A Figura 3.2 ilustra um esquema simplificado para o mesmo exemplo com *smartphones*.

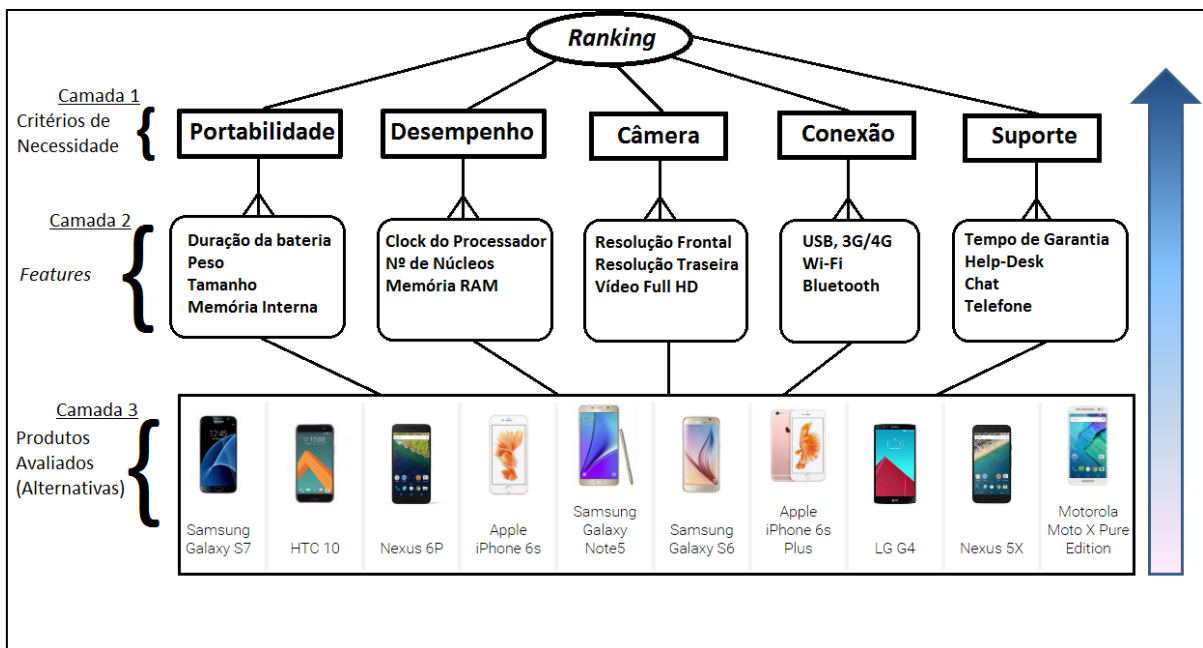


Figura 3.2 - Esquema simplificado da estrutura hierárquica da proposta.

Na Figura 3.2 podemos verificar que o modelo da solução proposta é formado por três camadas que, ao serem computadas, irão resultar em um *Ranking* geral. Em suma, o modelo é treinado com as informações fornecidas pelo especialista, para posteriormente ser capaz de calcular uma nota para uma alternativa desconhecida (produto não avaliado). Como o objetivo final do modelo é o *ranking* a partir da especificação técnica dos produtos, a estrutura hierárquica ilustrada na Figura 3.2 indica que o modelo pode ser concebido em uma visão *bottom-up*, ou seja, de baixo para cima.

Cada elemento (e_i) de uma camada **inferior** é conectado com um elemento (e_s) da camada imediatamente **superior** através de arestas (ligações na Figura 3.2). O valor (W) de cada aresta é representado pela influência de e_i sobre e_s , em relação aos demais elementos que estão no mesmo nível de e_i , também ligados a e_s . Essa influência é calculada por uma função de peso (w), tal que $W = w(e_i, e_s)$. Com essa definição, iremos demonstrar como é calculado o valor das arestas entre cada camada.

Durante a construção da estrutura, vamos considerar que todos os critérios de necessidade (c) tem influência igual no *ranking* dos produtos, ou seja, $w(c_n) = 1/n$, onde n é o número de critérios. Esta simplificação (entre a CAMADA 1 e o resultado do *ranking* geral) indica que todos os critérios definidos pelo especialista são considerados igualmente importantes, durante o treinamento do modelo. Nas próximas duas seções iremos explicar como chegamos aos valores das arestas entre a CAMADA 1 e CAMADA 2, e também entre a CAMADA 2 e CAMADA 3, respectivamente.

3.3 Calibragem da Importância das *features* em Relação aos Critérios

Apesar de não possuímos completamente o método de cálculo das notas do especialista, nosso trabalho utiliza a relação entre critérios e *features* (bem como os valores utilizados e fornecidos por ele) para treinar o modelo que está sendo proposto. Porém, uma parte da informação, que infelizmente não é fornecida, é de suma importância para a geração de um modelo mais consistente. Esta informação diz respeito ao valor das arestas entre a CAMADA 1 e a CAMADA 2, ou seja, o peso das *features* em relação ao critério que estão associadas.

Diferentemente do que fazemos para o peso dos critérios de necessidade em relação ao *ranking*, não podemos considerar que todas as *features* ligadas a um critério c_x possuem a mesma relevância, ou seja, $w(f_n, c) \neq 1/n$, onde n é a quantidade de *features* ligadas a c . Se tratássemos todas as *features* igualmente, o resultado final do modelo seria calculado em função apenas dos valores na CAMADA 2, ou seja, da especificação técnica do produto. Mas é coerente afirmar que, mesmo sem saber o real método de avaliação utilizado pelo especialista, podem existir diferenças na influência das *features*. Por exemplo, para o critério “Suporte”, é possível que o especialista considere que “Tempo de Garantia” seja mais importante do que “Atendimento por *Chat*”.

Como não temos essa informação, precisamos efetuar uma calibragem automática dos pesos, tendo como parâmetro as notas atribuídas pelo especialista. Através de um algoritmo de aprendizagem de máquina, nós ajustamos os valores das arestas entre a CAMADA 1 e a CAMADA 2, até que o modelo como um todo forneça um resultado final próximo ao *ranking* do especialista. Um esquema simplificado deste algoritmo é ilustrado pela Figura 3.3.

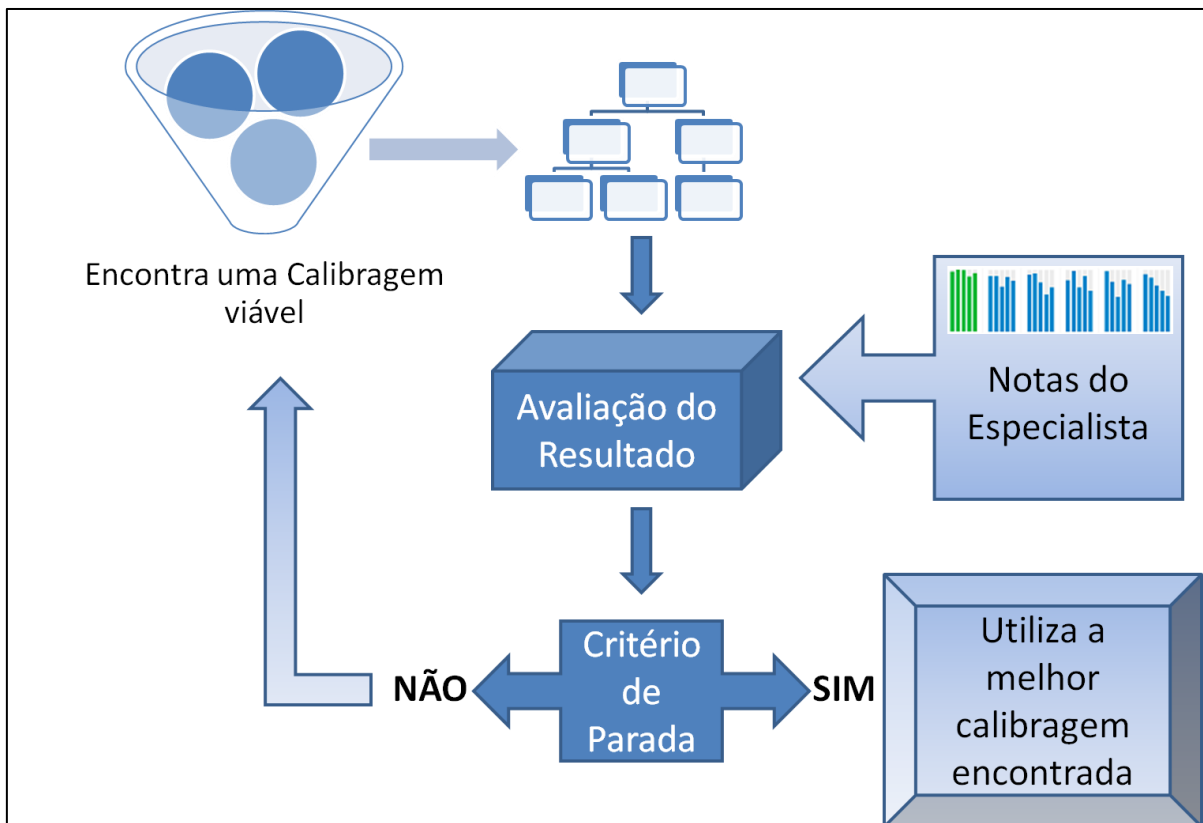


Figura 3.3 - Processo de calibragem das arestas entre a CAMADA 1 e 2.

De acordo com a Figura 3.3, atribuímos valores iniciais para popular nosso modelo hierárquico. O resultado (nota) encontrado é confrontado com as notas atribuídas pelo especialista, para determinar o quão próximo os dois *ranks* estão. A cada iteração, enquanto o processo não é interrompido pelo critério de parada, determinamos novos valores viáveis para calibragem.

Na prática, utilizamos nosso próprio modelo no processo de calibragem e, por isso, não é possível afirmar que iremos chegar a um resultado idêntico ao do especialista. Adotamos então um critério de parada, que ao ser atingido, interrompe o processo de calibragem fornecendo como saída a melhor distribuição de pesos encontrada até então. A melhor distribuição de pesos encontrada é aquela que fornece, através do nosso modelo, o resultado mais próximo do *ranking* do especialista. Através desta técnica, foi possível atribuir

valores coerentes com a avaliação do especialista, sem precisar fazer a calibragem manualmente. A vantagem é poder determinar valores que não são fornecidos previamente, sem uma atribuição arbitrária dos valores (aleatória, por exemplo). Em outras palavras, esse processo substitui o raciocínio do especialista no momento de julgar a importância de cada *feature* que atende a uma mesma necessidade.

A explicação sobre o processamento dos valores das *features* será dada na próxima seção para completar a estrutura de análise multicritério e, em seguida, explicaremos como o cálculo do *ranking* é realizado.

3.4 Processamento dos Valores da *Features*

Sabemos que a especificação técnica de um produto é fornecida pelo fabricante. O especialista pode fazer uso dessa informação para realizar sua avaliação, bem como o próprio consumidor. Porém, para alguém que não está familiarizado com todas as características técnicas que uma determinada categoria pode conter, o trabalho de comparação manual e individual pode ser muito penoso. Nesta seção, iremos demonstrar como que os valores de *features* dos produtos, $f(\mathbf{p})$, são utilizados para preencher as arestas entre a CAMADA 2 e a CAMADA 3.

Apesar de sabermos que um produto pode conter inúmeras *features* (dada a especificação do fabricante), levamos em consideração na nossa proposta apenas as que foram utilizadas pelo especialista para representar os critérios de necessidade. Além disso, nem todos os modelos de uma categoria precisam conter exatamente todos os recursos, sendo atribuído o valor zero ao peso da aresta quando isso acontece.

Se uma *feature* f está associada a n produtos $\mathbf{P} = \{p_1, p_2, p_3, \dots, p_n\}$, cada valor de ligação $A = w(p_x, f)$ indica o quanto $f(p_x)$ é melhor ou pior que os outros produtos em relação a essa mesma *feature*, ou seja,

$$w(p_x, f) = \frac{f(p_x)}{\sum_{y=1}^n f(p_y)}$$

Então, suponha que temos cinco produtos avaliados para uma categoria qualquer, todos contendo a *feature* "Tempo de Garantia" (sob o critério "Suporte") e seus valores estejam exemplificados através da Tabela 3.2.

A Tabela 3.2 informa, na terceira coluna, que os valores desta *feature* em cada produto foram convertidos para uma mesma unidade de medida, totalizando 54 meses. A quarta coluna informa o valor do peso da aresta da *feature* "Tempo de Garantia" para cada produto. Este cálculo é realizado para todas as *features* e produtos do modelo, e o resultado será utilizado junto com os pesos das demais camadas na estrutura.

Tabela 3.2 - Valores de Tempo de Garantia dos Produtos.

Produto	Tempo de Garantia	Nº de meses: $f(p_x)$	$w(p_x, f)$
p_1	1 ano	12	$12 / 54 \approx 0,222$
p_2	9 meses	9	$9 / 54 \approx 0,1666$
p_3	3 meses	3	$3 / 54 \approx 0,0555$
p_4	2 anos	24	$24 / 54 \approx 0,444$
p_5	6 meses	6	$6 / 54 \approx 0,1111$

A especificação técnica do produto pode possuir os mais diversos tipos de *features*, com as mais variadas unidades de medidas. O nosso modelo considera apenas as que podem ser quantificadas para a realização do cálculo de peso. Todas elas precisam ser cuidadosamente compreendidas conforme orientação do especialista para fazer a conversão correta. Por exemplo, para uma determinada situação, o especialista informa que quanto **menor** o valor da *feature*, **melhor** é o produto. Neste caso, a aresta é calculada com o inverso do valor, $V = w(p_x, f^{-1})$. O APÊNDICE A apresenta uma listagem com diversos exemplos de *features*, seus formatos e como foram utilizados pelo especialista.

3.5 Cálculo do *Ranking*

Este capítulo apresentou até aqui como as informações que são disponibilizadas pelo especialista são tratadas para construção do modelo que irá calcular o *ranking* de produtos não avaliados. O diagrama ilustrado na Figura 3.4 representa o processo de tratamento dos valores, construção da estrutura e a inclusão de um novo produto não avaliado para ter sua nota calculada em relação aos demais produtos.

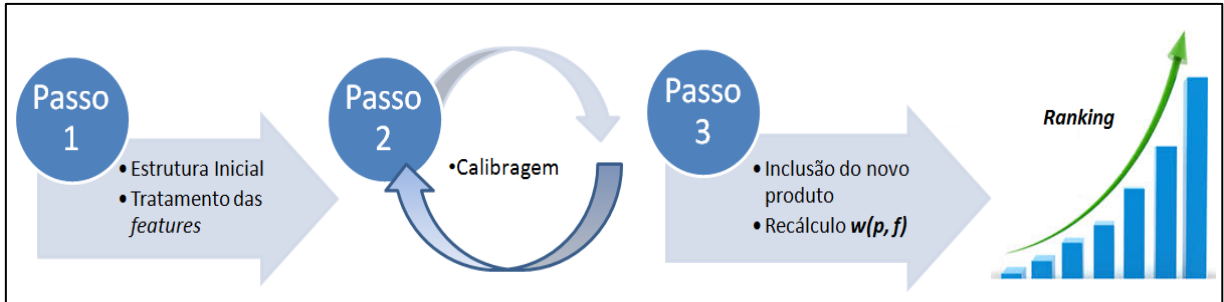


Figura 3.4 - Diagrama do Processo do Modelo de *Ranking* Proposto.

Cada passo destacado na Figura 3.4 está explicado conforme a seguir:

- **Passo 1:** A estrutura inicial do modelo é criada para a categoria de produto que se deseja avaliar. Neste momento, os critérios de necessidade devem ser definidos pelo especialista, bem como as *features* que foram consideradas em cada critério e os produtos avaliados. Além disso, os valores de cada *feature* dos produtos são processados para calcular o peso das arestas entre a CAMADA 2 e 3.
- **Passo 2:** O processo de calibragem explicado na seção 3.2 é executado para determinar a influência de cada *feature* relacionada a um critério, baseado nas notas do especialista. No final deste passo, o modelo já está completo, pronto para receber como entrada um novo produto para ser avaliado.
- **Passo 3:** Um novo produto, ainda não avaliado, é inserido na estrutura e os pesos das arestas entre a CAMADA 2 e 3 devem ser recalculados, pois o valor total da soma de cada *feature* foi alterado após a inserção.

Uma determinada categoria de produtos pode ser definida por um conjunto C , cujos elementos são os critérios, definidos pelo especialista no momento da avaliação para agrupar as *features*. Ou seja, $C = \{c_1, c_2, c_3, \dots, c_n\}$, onde n é o número de critérios.

Cada critério por sua vez pode ser representado por um conjunto F , composto pelas *features* as quais está associado. Então, $F_c = \{f_1, f_2, f_3, \dots, f_m\}$, onde m é o número de *features* em cada conjunto F_c . O resultado final do modelo é um novo *ranking* de produtos, cujo valor V da nota individual de cada alternativa p é calculada conforme fórmula a seguir:

$$V(p) = \sum_{i=1}^n \left[1/n \cdot \sum_{j=1}^m \omega(f_j, c_i) \cdot \omega(p, f_j) \right]$$

3.6 Considerações Finais

Nossa estrutura hierárquica permite uma abstração das *features* em critérios mais simples para o usuário que não tem conhecimento a respeito da especificação técnica de uma determinada categoria de produto. Para efeitos de simplificação durante a construção do modelo, o peso dos critérios foi distribuído igualmente: $w(c) = 1/n$.

Ao ser utilizada em um sistema de busca de produtos, essa distribuição corresponde a um parâmetro fornecido pelo usuário, representando sua priorização das necessidades disponíveis. Neste caso, $w(c)$ seria substituído pela normalização de um valor atribuído pelo usuário para cada critério. Apesar de ser compatível com o modelo, o escopo da nossa pesquisa se limita a avaliar a qualidade do *ranking* completo, ou seja, com todas as *features* e critérios.

Além da **posição** que um produto ocupa no *ranking*, o modelo proposto também fornece uma **nota**, tal como o especialista, informando o **quanto** um produto é melhor do que outro. Assim, um produto, que ainda não passou por uma avaliação detalhada de um especialista, pode ser classificado em relação aos demais informando apenas os valores contidos na especificação técnica. A única restrição para calcular a nota deste novo produto é considerar apenas as mesmas *features* que foram utilizadas durante construção do modelo.

A solução proposta tem como objetivo permitir o *ranking* de produtos não avaliados, com base em informações disponibilizadas por especialistas. O modelo apresentado é único para cada categoria de produto. Portanto, mesmo se duas categorias possuírem *features* e/ou critérios de necessidade em comum, as estruturas serão diferentes, uma vez que a avaliação do especialista foi realizada individualmente. O próximo capítulo irá detalhar a solução tecnológica, apresentando os algoritmos e estruturas de dados utilizados.

4 ARQUITETURA RANK2BUY

Neste capítulo apresentamos uma arquitetura para a solução proposta no capítulo anterior. Cada etapa do processo de *ranking* automático de produtos não avaliados, com base em *reviews* de especialistas, será aprofundada. O objetivo é apresentar a arquitetura que serviu de base para avaliação da nossa proposta, esclarecendo os algoritmos e as técnicas utilizadas em sua implementação²³. As seções foram organizadas da seguinte forma: primeiramente explicamos a utilização do Processo Analítico Hierárquico (AHP) como método de análise multicritério e, em seguida, a calibragem dos pesos das *features* sob os critérios através de um Algoritmo Genético. Finalizamos o capítulo exemplificando a execução completa para uma categoria de produtos, e como a solução pode ser utilizada por um usuário para realizar uma busca orientada a necessidades.

4.1 Estrutura AHP

Neste trabalho, escolhemos o AHP como método de análise multicritério, cuja estrutura de dados (que permite a organização de *features* em critérios de necessidades), juntamente com o algoritmo de priorização serviu de base para construirmos um modelo concreto, que permitiu avaliarmos a solução proposta. Além de ser amplamente utilizado no contexto de suporte à decisão, o AHP possui um conjunto de vantagens que são adequadas ao modelo apresentado neste trabalho. As principais características que nos ajudaram são:

- Além de calcular um *ranking*, o AHP fornece também notas indicando o quanto uma alternativa é melhor do que outra. Essa característica é necessária quando precisamos levar em consideração que o especialista também fornece notas para os produtos.

²³ Toda a implementação para testar a solução foi feita utilizando-se a linguagem de programação Java (www.oracle.com/java/), versão 7.

- A estrutura do AHP é hierárquica, o que permite uma solução expansível caso seja necessária uma abstração das *features* em mais níveis até chegar à camada dos critérios de necessidade. É importante considerar essa situação caso a avaliação do especialista siga uma estrutura mais complexa²⁴ do que a apresentada no Capítulo 3.
- O Processo Decisório de Compra pode ser um processo árduo para usuários que são leigos em algumas categorias de produtos. A principal característica do AHP é decompor uma decisão complexa em camadas mais simples. Sendo assim, podemos considerar que a "decisão" do consumidor no momento de comparação das *features* pode ser facilitada se for realizada através de critérios menos técnicos, uma vez que fica a cargo da solução calcular a influência das *features* automaticamente (baseado nas informações contidas na especificação técnica).
- A inclusão de um novo produto para avaliação (após a construção da estrutura inicial) exige a alteração em apenas uma camada: para recalcular os pesos das *features* dos produtos.
- Nossa solução realiza automaticamente a calibragem da importância das *features* em relação aos critérios de necessidade. Mas o AHP permite o ajuste fino desses valores por algum usuário ou especialista, sem alteração na estrutura em si. Isso pode ser necessário caso a calibragem automática não seja satisfatória.
- A estrutura e seus dados podem ser facilmente expostos, tornando transparente a organização dos critérios, suas *features* e os respectivos pesos. Isso permite que o usuário esteja ciente do que está envolvido no cálculo para poder criticar a confiabilidade do resultado.

Além dessas características, o AHP foi elaborado para facilitar o processo decisório de grupos ou indivíduos baseado em critérios, em múltiplos níveis. A comparação pareada explicada no Capítulo 2 é uma estratégia que permite ao indivíduo fazer seu julgamento aos poucos, sem precisar levar em consideração todos os elementos simultaneamente. Mas para o nosso contexto, mesmo esta tarefa seria desgastante de realizar manualmente para todos os conjuntos de alternativas, *features* e critérios.

Nossa proposta se beneficia das características do AHP, mas automatiza esse processo em todas suas camadas, permitindo que o usuário do sistema altere apenas os pesos das

²⁴ Apesar de ser uma situação possível, durante nossa pesquisa não foram encontrados portais de *reviews* de especialistas, nem referências na literatura que apresentassem uma estrutura com mais níveis do que a que foi considerada neste trabalho.

arestas no nível mais superior, se desejar. Ou seja, caso considere que o Critério de Necessidade X é mais importante do que Y , a proposta recalcula o *ranking* com essa nova informação. Isso é possível sem precisar alterar nada na estrutura e nenhum dos valores que já foram calculados durante o processamento das *features* e o processo de calibragem.

A estrutura de dados que mantém as informações necessárias para o cálculo de prioridades do AHP pode ser representada por um grafo unidirecional, conexo e sem ciclos (árvore). Este grafo contém um único vértice raiz (que chamamos de **objetivo**) no primeiro nível, enquanto os demais níveis são formados por critérios de necessidade, *features* e alternativas, respectivamente. A Figura 4.1 ilustra um diagrama de classes UML que representa um vértice na estrutura AHP.

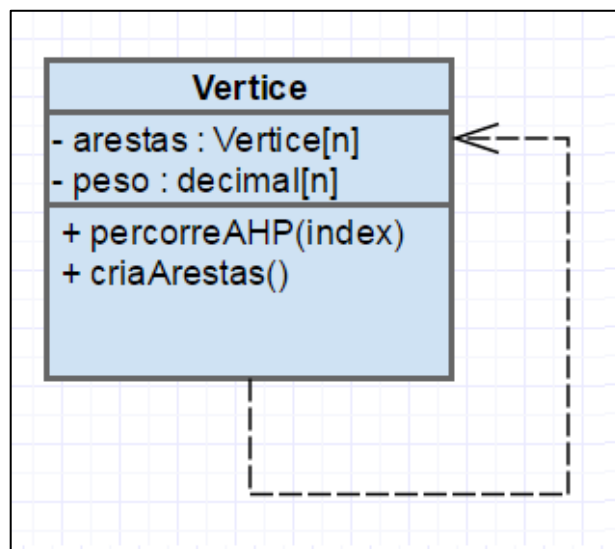


Figura 4.1 - Diagrama de Classes UML representando a estrutura AHP.

Pela Figura 4.1 podemos ver que a classe *Vertice* possui:

- arestas: um vetor com n referências (arestas) para os vértices do nível imediatamente inferior, e
- peso: um vetor com os pesos (w) de cada aresta, sendo w um valor decimal.

Portanto, para construir a estrutura, basta informar as arestas que cada nó está associado e o vetor de pesos, onde cada elemento ($peso[n]$) do vetor corresponde ao valor da aresta ($arestas[n]$). O Capítulo 3 desta dissertação forneceu as informações de como preencher os valores dos vetores com os pesos em cada camada da estrutura. Assim, o algoritmo de *ranking* precisa percorrer recursivamente esta estrutura para encontrar a nota calculada de cada alternativa no nível mais inferior (vértices folhas).

4.2 Calibragem com Algoritmo Genético

Conforme explicado no Capítulo 3, como não possuímos a informação do peso de cada *feature* em relação ao critério de necessidade, não podemos simplesmente supor que todas são igualmente importantes. Para resolver esse problema técnico e encontrar os valores automaticamente, recorreremos a uma estratégia de algoritmo genético (AG) para fornecer a melhor calibragem possível das arestas entre os vértices dos critérios de necessidade e das *features*.

Cada critério possui um conjunto de *features* e, portanto, um vetor V com os pesos para cada elemento. O cromossomo C utilizado no AG é uma concatenação dos vetores de todos os critérios. Ou seja, $C = U_1^n(V_n)$, onde n é o número de critérios de necessidades. As funções evolutivas do AG (acasalamento, mutação e *crossing-over*) são responsáveis por promover a alteração dos genes do cromossomo e encontrar automaticamente valores para os vetores de peso (V).

Com essa estratégia, não precisamos fornecer os valores manualmente (o que poderia gerar algum viés indesejado), possibilitando a construção de um modelo mais coerente. Além disso, o AG busca soluções orientadas a um valor de referência ótimo, ou seja, mesmo que não encontre um resultado final ótimo, a solução segue um caminho que se aproxima cada vez mais deste. A Tabela 4.1 apresenta os parâmetros utilizados na execução do AG.

Tabela 4.1 - Parâmetro de Execução do AG.

Nome	Valor
Tamanho da População	50 indivíduos
Número de Gerações	1000
Taxa de Mutação	20%
Proporção de Crossing-over	35%
Taxa de Acasalamento	90% (seleção dos melhores)

Para medir o quão próximo do ótimo o cromossomo está, devemos fornecer para o AG uma função de adaptação (FA). No nosso caso escolhemos a razão inversa da distância euclidiana (DE) entre dois vetores ($vEsp$ e $vAHP$), dada pela fórmula abaixo:

$$FA = DE^{-1}, \text{ onde } DE = \sum_1^n \sqrt{(vEsp_n - vAHP_n)^2}$$

Ou seja, quanto menor a distância entre esses dois vetores, melhor é a solução encontrada. Esses vetores são:

- *vEsp*: *ranking* de produtos fornecidos por um especialista e
- *vAHP*: *ranking* de produtos calculado pelo AHP.

Cada categoria de produto possui um único *vEsp* fornecido pelo especialista. Porém, o *vAHP* calculado irá variar cada vez que o AG encontra uma solução para substituir na estrutura AHP (vide Figura 3.3, Capítulo 3).

Em outras palavras, a melhor solução encontrada pelo AG é aquela que fornece uma opção de calibragem (entre critérios e *features*), na estrutura AHP, que resulta em um *rank*²⁵ mais próximo da avaliação do especialista. O critério de parada do AG ocorre quando este não encontra uma solução melhor na troca da geração dos seus indivíduos, e foi escolhido desta forma após observarmos o comportamento da solução durante os testes.

Durante a construção do modelo, mais especificamente no processo de calibragem, devemos levar em consideração que estamos modelando um possível julgamento que o especialista faz das *features* em relação a cada critério que criou para agrupá-las. Portanto, no nosso trabalho, uma *feature* não pode ser indiscriminadamente mais importante do que outra. Apesar do AG permitir utilizar infinitos valores para compor o cromossomo, nós optamos por uma variação pequena para os genes, para representar melhor um julgamento feito por um especialista.

Alguns trabalhos do próprio autor do método AHP (SAATY 1977; SAATY 1985) sugerem uma escala para facilitar o julgamento de quem está fazendo a decisão manualmente, que vai de 1 a 9 apenas, conforme Tabela 4.2 (sendo 2, 4, 6 e 8 valores intermediários). Nosso algoritmo genético se baseou na escala Saaty²⁶ para simular o julgamento do especialista, variando os valores dos genes, também de 1 a 9.

²⁵ Como o AHP fornece os valores das notas das alternativas de forma normalizada, tivemos que converter o vetor original do especialista para um vetor também normalizado. Ou seja, cada valor no vetor do especialista era dividido pela soma de todos os elementos. Assim podemos comparar os vetores (FA) na mesma escala.

²⁶ A utilização desta escala gera como resultado uma matriz de comparação pareada que deve ser convertida em um vetor de pesos para posteriormente ser utilizado no cálculo de ranking. Este procedimento está explicado no APÊNDICE B.

Tabela 4.2 - Escala de Intensidade. Fonte: (SAATY, 1985), tradução.

Intensidade	Definição	Explicação
1	Igual	Duas <i>features</i> contribuem igualmente para o critério.
3	Moderado	Existe uma diferença moderada na contribuição de duas <i>features</i> para o critério.
5	Forte	Existe uma diferença forte na contribuição.
7	Muito Forte	Existe uma diferença muito forte na contribuição.
9	Extremamente Forte	A diferença da contribuição de duas <i>features</i> para o critério tem o nível mais alto possível.

4.3 Algoritmo Geral RANK2BUY

Para exemplificar o funcionamento geral da solução implementada, vamos realizar o processo completo de *ranking* para uma categoria de produtos. Suponha que um consumidor deseja comprar uma "TV LED de Tela Grande" e encontra a avaliação realizada por um especialista para sete modelos diferentes desta categoria. A nota geral fornecida na *review* para cada um dos modelos está ilustrada na Figura 4.2.

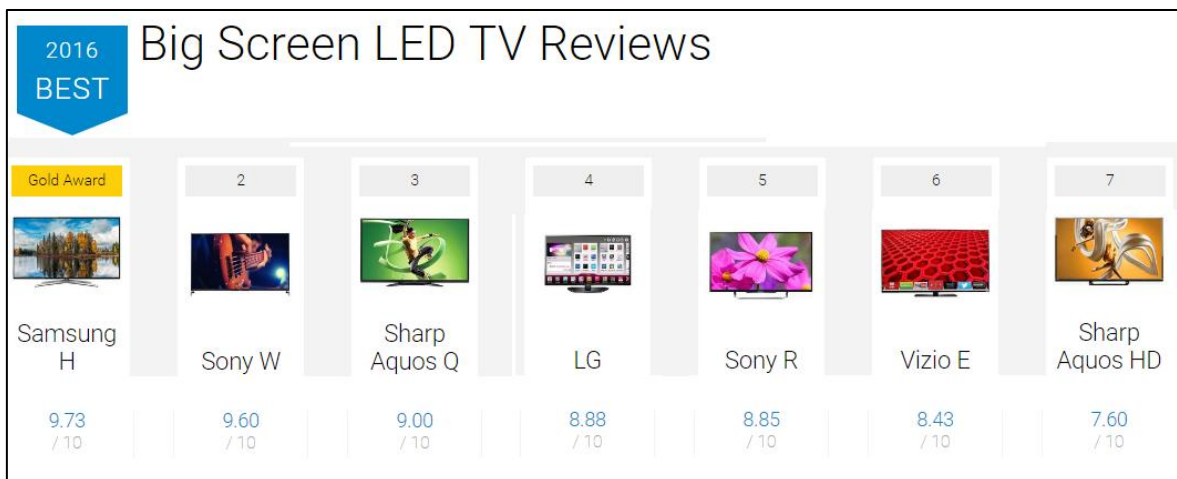


Figura 4.2 - Notas para modelos de TV LED de Tela Grande fornecida por um especialista em sua *review*. Fonte: toptenreviews.com

Essas notas são primeiramente normalizadas (conforme explicado na seção 3.4) para serem comparadas com o resultado do AHP. Os valores normalizados das notas que estão na Figura 4.2 estão representados na Tabela 4.3.

Tabela 4.3 - Valores Normalizados das Notas do Especialista.

Samsung H	Sony W	Aquos Q	LG	Sony R	Vizio E	Aquos HD
0,156708	0,154614	0,144951	0,143018	0,142535	0,135771	0,122403

Na *review*, o especialista utilizou quatro critérios para avaliar esses modelos e agrupar vinte e oito *features*. Alguns exemplos para cada critério são:

- **Qualidade de Vídeo:** nível de preto, resolução, taxa de contraste, ângulo de visão, precisão da cor.
- **Funções:** possui 3D, aplicativo de controle remoto no celular, controle por gestos, controle por voz.
- **Conexões (N°):** HDMI, USB, vídeo componente, ethernet.
- **Assistência Técnica:** tempo de garantia, telefone, *chat* ao vivo, email, manual online.

Suponha que um consumidor deseja saber se um novo produto disponibilizado no mercado (e que, portanto, ainda não possui avaliação) atende melhor a uma determinada necessidade. Assim, nossa solução utiliza as informações da *review* (de outros produtos da mesma categoria) para montar uma estrutura AHP, bem como a especificação técnica deste novo produto, que são disponibilizadas pelo fabricante, preenchendo assim os valores das *features* para este produto. Por fim é realizada uma calibragem através do AG completando as informações restantes da estrutura.

Durante este processo o AG realiza o cálculo intermediário das notas, para medir a distância *euclidiana* com as notas normalizadas do especialista. Este cálculo é feito de forma recursiva desde o vértice objetivo, até encontrar cada uma das alternativas. O Algoritmo ilustrado na Figura 4.3 contém um pseudocódigo deste processo.

O resultado mais próximo das notas (normalizadas) do especialista que o AG conseguir encontrar²⁷, usando a nossa estrutura AHP, está representado na Tabela 4.4.

Tabela 4.4 - Valores das Notas Geradas pelo RANK2BUY.

Samsung H	Sony W	Aquos Q	LG	Sony R	Vizio E	Aquos HD
0,156949	0,153905	0,144606	0,142957	0,143033	0,136281	0,122266

²⁷ Utilizando os valores apresentados nas Tabelas 4.2 e 4.3, também é possível saber qual é a menor distância *euclidiana* (DE) encontrada pelo AG.

Após estes passos, é possível inserir o novo produto (da mesma categoria) que não possui avaliação, para ter sua nota calculada através do RANK2BUY. A inclusão do mesmo é realizada no conjunto de alternativas, bem como os valores de suas *features*. É importante ressaltar que este será avaliado utilizando-se somente *features* que já se encontram na estrutura AHP construída, ignorando-se novas *features* que porventura possam fazer parte da especificação técnica deste novo produto.

Por fim, como a calibragem já foi realizada, basta executar o Algoritmo da Figura 4.3 novamente. Com o novo *ranking* calculado, descobre-se a posição que este produto irá ocupar dentre os demais, auxiliando o usuário em sua escolha e a comparação com as demais alternativas.

4.4 Considerações Finais

Este capítulo apresentou o detalhamento técnico da arquitetura da solução RANK2BUY proposta neste trabalho. Além do funcionamento geral, explicamos as vantagens e necessidades da utilização do AHP e de um algoritmo genético. O próximo capítulo irá explicar o projeto de avaliação da solução proposta, as informações de entrada, as restrições e as métricas utilizados ao longo de todo o experimento empírico para um conjunto variado de categorias de produtos.

```

1: //Entrada Objetivo: nó raiz
2: PROCEDIMENTO calculaNotas( Objetivo )
3: INÍCIO
4:   //Preenche vetor com notas de cada alternativa na estrutura AHP
5:   PARA CADA alternativa a em AHP FAÇA
6:     i ← índice de a
7:     Notas[i] ← Objetivo.percorreAHP(i)
8:   FIM PARA
9:   RETORNA Notas
10: FIM PROCEDIMENTO
11:
12: //Função recursiva que atravessa a estrutura AHP
13: //Entrada V: um vértice da estrutura AHP
14: //Entrada i: índice da alternativa que se deseja calcular a nota
15: FUNÇÃO percorreAHP( V , i )
16: INÍCIO
17:   SE V.arestas = alternativas ENTÃO
18:     RETORNA V.peso(i)
19:   SENÃO
20:     soma ← 0
21:     PARA CADA aresta x em V FAÇA
22:       soma ← soma + x.percorreAHP(i) * peso(i)
23:     FIM PARA
24:     RETORNA soma
25:   FIM SE
26: FIM FUNÇÃO

```

Figura 4.3 - Algoritmo do Cálculo de Nota das Alternativa

5 PROJETO DE AVALIAÇÃO DA SOLUÇÃO

Nossa proposta de solução faz uso de um mecanismo de calibragem automática (algoritmo genético) que ajusta os valores do modelo utilizando a própria solução. Esse processo poderia gerar uma calibragem com sobreajuste (*overfitting*), então a avaliação da nossa proposta deve levar em consideração se o modelo é realmente suficiente para a geração de um *ranking* de produtos, independente dos valores que foram encontrados durante o processo de calibragem.

Com o objetivo de avaliar a solução proposta para o problema de *ranking* automático de produtos, conduzimos um experimento para coletar resultados e realizar uma análise quantitativa da solução. Este capítulo apresenta o projeto de avaliação com as métricas utilizadas para validar as nossas hipóteses e os dados de entrada que utilizamos, que foram avaliações de especialistas para diversas categorias de produtos.

Primeiramente explicamos algumas métricas para avaliação de *ranking*, importantes na área recuperação da informação (IR - *Information Retrieval*) e a justificativa de utilizarmos cada uma delas. Em seguida, detalhamos os dados que foram coletados da *web* e que serviram como fonte para nossa avaliação e apresentamos o processo de avaliação propriamente dito em todas as suas fases.

5.1 Métricas de Avaliação de *Ranking*

Em IR, existem diversas métricas que podem avaliar a qualidade do retorno de uma consulta (CLARKE et al. 2008; VOORHEES e HARMAN 2005; YILMAZ et al. 2008). Neste trabalho, estamos mais preocupados com o resultado do *ranking*, então algumas métricas foram selecionadas para avaliar a correlação, a precisão e o ganho do mesmo. Esta seção irá apresentar essas métricas, suas funções e como são calculadas.

5.1.1 Correlação de Spearman

Em estatística, o coeficiente de correlação de *ranks Spearman*, representado pela letra grega ρ (rho), indica a força e a direção do relacionamento entre duas variáveis aleatórias (x e y). Nosso objetivo é medir o quanto o *ranking* calculado pela nossa solução está de acordo com o *ranking* do especialista. Ou seja, considerando o resultado final com todas as alternativas, queremos investigar se há uma relação direta entre os dois valores. A fórmula para o cálculo de ρ é:

$$\rho = 1 - \frac{6 \sum_1^i d_i^2}{(n^3 - n)}$$

onde, d_i é a diferença entre cada posição dos valores de x e y , e n é o número de pares, que em nosso caso é a quantidade de alternativas para cada categoria avaliada.

O coeficiente de *Spearman* pode assumir valores decimais entre -1 e 1. Quanto mais próximo de zero, menor é a correlação. O sinal do coeficiente indica se os *ranks* são inversa ou diretamente correlacionados, respectivamente.

Para calcular esse coeficiente, precisamos transformar as notas resultantes da nossa solução e do especialista em seu valor correspondente à ordem que ocupa no ranking. Assim, suponha que após a execução da nossa solução para uma categoria de produto, chegamos ao resultado demonstrado na Tabela 5.1. Os valores da Tabela 5.1 serão convertidos para valores inteiros que correspondem a sua posição, que estão apresentados na Tabela 5.2. Após essa conversão, os valores de d_i (e consequentemente d_i^2) podem ser calculados.

Somando a última coluna da Tabela 5.2, conforme fórmula de ρ , temos que $\sum d_i^2 = 10$ e, portanto, o resultado final é $\rho = 1 - (60 / 210) \approx 0,71428$. Com este resultado positivo, concluímos que os dois *ranks* estão diretamente relacionados. Segundo a literatura (CASTILHO et al. 2014), um valor de correlação acima de 0,7 pode ser considerado minimamente forte. Mas para ser significativa, o *p-value*²⁸ dessa correlação deve ser menor do que 0,05.

²⁸ *p-value* é uma função que mede o nível de significância estatística de uma correlação, com base no tamanho da amostra. Nossa implementação calculou *p-value* utilizando uma biblioteca de classes estatísticas em Java (JSC, 2016). O algoritmo é uma implementação do teste estatístico de *Hotelling e Pabst* (1936).

Tabela 5.1 - Resultado das notas normalizadas do especialista e da nossa solução.

	Sony W	Aquos Q	LG	Sony R	Vizio E	Aquos HD
Especialista	0,154614	0,144951	0,143018	0,142535	0,135771	0,122403
RANK2BUY	0,134614	0,154657	0,12839	0,144857	0,114543	0,104614

Tabela 5.2 - Resultado das notas convertidas para a posição correspondente.

	Nota	Nota	Posição	Posição	d_i	d_i^2
	Especialista	RANK2BUY	Especialista	RANK2BUY		
Sony W	0,154614	0,134614	1°	3°	-2	4
Aquos Q	0,144951	0,154657	2°	1°	1	1
LG	0,143018	0,12839	3°	4°	-1	1
Sony R	0,142535	0,144857	4°	2°	2	4
Vizio E	0,135771	0,114543	5°	5°	0	0
Aquos HD	0,122403	0,104614	6°	6°	0	0

Durante o levantamento das métricas na literatura para avaliar a nossa solução, verificamos que outro cálculo de coeficiente de correlação entre *ranks* também é muito utilizado, chamado τ (tau) de Kendall. Apesar possuir algumas vantagens sobre ρ conforme demonstrado no trabalho de Xu et al. (2013), escolhemos a correlação de *Spearman* por possuir uma característica que consideramos mais importante ao nosso contexto: ao elevar a diferença ao quadrado (d^2), o valor de *Spearman* torna-se mais sensível a discrepâncias muito grandes entre posições no *rank*. Em outras palavras, caso a nota calculada de uma alternativa em nossa solução ocupe uma posição no *ranking* muito diferente do especialista, ρ é mais penalizado do que τ . Isso é importante, pois para ordenação de produtos, é preferível que as melhores alternativas ocupem as primeiras posições e, conseqüentemente, as piores ocupem as últimas.

5.1.2 Precisão em k : P@k

Além da correlação, a precisão de um resultado é muito relevante como métrica em IR. A $P@k$, em linhas gerais, informa a quantidade de alternativas relevantes que estão nas primeiras posições do *rank*, independente da ordem. O objetivo com essa métrica é saber, para os melhores k produtos do *ranking* calculado pela nossa solução, quantos estão precisamente na mesma porção (k) do *ranking* do especialista.

O cálculo desta métrica é simples e pode ser representado pela fórmula:

$$P@k = \frac{n}{k}$$

onde n é a quantidade de alternativas em comum que estão nas k primeiras posições dos dois *ranks*. Utilizando o mesmo exemplo da Tabela 5.2, para $k = 3$, vemos que apenas os produtos *Sony W* e *Aquos Q* estão na mesma posição, logo $P@k = 2 / 3 = 0,75$.

Nas categorias de produtos que utilizamos como dados para avaliação da nossa solução, a quantidade de alternativas avaliadas pelo especialista é variável (porém pequena - em média 10). Escolhemos utilizar k igual ao teto da divisão inteira de $n / 2$, ou seja, a precisão foi calculada sempre para a metade superior²⁹ do *ranking*. Em outras palavras, estamos interessados em medir se os produtos mais relevantes segundo o especialista (ocupando as primeiras posições) estão sendo avaliados pela nossa solução da mesma forma.

Diferentemente da correlação de *Spearman*, o valor calculado de $P@k$ varia apenas entre 0 e 1, sendo 0 (zero) quando nossa solução não ordena nenhuma das alternativas nas k primeiras posições corretamente, e 1 (um) caso encontre o mesmo resultado do *ranking* do especialista nessas mesmas posições.

5.1.3 Normalized Discounted Cumulative Gain: nDCG

Esta última métrica³⁰ indica o ganho de informação que cada elemento no resultado fornece baseado em sua posição no *rank*. Além disso, o *nDCG* considera que os elementos nas primeiras posições são mais relevantes, portando cada elemento sofre um desconto à medida que sua posição é mais inferior no *rank*. Por fim, o resultado é normalizado pelo ganho considerado ideal, que no nosso caso é o *ranking* do especialista.

O ganho cumulativo pode ser calculado pela fórmula abaixo:

$$CG = \sum_{i=1}^n rel_i$$

onde n é o número de alternativas no *ranking* e rel_i a relevância de cada item do resultado, sem levar em consideração a sua posição. Mas a premissa do *nDCG* é penalizar os elementos

²⁹ Apesar de ser possível utilizar outros valores, determinamos essa restrição pois nosso contexto não possui uma quantidade muito grande de produtos avaliados.

³⁰ A Tradução para o português seria Desconto do Ganho Cumulativo Normalizado, e sua sigla é *nDCG*.

mais relevantes que estejam ocupando posições mais inferiores no *rank*. Portanto, *DCG* pode ser formulado conforme proposto por Wang (2013):

$$DCG = \sum_{i=1}^n \frac{2^{rel_i} - 1}{\log_2(i + 1)}$$

onde rel_i é a posição que o elemento está ocupando.

O valor de *DCG* deve ser normalizado para manter a mesma grandeza independente da quantidade de elementos no resultado. Para isso, dividimos *DCG calculado* com o valor de *DCG ideal*, ou seja, do *ranking* fornecido pelo especialista, fazendo com que esta métrica também possa assumir valores decimais entre 0 (zero) até 1 (um). Dizemos que *nDCG* é igual a 1 quando ambos os *ranks* são idênticos.

A fórmula final para *nDCG* é:

$$nDCG = \frac{DCG_{calculado}}{DCG_{especialista}}$$

5.2 Fonte de Dados

Nesta seção apresentamos qual a fonte de dados foi utilizada na avaliação da nossa solução. Buscamos através de diversos sítios com avaliações de especialistas na *web*, aqueles que contêm informação a respeito do máximo de categorias de produtos possível, além de fornecer notas (ou pelo menos a posição) dos produtos avaliados. Além desses requisitos, no nosso modelo precisamos utilizar avaliações que apresentam critérios agrupadores de *features*.

Em sítios de busca e comparação de preço³¹ de produtos na *web*, é comum encontrar avaliações organizadas através de critérios, mas que nem sempre apresentam uma explicação detalhada das *features* que foram consideradas em cada critério. Demos preferência a um destes sítios especialistas em avaliações de produtos, chamado TopTenReviews³².

O referido sítio contém avaliações de especialistas altamente detalhadas, atendendo a todos os critérios que precisamos para a avaliação quantitativa da nossa solução. Para

³¹ Por exemplo, buscape.com.br.

³² www.toptenreviews.com

minimizar o risco de viés do resultado da solução em somente algumas categorias de produtos, não fizemos nenhuma restrição no momento da escolha. De todas as categorias coletadas deste sítio, com avaliações de 2016, tivemos de retirar dos nossos testes apenas categorias que não continham nota final na avaliação, pois sem isso não teríamos como realizar a calibragem, nem medir a qualidade final do *ranking*. Por não ser foco da nossa pesquisa, retiramos também as avaliações de serviços que porventura foram encontradas no TopTenReviews.

Foram selecionadas 237 categorias de produtos para os testes, das mais variadas utilidades, com avaliações realizadas recentemente³³, no ano de 2016. Além de conter um conjunto com modelos de produtos bem atuais, os dados de testes abrangem categorias diversas como: utensílios de cozinha, eletrônicos, eletrodomésticos, equipamentos (de som, veicular, esportivos, de alarme), brinquedos, ferramentas pra jardim e marcenaria, *smartphones*, computadores, câmeras fotográficas digitais e até aparelhos para cuidados de bebês (vide listagem completa no APÊNDICE D).

5.2.1 Coleta dos dados

Para coletar e organizar todas essas informações, de forma estruturada, construímos um *parser*³⁴ de HTML que converte todos os valores de cada categoria em um arquivo para ser processado pela solução. Cada arquivo gerado contém informações para uma única categoria, com as *features* organizadas em critérios, o nome dos produtos avaliados e as respectivas notas. Além disso, para cada *feature* é atribuído o valor numérico de cada produto (vide Figura 5.1). O formato do arquivo (que é utilizado como entrada para os testes de uma categoria) gerado pelo *parser* pode ser visto no APÊNDICE C. A próxima subseção explica como os valores das *features* foram tratados antes de serem processados.

³³ Os testes foram executados primeiramente com dados de 2015, mas foram posteriormente atualizados para produtos com lançamento mais recentes.

³⁴ Algoritmo para interpretar automaticamente o conteúdo (em formato HTML) de um sítio na *web*, e facilitar o seu processamento.

Performance Specifications									
Rated Power (watts)	?	3000	350	2000	350	500	350	550	575
Rated Horsepower (HP)	?	2.4	0.5	2.6	0.5	0.5	0.5	1.5	0.75
Grinding Rate (pounds/per minute)	?	3.75	2.5	3	1.5	2	2	2	2
Number of Speeds	?	3	1	3	1	1	1	1	1
Reverse Function	?	✓	✓	✓	✓	✓	✓	✓	✓

This setting allows operators to dislodge any potential jams from within the grinder by reversing the rotation of the screw.

Figura 5.1 - Exemplo de valores de features contidas no critério "Performance" para uma categoria de produto. Fonte: <http://meat-grinders-review.toptenreviews.com/>.

5.2.2 Aspecto Geral dos Dados

Apesar do nome TopTenReviews, que pode ser traduzido como "Avaliação dos Dez Melhores", nem todas as avaliações são feitas com dez produtos³⁵. Algumas categorias possuem mais produtos avaliados como *Purificador de Ar* (33), *Impressora 3D* (15), *Torradeira* (16), *Lavadora de Louças* (23) e *Smartphones* (21). Por outro lado, outras categorias possuem uma avaliação com menos de dez itens, por exemplo: *Alarme de Carro* (5), *Porta-retrato digital* (7) e *Video-game portátil* (5).

A quantidade de critérios escolhidos pelo especialista para agrupar as *features* tem pouca oscilação. Em sua maioria, 165 categorias, o especialista realiza sua avaliação com quatro critérios. O número máximo de critérios utilizados para representar um produto foi 6 (seis). Estes critérios podem ser determinados de forma muito específica para a categoria como *Performance de Aquecimento e Refrigeração*, ou podem ser de âmbito mais geral como: *Design*, *Suporte Técnico* e *Facilidade de Uso*.

Já em relação a quantidade de *features* que cada categoria possui em sua avaliação tem uma maior variação. O Gráfico 5.1 informa quantas categorias (eixo das ordenadas) possuem o mesmo número de *features* (eixo das abscissas).

³⁵ Das 237 categorias avaliadas, a maioria (156) possui 10 produtos avaliados.

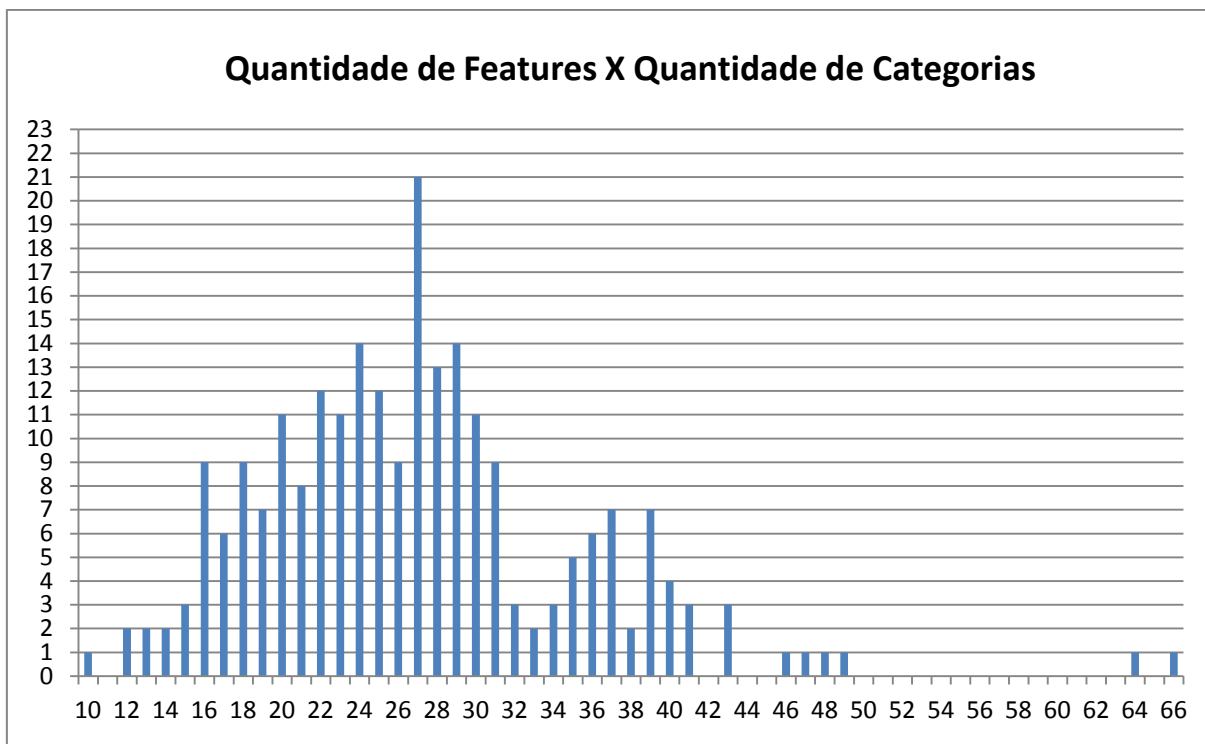


Gráfico 5.1 - Distribuição da quantidade de features por categoria.

O Gráfico 5.1 demonstra que a maioria das categorias possuem entre 16 e 31 *features* agrupadas em diferentes critérios. A quantidade das *features* é uma característica da categoria, pois quanto mais complexo é o produto, mais *features* costumam existir em sua especificação técnica, variando principalmente entre 35 e 43 *features*.

Existe uma relação implícita entre quantidade de *features* e quantidade de critérios, pois o especialista utiliza essas *features* para criar seus agrupamentos. O Gráfico 5.2 representa esta relação, podendo-se verificar que mais critérios são criados pelo especialista conforme mais *features* estão disponíveis na especificação técnica.




Gráfico 5.2 - Média da quantidade de features por quantidade de critérios.

5.2.3 Heurísticas do Tratamento das Features

Nem todos os valores de *features* podem ser automaticamente processados dentro da estrutura AHP. Isso ocorre porque é necessário interpretar como o especialista utilizou a mesma em sua avaliação, ou até mesmo se ela foi desconsiderada. Na Figura 5.1, é possível perceber um ícone de interrogação ("?") ao lado de cada nome de *feature*. Este ícone, ao ser clicado, apresenta (conforme destaque na última linha da Figura 5.1) uma explicação sobre a visão do especialista em relação à *feature* correspondente.

Em algumas situações, o especialista afirma que desconsiderou determinada *feature* em sua avaliação e apenas está exibindo por motivo de informação. Outras *features* não contêm necessariamente um valor numérico, mas apenas informam se o produto **possui ou não** um recurso³⁶. Em caso afirmativo, nós atribuímos o valor 1 (um) à aresta do AHP para o par *features*-alternativa ou zero caso contrário, o que indica que não existe a relação entre o produto e a *feature*. Em outras palavras, sempre que o valor de uma determinada *feature* de um produto é zero, a respectiva aresta é eliminada.

³⁶ Por exemplo, a última *feature* que está sendo exibida na Figura 5.1 é traduzida do inglês como "Função Reversa", relativa a **Moedores de Carne**.

Muitas *features* relativas aos critérios "Design" e "Portabilidade", por exemplo, como "tamanho" e "peso", devem ser consideradas de forma inversa. Ou seja, quanto maior o valor, menor deve ser seu peso na estrutura AHP, então nestes casos elevamos o número à potência -1 (menos um). Em outras situações, o especialista pode colocar a medida em formato de fórmula, como por exemplo, "Altura X Comprimento X Largura". Para estas situações, nosso *parser* já realiza a multiplicação e insere o resultado final no arquivo de entrada.

Em algumas *features* como "Índice Energético", no lugar de um valor, o especialista utilizou uma classificação com letras (ex.: A, B, C, D). Como não foi encontrada nenhuma fórmula exata pra conversão, substituímos cada letra por um número em ordem decrescente. Ou seja, A = 10, B = 9, C = 8 e assim por diante.

Features nominais ou categóricas (como cor ou matéria prima), foram ignoradas por não possuírem uma conversão numérica direta, ou por exigir um conhecimento muito específico e que não foi informado.

Outras unidades são mais simples de calcular, como medida de tempo (hora + minutos), mas todas as *features* devem ser convertidas para uma mesma unidade de medida, respeitando sempre que possível, criteriosamente a definição dada pelo especialista. A próxima seção detalha como foram executados os cenários de testes para as categorias selecionadas, bem como os resultados foram capturados para as métricas serem calculadas.

5.3 Execução dos Testes

O modelo de solução para *ranking* automático de produtos proposto neste trabalho levou em consideração que nem sempre é possível encontrar uma quantidade enorme de avaliação para os produtos de uma categoria. Portanto, precisamos de uma técnica que possa ao mesmo tempo treinar o modelo e avaliar seu resultado. Decidimos por realizar uma validação cruzada (*cross-validation*).

Conforme explicado em Refaeilzadeh et al. (2009), no processo de validação cruzada, parte da amostra é separada para o treinamento do modelo e o restante é utilizado para as medições. Porém, como a quantidade de produtos avaliados em cada categoria é relativamente pequena, optamos pela técnica chamada *Leave-One-Out-Cross-Validation* (Validação-Cruzada-Deixe-Um-de-Fora).

Em linhas gerais, caso o especialista tenha avaliado n produtos para uma determinada categoria, nós separamos $n - 1$ para treinar o modelo, deixando um elemento de fora da estrutura AHP inicial. Em seguida, incluímos este elemento restante na estrutura e comparamos o *ranking* final calculado pela nossa solução com o *ranking* completo do especialista. Esse processo é repetido para todos os produtos, ou seja, a cada iteração uma alternativa diferente é deixada de fora, voltando a ser incluída no final da calibragem.

Além disso, a cada iteração também calculamos ρ , $P@k$ e $nDCG$, e por fim calculamos a média de cada uma dessas métricas após a execução da validação cruzada com todos os produtos da categoria. Em outras palavras, cada categoria foi executada n vezes (onde n é a quantidade de produtos avaliados pelo especialista) e o resultado final é a média aritmética da correlação, da precisão e do ganho, respectivamente.

O fluxograma ilustrado através da Figura 5.2 apresenta o processo geral da realização dos testes e a extração das métricas durante essa execução. Este processo iterativo da avaliação consiste em 8 (oito) etapas:

- **Etapa 1:** Uma das 237 categorias de produtos (que foi extraída do sítio *TopTenReviews* e teve seu respectivo arquivo de entrada gerado pelo *parser* HTML) é selecionada.
- **Etapa 2:** De todos os produtos avaliados nesta categoria, um produto é deixado de fora na construção do modelo.
- **Etapa 3:** Os demais produtos são utilizados para geração da estrutura AHP e na calibragem.
- **Etapa 4:** Após o modelo ser treinado, o produto inicialmente excluído é inserido na estrutura para ter seu *ranking* automático calculado.
- **Etapa 5:** As três métricas apresentadas neste capítulo (ρ , $p@k$ e $nDCG$) são calculadas para o cenário corrente.
- **Etapa 6:** O produto inicialmente excluído retorna ao conjunto e uma nova alternativa (Etapa 2) é escolhida para ficar de fora do novo treinamento. Este processo é repetido até que todas as alternativas de uma categoria fiquem uma (e somente uma) vez de fora da construção do modelo, repetindo os Etapas 3, 4 e 5.
- **Etapa 7:** Após a extração das métricas para todos os produtos de uma categoria, outra categoria é selecionada (retornando a Etapa 1) para ser processada da mesma forma.

- **Etapa 8:** Com a avaliação de todas as categorias finalizadas, analisamos a variação das métricas em relação a quantidade de *features* e de critérios.

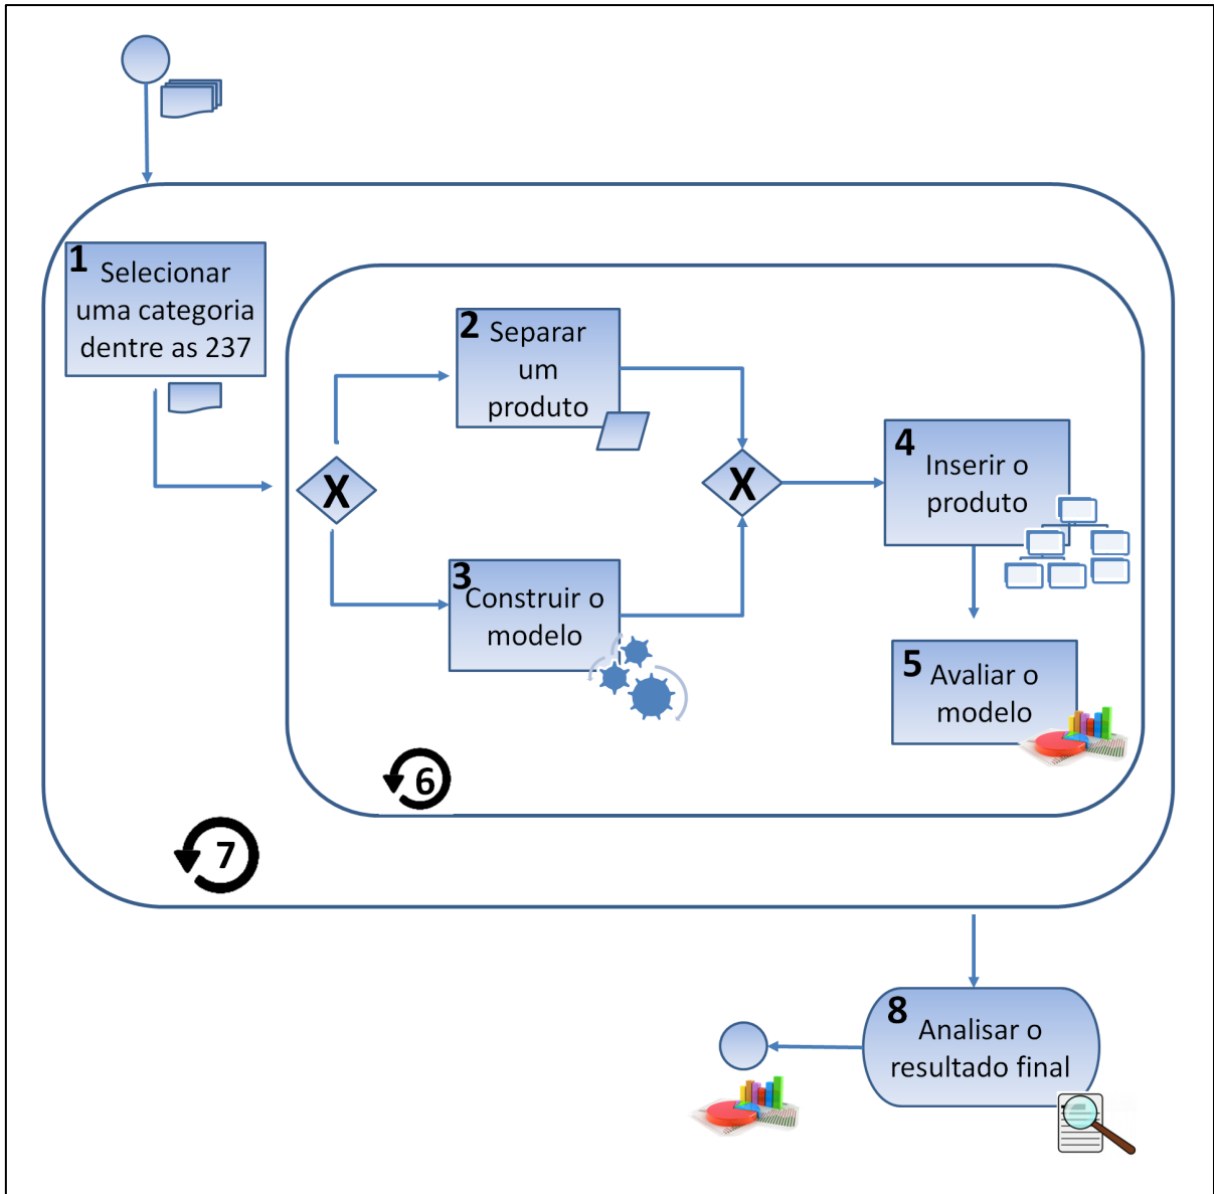


Figura 5.2 - Projeto de avaliação e execução da validação cruzada.

5.4 Considerações Finais

Neste capítulo apresentamos o projeto de avaliação da solução, e todo o processo de execução do experimento. Além das métricas, detalhamos os dados utilizados como testes nas medições, bem como a coleta dessas informações.

Esperamos que, com essas informações, outros experimentos possam ser executados alterando-se uma ou mais etapas do processo e/ou utilizando-se dados de origens diferentes com *reviews* de produtos.

6 ANÁLISE DOS RESULTADOS

O objetivo deste capítulo é analisar os resultados do experimento empírico explicado no capítulo anterior. Após a execução com 237 categorias de produtos avaliadas por especialistas, compilamos os dados e os principais aspectos quantitativos do *ranking* automático de produtos da nossa solução. Este capítulo está dividido em duas seções: a primeira apresenta a distribuição geral dos resultados e a segunda analisa o comportamento destes em relação à quantidade de alternativas, *features* e critérios em cada categoria processada pela nossa solução.

6.1 Visão Geral dos Resultados

No Gráfico 6.1 existem três diagramas de quartis (*boxplot*) que apresentam um panorama geral dos resultados do experimento. Para construir estes gráficos, consideramos o resultado médio da validação cruzada para as três métricas (Correlação de *Spearman*, *Precision@K* e *nDCG*) em todas as categorias utilizadas.

Após a compilação dos resultados, algumas categorias apresentaram valores de medições médias muito discrepantes em relação ao restante da amostra. Nesses casos, o *boxplot* destaca essas categorias como *outliers*³⁷, indicando que o nosso modelo não produz um *ranking* satisfatório com as informações de *features* e critérios utilizados pelo especialista.

Quanto à correlação, percebemos que 75% da amostra está acima de $\rho = 0,84$. Além disso, no quartil superior vemos que 25% dos resultados ultrapassaram 0,96 no coeficiente de correlação. Algumas categorias de produto atingiram uma correlação média entre os *ranks* muito próximos de 1 (um), como por exemplo: *Alarme para Automóveis* (1,0), *Máquina de*

³⁷ Valor atípico, muito distante da amostra. No Gráfico 6.1, este valor é representado pelo ponto azul. O cálculo de *outliers* é explicado mais adiante na seção 6.2.1 deste capítulo.

Lavar, Bicicleta Ergométrica, GPS de Navegação e Tablets infantis ($> 0,99$). A categoria *outlier* mínima da correlação atingiu um coeficiente de aproximadamente apenas 0,11 correspondente a categoria *Micro-ondas Compacto*. Por outro lado esse valor demonstra que nenhum resultado atingiu uma correlação média negativa, ou seja, com uma ordenação dos produtos "inversa" ao *ranking* do especialista.

Em relação à precisão calculada, o segundo *boxplot* do Gráfico 6.1 nos mostra que 75% dos resultados têm uma precisão maior do que 0,82. Assim como a correlação, a mediana também está próxima de 0,92. O *outlier* mínimo foi medido também para a categoria *Micro-ondas Compacto*. O quartil superior neste gráfico nos mostra que 25% da amostra do resultado está próxima de $p@k \approx 0,97$. Esse valor indica que 1/4 dos resultados obtiveram uma precisão quase exata entre o *ranking* da nossa solução e do especialista, levando em consideração os k primeiros (melhores) produtos ordenados.

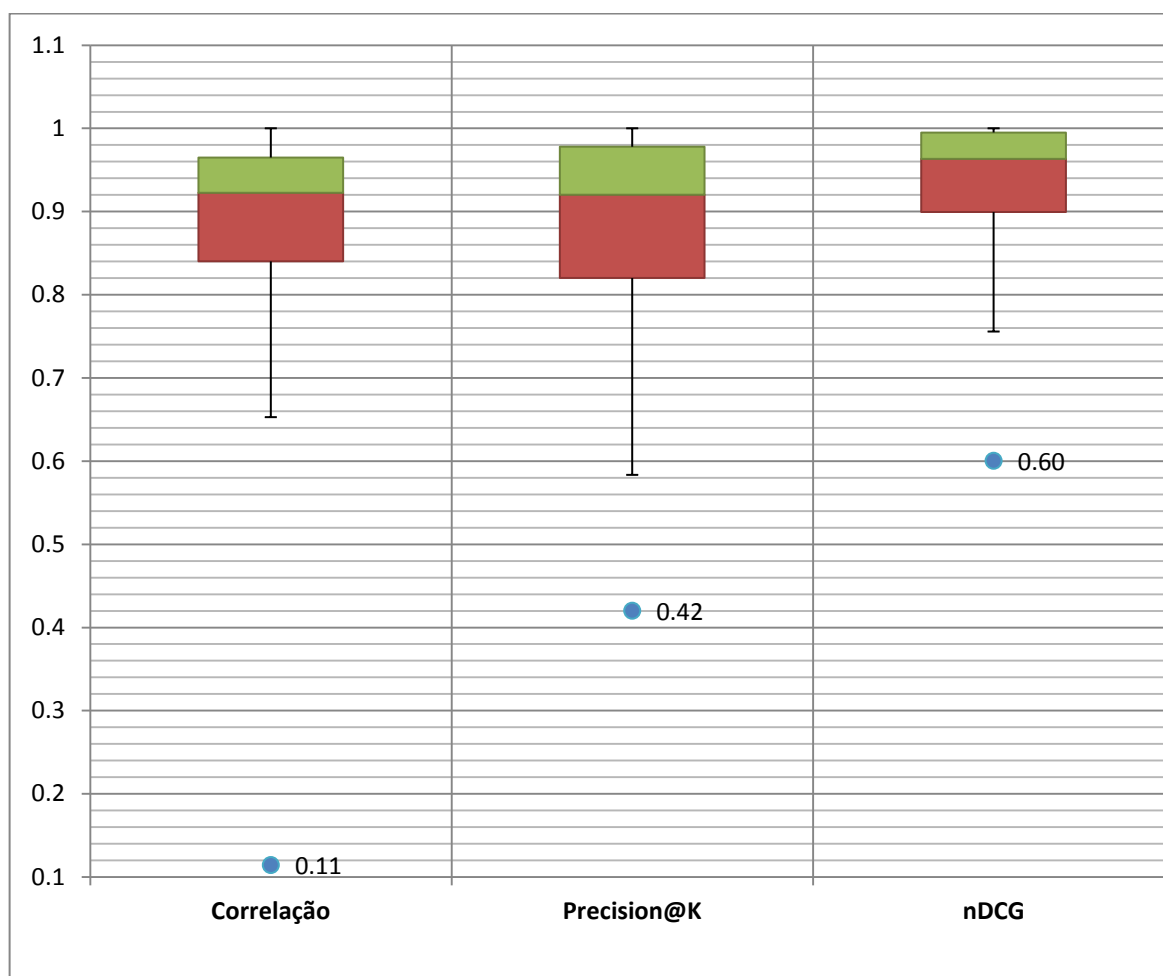


Gráfico 6.1 - Boxplot geral dos resultados.

O terceiro e último *boxplot* do Gráfico 6.1 indica que 75% dos resultados atingiram um ganho de informação (*nDCG*) acima de 0,89. Isso quer dizer que, nestes casos, o *ranking* realizado pela nossa solução consegue ter um ganho de quase 90% em relação à avaliação do especialista. É possível verificar também que, pelo quartil superior, 25% dos resultados da nossa solução produz um *ranking* com ganho de informação tão efetivo quanto dos especialistas. O *outlier* mínimo (0,6) também foi medido para a categoria *Micro-ondas Compacto*. Como o valor máximo possível para as três métricas é 1 (um), não existe nenhum *outlier* máximo em nenhuma situação. O APÊNDICE D, além de listar todas as categorias utilizadas no teste, apresenta o valor médio das três métricas para cada uma das delas.

O Gráfico 6.2 ilustra a proporção (para cada métrica) entre os resultados maiores ou iguais a 0,7 contra os resultados que não conseguiram alcançar esse valor. Podemos afirmar que grande parte das categorias avaliadas está acima deste valor, levando-nos a especular que a hipótese formulada para essa pesquisa foi validada para grande parte da nossa amostra utilizada nos testes: praticamente 92% das categorias ultrapassaram o valor de 0,7 para correlação de *Spearman*, com uma significância estatística menor do que 0,05. Nessas situações, podemos afirmar que nossa proposta é capaz de fornecer um *ranking* de produtos com correlação minimamente forte com a avaliação de especialistas.

Além disso, praticamente 95% das categorias tiveram uma precisão maior do que 0,7 para os *k* primeiros resultados no *ranking*. Isso indica que uma ordenação de produtos realizada pela nossa solução é precisa em 70% dos produtos que devem ser considerados os melhores dentre os avaliados. Finalmente, mais de 98% das categorias utilizadas nos testes alcançaram um ganho cumulativo (medido através da métrica *nDCG*) acima de 0,7.

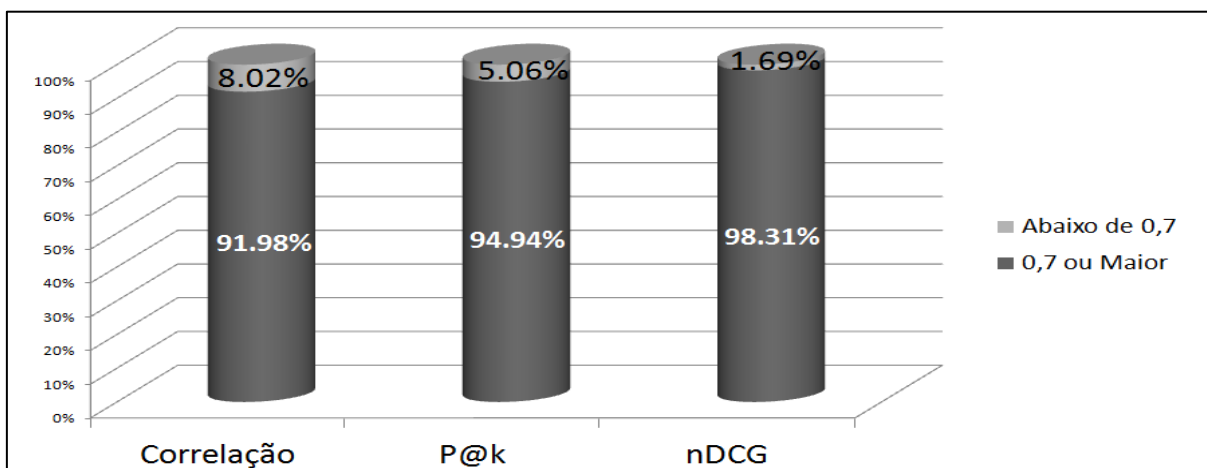


Gráfico 6.2 - Gráfico de proporção dos resultados das métricas.

6.2 Detalhe dos Resultados

Nesta seção iremos detalhar os valores das métricas, utilizadas na avaliação da nossa solução, em relação a três variáveis: quantidade de alternativas, quantidade de *features* e quantidade de critérios. Essas variáveis são características dos dados coletados nas categorias avaliadas pelos especialistas no sítio *TopTenReviews*. O objetivo é analisar se existe alguma relação entre as características dos dados de treinamento e a qualidade do *ranking* automático gerado pela nossa solução.

Além disso, como foi explicado anteriormente, utilizamos uma medida (Distância *Euclideana*) que atua como parâmetro durante o processo de calibragem dos pesos entre *features* e critérios. Então, também iremos analisar o comportamento desta medida em função das características dos cenários de teste.

6.2.1 Compilação dos Resultados

Em cada resultado apresentado, estamos considerando o valor médio (V_{med}) em relação à quantidade de elementos (alternativas, *features* e critérios). Por exemplo, caso existam n categorias com x alternativas, o resultado apresentado no eixo das ordenadas será a média aritmética, conforme fórmula abaixo:

$$V_{med} = \frac{\sum_{i=1}^n x_i M}{n}$$

onde M é uma medida (correlação, precisão, ganho ou distância *euclideana*) e x é a abscissa do gráfico.

Em cada gráfico, é traçada também uma linha de tendência dos valores. Mas para isso, os respectivos *outliers* de cada medida foram excluídos. A detecção dos *outliers* foi realizada através da técnica *Z-Score* (ALTMAN 1968), cujo cálculo é dado pela fórmula abaixo:

$$Z = \frac{X - \mu}{\sigma}$$

onde X é o valor a ser analisado, μ é a média e σ é o desvio padrão da população. Eliminamos da análise qualquer elemento cujo valor de Z fosse maior do que 3 ou menor do que -3 (três negativo)³⁸.

6.2.2 Relação com Quantidade de Alternativas

O Gráfico 6.3 apresenta o resultado das três métricas utilizadas durante a avaliação da nossa proposta, em função da quantidade de alternativas (produtos avaliados pelo especialista) que cada categoria processada possui. É possível verificar que todas as métricas tem a tendência de melhorarem o valor, cada vez que aumentamos a quantidade de alternativas no modelo. A provável justificativa para esse comportamento é que um conjunto maior de produtos avaliados pelo especialista torna o modelo mais robusto e menos suscetível a erros no momento da inclusão de um novo produto.

A linha de tendência que apresenta a variação mais sutil é a da métrica $nDCG$. O motivo provável é que se trata da métrica com melhor resultado geral e, como o valor máximo é sempre 1 (um), seu crescimento também não poderia ser muito "agudo".




Gráfico 6.3 - Valores das Métricas por Quantidade de alternativas.

³⁸ Ou seja, valores que estão fora dos 99,7% da área sob a curva da distribuição normal. No caso da correlação (*Spearman*), desconsideramos também as categorias que obtiveram significância estatística: *p-value* igual ou maior do que 0,05.

6.2.3 Relação com Quantidade de *Features*

O Gráfico 6.4 apresenta o resultado das três métricas em função da quantidade de *features*, ou seja, os elementos da especificação técnica da categoria do produto cujos valores foram considerados pelo especialista na sua revisão. Assim como na situação anterior, todas as métricas tendem a melhorar conforme mais *features* são utilizadas no modelo. Novamente nesta situação, é verificado que a métrica *nDCG* é a que menos varia.

Durante o processo de calibragem, o algoritmo genético tenta encontrar o melhor cromossomo (solução), cujo tamanho é exatamente a quantidade de *features*. Portanto, esta pode ser uma razão para observarmos um aumento do valor das métricas conforme mais elementos da especificação técnica do produto são utilizados, pois isso permite um ajuste mais fino entre os valores dos cromossomos.




Gráfico 6.4 - Valores das Métricas por Quantidade de *features*.

6.2.4 Relação com Quantidade de Critérios

Em geral, a quantidade de critérios sempre será consideravelmente menor do que a quantidade de *features*, pois o objetivo é agrupá-las para dar ao consumidor uma visão mais abstrata do produto. Desta forma, o especialista não utiliza uma quantidade muito grande de

critérios para avaliar uma categoria de produto, uma vez que as *features* fornecidas pelo fabricante são limitadas.

No Gráfico 6.5, podemos observar que a quantidade de critérios varia apenas entre 3 e 5 (inclusivos). Mesmo assim, verifica-se uma tendência de aumento no valor das métricas. O motivo pode estar relacionado também com a quantidade de *features*, pois essas duas variáveis estão intrinsecamente relacionadas.

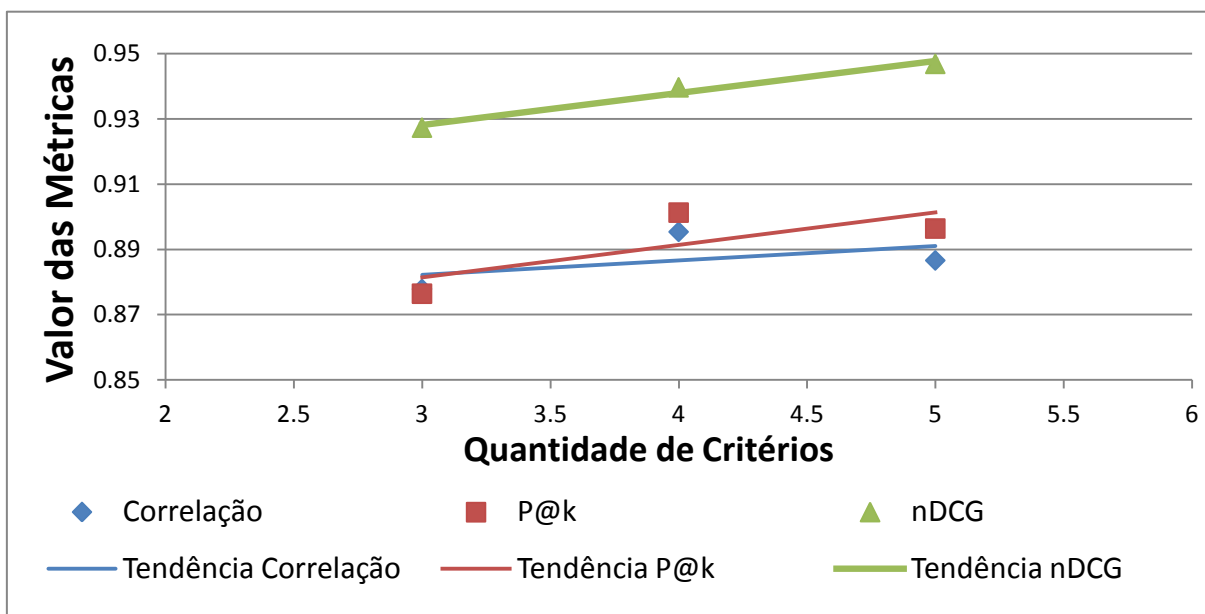


Gráfico 6.5 - Valores das Métricas por Quantidade de critérios.

6.2.5 Análise da Distância *Euclideana*

Apesar de ser uma medida utilizada somente no processo de calibragem da estrutura AHP, a Distância *Euclideana* Mínima ($DE_{mín}$) indica o quanto o *ranking* gerado pelo nosso modelo é capaz de "se aproximar" do *ranking* do especialista no final da execução do algoritmo genético. Por essa razão, consideramos importante analisar a relação desta medida com as variáveis dos dados de teste.

Nos Gráfico 6.6, 6.7 e 6.8, podemos perceber que a $DE_{mín}$ diminui à medida que as três variáveis aumentam (quantidade de critérios, alternativas e *features*, respectivamente). A menor $DE_{mín}$ possível é 0 (zero), ou seja, quando o nosso modelo encontra, não somente uma ordenação, mas também notas de produtos idênticas ao do especialista.

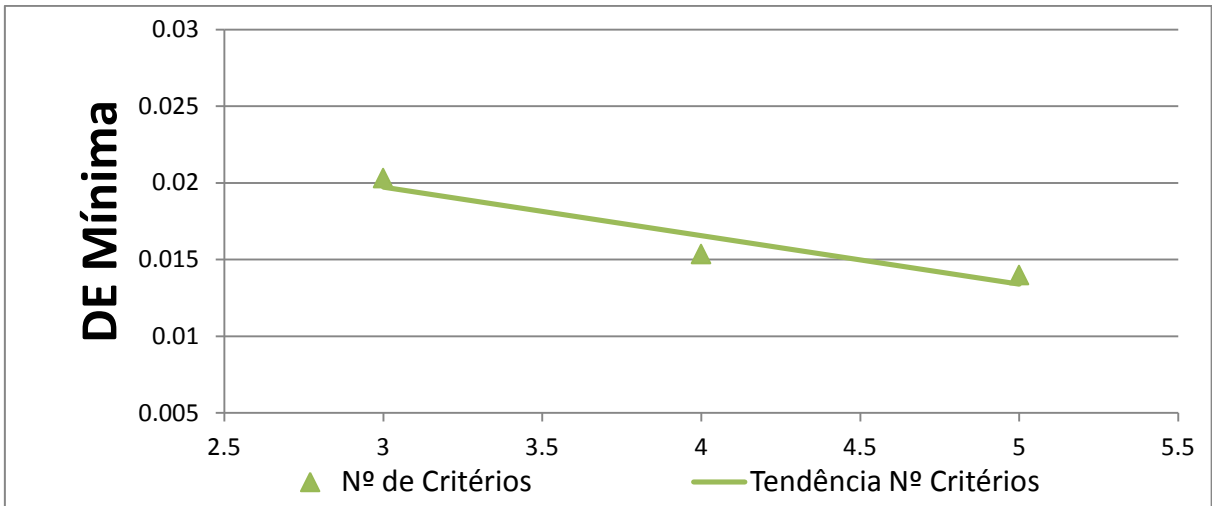


Gráfico 6.6 - Valores de DE mínima em função da quantidade de critérios na *review*.

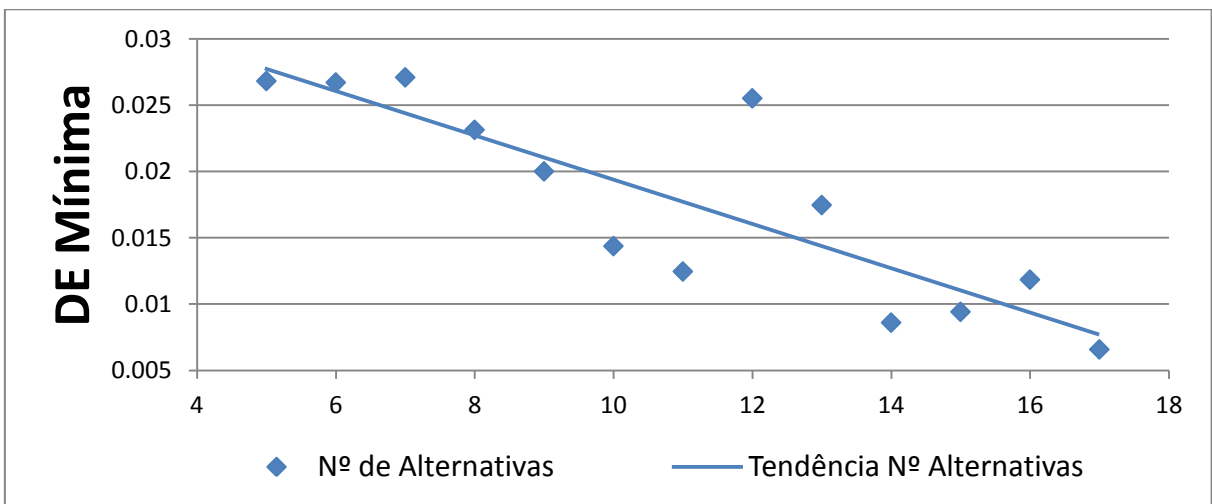


Gráfico 6.7 - Valores de DE mínima em função da quantidade de alternativas avaliadas.

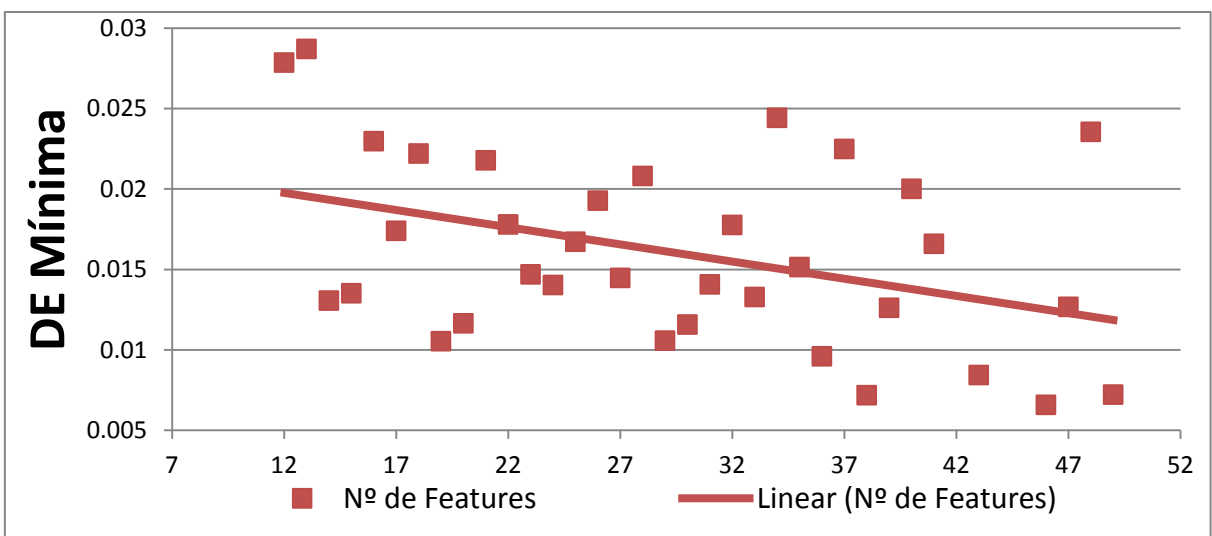


Gráfico 6.8 - Valores de DE mínima em função da quantidade de *features* da categoria.

6.3 Considerações Finais

Neste capítulo apresentamos os principais resultados coletados durante nosso experimento, desde um panorama mais geral até o detalhamento das métricas em função das características dos cenários de teste. Os pontos que podemos destacar, com a análise da solução de *ranking* automático, são:

- Quase 92% da amostra possui uma correlação minimamente forte (0,7).
- Em praticamente 95% da amostra, nosso modelo foi capaz de fornecer um *ranking* com precisão acima de 70% para os k melhores produtos.
- A métrica que apresentou o melhor resultado foi do Ganho de Informação ($nDCG$), ultrapassando 98% da amostra com ganho maior do que 70% em relação ao *ranking* do especialista.
- Pôde-se observar que, pelos dados utilizados, existe uma relação de melhoria do *ranking* com o aumento da quantidade de informação utilizada na estrutura AHP.

No próximo capítulo concluímos a nossa pesquisa com as implicações diretas do resultado analisado e da solução como um todo. Além disso, apresentamos nossas contribuições teóricas e práticas e sugestões para pesquisas futuras.

7 CONCLUSÃO

O crescimento do comércio *online* ao longo dos anos destaca a importância da evolução contínua dos Sistemas de Informação (SI) que o apoiam. O número de lojas, produtos e consumidores *online* aumenta constantemente, tendo como consequência um volume de informações que pode sobrecarregar o usuário que necessita encontrar um produto.

As ferramentas de busca³⁹ de produtos em sistemas de comércio *online* precisam focar cada vez mais em soluções que permitam ao usuário explorar a informação fornecida, sem limitá-lo ou conduzi-lo à desistência da compra durante a utilização do sistema. Além disso, estas ferramentas precisam minimizar o esforço do usuário sem a possibilidade de realizar uma compra com menos confiança na sua escolha. Por esse motivo, a usabilidade e o enriquecimento da informação são focos de pesquisas na área de SI.

Acreditamos que um sistema mais simples de comparação de produtos deve ajudar o usuário no entendimento da função de cada *feature*. Esse entendimento evita a necessidade da compreensão detalhada de cada característica técnica durante a comparação das alternativas, minimizando a carga cognitiva para tentar entender os diferentes produtos. O sistema também precisa ser flexível e mais tolerante às escolhas do usuário, evitando que um resultado seja totalmente descartado precipitadamente.

O uso de tecnologias da Web 2.0 (Web Social) faz com que os consumidores tenham acesso a um conteúdo que vai além da informação do fabricante, como as avaliações de produtos realizadas por especialistas e por outros usuários. Tal conteúdo permite a comparação na web das diversas opções disponíveis, possibilitando uma compra mais bem informada.

³⁹ Consideramos também ferramentas de meta-busca ou agregadores de lojas e produtos como Busca Pé (www.buscaped.com.br).

Por outro lado, nem todas as marcas e modelos possuem uma avaliação completa para que o consumidor possa decidir, dentre as opções, quais que atendem melhor a suas necessidades. Além disso, pode ser uma tarefa árdua comparar todas as *features* dos produtos manualmente. A busca facetada tradicional, que utiliza essas *features* como parâmetro de filtragem, exige um conhecimento muitas vezes técnico, que pode dificultar o processo de compra de um consumidor leigo.

O Processo Decisório de Compra define que o consumidor deve primeiramente identificar suas necessidades, para então buscar as informações suficientes para a comparação das alternativas de forma mais adequada. Faz-se necessário, então, uma ferramenta que automatize essa comparação, reunindo diversas fontes de informação, como: a especificação técnica do produto, os critérios relevantes para um usuário e avaliações de produtos.

Propomos então um modelo de *ranking* automático de produtos, baseado em critérios de necessidade do usuário e valores de *features* fornecidas pelo fabricante. Nossa proposta faz uso de *reviews* disponibilizadas por especialistas na web, utilizando um método de análise multicritério para o cálculo de priorização. O objetivo é substituir a avaliação de um especialista, fornecendo uma classificação (notas) para produtos ainda não avaliados.

Para atingir o objetivo, utilizamos um método de análise multicritério reconhecido (AHP) que tem por definição decompor um problema complexo em problemas menores, permitindo computar valores numéricos sem a necessidade da intervenção humana. O algoritmo da solução é capaz de calcular a priorização das alternativas e ponderá-las automaticamente com foco nas necessidades do usuário. Mas o AHP não teria todas as informações utilizando unicamente as *reviews* dos especialistas, portanto o resultado satisfatório da solução só foi possível porque adotamos uma estratégia de aprendizagem de máquina que permitiu suprir a ausência desses valores.

Diferente de outras soluções existentes na literatura e nos sistemas de comércio *online* atuais, nós não desconsideramos os valores das especificações técnicas do produto. Pelo contrário, agrupamos as mesmas *features* em diferentes perspectivas para apresentá-las ao usuário usando uma linguagem mais próxima do seu cotidiano. Com isso, um dos benefícios da proposta apresentada através desta pesquisa vai além de substituir ou traduzir o significado dos filtros em uma busca facetada. Nosso estudo demonstrou a possibilidade de relacionar *features* com critérios mais simples para um consumidor leigo, ou seja, que não está

completamente familiarizado com as especificações técnicas da categoria de produto que deseja comprar. Mesmo assim, a nossa solução não ignora o que é crucial para o cliente: a qualidade do produto e de todas as suas características técnicas.

Conduzimos um experimento, com 237 categorias diferentes de produtos, e avaliamos a performance da nossa solução com métricas utilizadas em sistemas de Recuperação da Informação. Em relação à hipótese, ela foi verdadeira para praticamente 92% da amostra. Medições complementares foram ainda melhores, de 95% e 98%, respectivamente. O resultado demonstrou que a abordagem que utilizamos abre um caminho promissor, que pode ser mais explorado nos sistemas de comércio *online*.

Uma parte dos resultados da nossa pesquisa (com três categorias) foi apresentada no artigo "*Online Product Search with Focus on Customers' Needs*" na AMERICAS CONFERENCE ON INFORMATION SYSTEMS (AMCIS), 2016. Mesmo com uma quantidade menor de dados para teste, a aceitação dos revisores demonstrou a relevância pelo tema e a concordância com a metodologia científica escolhida para avaliação da proposta.

Neste capítulo apresentamos as contribuições teóricas e práticas do nosso trabalho, bem como as limitações e os trabalhos futuros que podem decorrer da nossa pesquisa.

7.1 Contribuições Teóricas

Nesta pesquisa demonstramos a viabilidade de realizar automaticamente o *ranking* de produtos, através de um mapeamento entre suas *features* e as necessidades dos clientes, utilizando avaliações (*reviews*) de especialistas disponíveis na web como dados de treinamento.

A principal contribuição teórica da nossa pesquisa consiste em fornecer um modelo de representação da especificação técnica de produtos através de critérios agrupadores, possibilitando um cálculo de priorização de alternativas em função dos valores de suas *features*.

Os trabalhos relacionados encontrados na literatura não contemplam uma avaliação sobre a qualidade do *ranking* calculado, portanto nossa pesquisa pode ser utilizada como uma fonte comparativa para experimentos futuros, com a configuração de cenários ou dados diferentes. Isso é possível pois a avaliação da nossa proposta levou em consideração três métricas amplamente utilizadas sistemas de recuperação da informação.

Além disso, a combinação do uso de algoritmo genético demonstrou que é viável realizar uma calibragem automática dos pesos que preenchem uma Matriz de Comparação do AHP. Para isso, foi necessário fornecer apenas um parâmetro de comparação para ser utilizado na Função de Adaptação do AG, que no nosso caso foi o *ranking* fornecido por um especialista. A técnica de aprendizagem de máquina como foi utilizada pode permitir a generalização do modelo para um conjunto de categorias de produtos maior do que o que foi utilizado como testes neste trabalho.

7.2 Contribuições Práticas

A nossa proposta pode beneficiar a evolução de sistemas de busca de produtos *online* de diversas formas. O sistema poderia identificar que o usuário do sistema está tendo dificuldades em encontrar um resultado adequado através de uma busca facetada tradicional (ou pelo seu perfil detectar falta de conhecimento técnico relativo a uma determinada categoria de produtos) e oferecer a mudança dos parâmetros de filtro para opções menos técnicas e próximas do cotidiano do consumidor.

Além de apresentar uma nova opção de filtragem, o modelo proposto poderia permitir a organização das *features* em diferentes perspectivas. Assim, os critérios poderiam representar o produto através de diferentes facetadas, além daquela baseada em *features* tradicionalmente. Por exemplo, em determinada circunstância o usuário pode querer encontrar produtos de acordo com sua utilidade, assim cada critério de filtro seria uma possível atividade a ser desempenhada.

Sistemas de recomendação poderiam utilizar nossa proposta para sugerir produtos baseados em informações personalizadas, como o histórico de navegação do usuário. Assim, o *ranking* poderia levar em consideração um peso maior para os critérios de necessidade que são mais relevantes para o possível comprador.

Outra aplicação prática é permitir que produtos recém-lançados, que ainda não possuem avaliação de especialistas, possam ser facilmente comparados com outros que já possuem. Para isso, bastaria calcular a prioridade deste novo produto levando em consideração as mesmas *features* e critérios.

Como contribuição secundária, todo o código fonte implementado para avaliação da proposta, além dos dados de testes, foram disponibilizados⁴⁰ e podem ser reaproveitados em outras pesquisas, com novas categorias ou até mesmo a substituição da arquitetura, como: o método de análise multicritério e o processo de calibragem dos pesos.

7.3 Limitações

Apesar de um resultado inicial otimista, nossa pesquisa ainda possui algumas limitações. A utilização de algumas *features* foi ignorada, pois exigia um conhecimento muito específico que não estava exposto na avaliação do especialista. Por exemplo, não foi possível valorar a *feature* “*Tipo de Tela*” para saber o quanto a opção “AMOLED” é melhor ou pior do que “IPS LCD”.

Além disso, muitas categorias de caráter tecnológico podem sofrer defasagem rapidamente, ou seja, as notas atribuídas a produtos em uma avaliação antiga provavelmente não terá tanta relevância quanto uma avaliação recente e, portanto, nem sempre será possível utilizar dados de períodos muito diferentes para construir o mesmo modelo.

A avaliação do especialista pode não contemplar todas as *features* que um produto possui. Então, para evitar um viés indesejado, seria necessário realizar os mesmos testes com outras fontes de dados e avaliações de outros especialistas. Por outro lado, a solução permite a transparência e confiabilidade, ao disponibilizar ao usuário as informações sobre os mapeamentos, a calibragem e o cálculo de *ranking*.

7.4 Trabalhos Futuros

Como sugestão de trabalhos futuros, é possível avançar nesta pesquisa considerando as avaliações de produtos realizadas por usuários na web. É possível minerar os critérios e *features* pelo ponto de vista de outros consumidores (CHAABNA et al. 2014), baseando-se em trabalhos como *eWOM* (WEATHERS et al. 2015). Essas opiniões sobre os produtos podem servir de carga para construir automaticamente uma estrutura AHP sem o viés das informações disponibilizadas somente por especialistas.

Assim como os trabalhos relacionados nesta pesquisa, diversos estudos estão avançando em utilizar a perspectiva de outros usuários consumidores como informação para

⁴⁰ Código-fonte disponível em <https://github.com/Tivor/rank2buy>

qualificar um produto. Sem dúvida é muito importante não desconsiderar esse fator, sendo a mineração de opiniões uma fonte altamente relevante e confiável de informações para quem está buscando e comparando produtos.

Além disso, seria importante obter avaliações dos mesmos produtos, mas com diferentes organizações de *features*. Isso poderia demonstrar o quão flexível é o modelo para diferentes situações. Não só outros métodos de análise multicritério poderiam ser utilizados, mas também a combinação de diferentes métodos. Como técnica de aprendizagem de máquina, outras soluções poderiam ser adotadas (como a utilização de Cadeias de *Markov* ou Rede Neural) no lugar de algoritmo genético.

Trabalhos futuros poderiam expandir o universo com categorias de produtos mais variadas, realizando testes também com serviços oferecidos na web, como por exemplo: reserva de hotel ou restaurante, sugestão de mídia digital (filmes e séries), conteúdo educacional e objetos de aprendizagem (*e-learning*), dentre outros.

Poderia ser feito um estudo de aceitação dos usuários quanto à abordagem apresentada nesta pesquisa, considerando diversas categorias de produtos e serviços. Podem-se realizar experimentos com usuários em um ambiente de busca de produtos real para analisar o comportamento em relação a nossa proposta. Em outras palavras, o usuário poderia dar *feedback* das sugestões fornecidas pelo nosso *ranking*.

Dados do perfil do usuário também poderiam ser utilizados para configurar automaticamente o estilo do filtro de busca (baseada em necessidades ou em *features*). Além disso, o rastreamento de compras passadas poderia ser utilizado como apoio ao refinamento do mapeamento e da calibragem.

Para uma maior conveniência, os critérios de necessidade que foram utilizados para construir o modelo, poderiam ser interpretados através da linguagem natural do usuário. Assim, no momento de filtrar os produtos, ao invés de direcionar o consumidor a escolher dentro de um conjunto de filtros pré-determinados, o sistema poderia traduzir as necessidades informadas.

Com foco maior na usabilidade e experiência do usuário, um estudo mais abrangente poderia ser realizado a fim de analisar o impacto real da solução em consumidores que estão

procurando e comparando produtos em um ambiente controlado de compra online, com uma interface de busca facetada orientada a necessidades.

7.5 Projetos de Inovação

Após um estudo do potencial econômico desta solução, contatos com empresas/*startups* poderiam ser feitos para a construção de um *software* diferenciado de busca e comparação de produtos. Dentre os benefícios já apresentados, as empresas também poderiam recomendar serviços relacionados com a mesma necessidade identificada pelo cliente no momento de uma compra de um produto.

Além disso, dados recentes apontam uma migração vertiginosa da compra *online* de produtos através de dispositivos móveis. Cada vez mais, celulares e *tablets* são utilizados para comprar produtos *online*. Com isso, um método mais ágil e prático para comparar produtos é uma alternativa quando os mesmos possuem inúmeras *features* e a busca facetada tradicional pode ser inconveniente. O desenvolvimento de um aplicativo móvel (*app*) poderia ser elaborado, fazendo uso da nossa solução. Ao mesmo tempo, informações podem ser coletadas quanto à experiência do usuário na utilização do *aplicativo*.

A solução também poderia ser inserida dentro de um recurso de conversação automática com o consumidor no momento da compra (*ChatBot*), auxiliando a interpretar a necessidade e sugerir produtos mais adequados. Ou seja, o robô seria capaz de realizar uma nova filtragem de opções de acordo com a necessidade identificada durante a conversação.

7.6 Considerações Finais

Durante as etapas da nossa pesquisa, buscamos acima de tudo, identificar a relevância do tema, na contextualização e motivação do problema. Apesar do foco em Sistemas de Informação e Representação do Conhecimento e Raciocínio, os estudos foram inspirados no Processo Decisório de Compra que pertence ao campo de Administração e *Marketing*.

Levamos em consideração a importância deste processo e como ele pode ser apoiado pela nossa solução para auxiliar o consumidor, mesmo que este seja leigo ou se sinta limitado no momento de buscar um produto que melhor atenda as suas necessidades.

Acreditamos que, apesar de embrionária, nossa solução possa evoluir e se adequar ao máximo a esse cenário tão diversificado que é o comércio *online*, onde as categorias e as especificações técnicas dos produtos são tão variadas e voláteis. Portanto, esperamos que nossa contribuição possa motivar outras pesquisas na área ou até mesmo ser útil em situações mais generalizadas.

Referências

- ALIAS, M. A., HASHIM, S. Z. M. e SAMSUDIN, S. (2008). "Multi-criteria decision making and its applications: a literature review". *Jurnal Teknologi Maklumat*, 20(2), 129-152.
- ALTMAN, E. I. (1968). "Financial ratios, discriminant analysis and the prediction of corporate bankruptcy". *The journal of finance*, 23(4), 589-609.
- ARULDOSS, M., LAKSHMI, T. M. e VENKATESAN, V. P. (2013). "A survey on multi criteria decision making methods and its applications". *American Journal of Information Systems*, 1(1), 31-43.
- ASHMAN, R., SOLOMON, M.R. e WOLNY, J. (2015). "An old model for a new age: Consumer decision making in participatory digital culture". *Journal of Customer Behaviour*, 14(2), pp.127-146.
- BELLOGIN, A., CASTELLS, P. e CANTADOR, I. (2011). "Precision-oriented evaluation of recommender systems: an algorithmic comparison". In *Proceedings of the fifth ACM conference on Recommender systems* (pp. 333-336). ACM.
- BELLOGÍN, A., WANG, J. e CASTELLS, P. (2011). "Text retrieval methods for item ranking in collaborative filtering". In *European Conference on Information Retrieval* (pp. 301-306). Springer Berlin Heidelberg.
- BROOKE, J. (1996). "SUS - A quick and dirty usability scale". *Usability evaluation in industry*, 189(194), 4-7.
- CARTER, S., CHEN, F., MURALIDHARAN, A. S. e PICKENS, J. (2011). "Dig: a task-based approach to product search". In *Proceedings of the 16th international conference on Intelligent user interfaces* (pp. 303-306). ACM.
- CASTILHO, D., DE MELO, P.O.V., QUERCIA, D. e BENEVENUTO, F., (2014). "Working with Friends: Unveiling Working Affinity Features from Facebook Data". In *ICWSM*.
- CHAABNA, S., WANG, H. e LUTF, M. (2014). "Designing Ranking System for Chinese Product Search Engine Based on Customer Reviews". In *Proceedings of the Wuhan International Conference on E-Business* (p. 26).
- CHIU, C. M., CHANG, C. C., CHENG, H. L. e FANG, Y. H. (2009). "Determinants of customer repurchase intention in online shopping". *Online information review*, 33(4), 761-784.
- CLARKE, C. L., KOLLA, M., CORMACK, G. V., VECHTOMOVA, O., ASHKAN, A., BÜTTCHER, S. e MACKINNON, I. (2008). "Novelty and diversity in information retrieval evaluation". In *Proceedings of the 31st ACM SIGIR conference on Research and development in information retrieval* (pp. 659-666). ACM.
- DARLEY, W. K., BLANKSON, C. e LUETHGE, D. J. (2010). "Toward an integrated framework for online consumer behavior and decision making process: A review". *Psychology & marketing*, 27(2), 94-116.
- DEVI, S. e SAINI, P. (2015). "Online Shopping: Interplay of Influencing Factors, Risks & Benefits". In *Social Science Research Network, Risks & Benefits*.

- ENGEL, J. F., KOLLAT, D. T. e BLACKWELL, R. D. (1968). "Consumer Behavior". New York, Holt, Rinehart & Winston.
- EMARKETER. (2014). Retail Sales Worldwide Will Top \$22 Trillion This Year. Disponível em: <<http://www.emarketer.com/Article/Retail-Sales-Worldwide-Will-Top-22-Trillion-This-Year/1011765>>. Setembro, 2016.
- FELIX, D., NIEDERBERGER, C., STEIGER, P., e STOLZE, M. (2002). Feature-oriented vs. needs-oriented product access for non-expert online shoppers. In *Towards the E-Society* (pp. 399-406). Springer US.
- FENG, Q., HWANG, K. e DAI, Y. (2009). "Rainbow product ranking for upgrading e-commerce". *IEEE Internet Computing*, 13(5), 72-80.
- FRIEDRICH, T., (2015). "Analyzing the Factors that Influence Consumers' Adoption of Social Commerce—A Literature Review". In *Proceedings of the 21st Americas Conference on Information Systems*. AMCIS.
- FRUTOS, S.M., GIONES, F. e MIRALLES, F. (2014). "Social Media engagement as an e-commerce driver, a consumer behavior perspective". In *Information Systems and Technologies (CISTI)*. 9th Iberian Conference on (pp. 1-6). IEEE.
- HÄUBL, G. e TRIFTS, V. (2000). "Consumer decision making in online shopping environments: The effects of interactive decision aids". *Marketing science*, 19(1), 4-21.
- HOTELLING, H., e PABST, M. R. (1936). "Rank correlation and tests of significance involving no assumption of normality". *The Annals of Mathematical Statistics*, 7(1), 29-43.
- HU, S., DOU, Z. C., WANG, X. J. e WEN, J. R. (2015). "Search Result Diversification Based on Query Facets". *Journal of Computer Science and Technology*, 30(4), 888-901.
- HUANG, L.S. (2015). "Trust in product review blogs: the influence of self-disclosure and popularity". *Behaviour & Information Technology*, 34(1), pp.33-44.
- KHAN, S. A., KHODKE, P. A. e BHAGAT, A. P. (2015). "Neuro Fuzzy based user queries categorization". In *Innovations in Information, Embedded and Communication Systems (ICIIECS)*, 2015 International Conference on (pp. 1-7). IEEE.
- KIM, H. J., ZHU, Y., KIM, W. e SUN, T. (2014). "Dynamic faceted navigation in decision making using Semantic Web technology". *Decision Support Systems*, 61, 59-68.
- KONG, S. e QIN, L. (2015). "Why do People Seek Shopping Recommendations in Social Commerce Sites?". In *Proceedings of the 21st Americas Conference on Information Systems*. AMCIS.
- LEE, J., HWANG, S.W., NIE, Z. e WEN, J.R. (2010). "Navigation system for product search". In *Data Engineering (ICDE)*, IEEE 26th International Conference on (pp. 1113-1116). IEEE.
- LI, H., BHOWMICK, S. S., e SUN, A. (2011). "AffRank: Affinity-driven ranking of products in online social rating networks". *Journal of the American Society for Information Science and Technology*, 62(7), 1345-1359.
- LIANG, S., REN, Z. e DE RIJKE, M. (2014). "Personalized search result diversification via structured learning". In *Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining* (pp. 751-760). ACM.
- LUO, J., Ba, S. e ZHANG, H. (2012). "The effectiveness of online shopping characteristics and well-designed websites on satisfaction". *Mis Quarterly*, 36(4), 1131-1144.

- MAKEEV, S., PLAKHOV, A. e SERDYUKOV, P. (2014). "Personalizing Aggregated Search". In *Advances in Information Retrieval* (pp. 197-209). Springer International Publishing.
- MARCHIONINI, G. (2006). "Exploratory search: from finding to understanding". *Communications of the ACM*, 49(4), 41-46.
- MARTÍNEZ-LÓPEZ, F.J., ESTEBAN-MILLAT, I., CABAL, C.C. e GENGLER, C. (2015). "Psychological factors explaining consumer adoption of an e-vendor's recommender". In *Industrial Management & Data Systems*, 115(2), pp.284-310.
- MITCHELL, M. (1998). "An introduction to genetic algorithms". MIT press.
- MOTTIN, D., LISSANDRINI, M., VELEGRAKIS, Y. e PALPANAS, T. (2014). "Exemplar queries: Give me an example of what you need". *Proceedings of the VLDB Endowment*, 7(5), 365-376.
- NAJMI, E., HASHMI, K., MALIK, Z., REZGUI, A. e KHAN, H. U. (2015). "CAPRA: a comprehensive approach to product ranking using customer reviews". *Computing*, 97(8), 843-867.
- OUNIS, I., MACDONALD, C. e SANTOS, R. L. (2015). "Search result diversification". *Foundations and Trends in Information Retrieval*, 9(1), 1-90.
- PARK, C. H. e KIM, Y. G. (2003). "Identifying key factors affecting consumer purchase behavior in an online shopping context". *International Journal of Retail & Distribution Management*, 31(1), 16-29.
- REFAEILZADEH, P., TANG, L. e LIU, H. (2009). "Cross-validation". In *Encyclopedia of database systems* (pp. 532-538). Springer US.
- REN, P., CHEN, Z., MA, J., WANG, S., ZHANG, Z. e REN, Z. (2015). "Mining and ranking users' intents behind queries". *Information Retrieval Journal*, 18(6), 504-529.
- SAATY, T. L. (1977). "A scaling method for priorities in hierarchical structures". *Journal of mathematical psychology*, 15(3), 234-281.
- SAATY, T. L. (1985). "Decision making for leaders". *IEEE Transactions on Systems, Man, and Cybernetics*, (3), 450-452.
- SAATY, T. L. (2008). "Decision making with the analytic hierarchy process". *International journal of services sciences*, 1(1), 83-98.
- SINGH, A. e MALIK, S. K. (2014). "Major MCDM Techniques and their application-A Review". *IOSR Journal of Engineering*, 4(05), 15-25.
- SINGH, G., PARIKH, N. e SUNDARESAN, N. (2012). "Rewriting null e-commerce queries to recommend products". In *Proceedings of the 21st international conference companion on World Wide Web* (pp. 73-82). ACM.
- SINGH, M. (2015). "Information Exploration in E-Commerce Databases". In *Big Data Analytics* (pp. 41-56). Springer International Publishing.
- SHAPIRO, J. (2001). *Genetic algorithms in machine learning*. In *Machine Learning and Its Applications* (pp. 146-168). Springer Berlin Heidelberg.
- STOLZ, A. e HEPP, M. (2015). "Adaptive Faceted Search for Product Comparison on the Web of Data". In *Engineering the Web in the Big Data Era* (pp. 420-429). Springer International Publishing.

- TIAN, P., LIU, Y., LIU, M. e ZHU, S. (2009). "Research of product ranking technology based on opinion mining". In *Intelligent Computation Technology and Automation. ICICTA'09. Second International Conference on* (Vol. 4, pp. 239-243). IEEE.
- TRIANANTAPHYLLOU, E. (2013). "Multi-criteria decision making methods: a comparative study" (Vol. 44). Springer Science & Business Media.
- USMANI, T. A., PANT, D., e BHATT, A. K. (2012). "A comparative study of google and bing search engines in context of precision and relative recall parameter". *International Journal on Computer Science and Engineering*, 4(1), 21.
- VANDIC, D., NEDERSTIGT, L. J. e AANEN, S. S. (2014). "Ontology population from web product information". In *Advances in Conceptual Modeling* (pp. 263-272). Springer International Publishing.
- VELASQUEZ, M. e HESTER, P. T. (2013). "An analysis of multi-criteria decision making methods". *International Journal of Operations Research*, 10(2), 56-66.
- VOORHEES, E. M. e HARMAN, D. K. (2005). "TREC: Experiment and evaluation in information retrieval". Cambridge: MIT press. Vol 1.
- WEATHERS, D., SWAIN, S.D. e GROVER, V. (2015). "Can online product reviews be more helpful? Examining characteristics of information content by product type". In *Decision Support Systems*, 79, pp.12-23.
- XU, W., HOU, Y., HUNG, Y. S., e ZOU, Y. (2013). "A comparative analysis of Spearman's rho and Kendall's tau in normal and contaminated normal models". *Signal Processing*, 93(1), 261-276.
- WANG Y., WANG L., LI Y., HE D., CHEN W. e LIU T. (2013). "A Theoretical Analysis of Normalized Discounted Cumulative Gain (NDCG) Ranking Measures". In *Proceedings of the 26th Annual Conference on Learning Theory*.
- YILMAZ, E., ASLAM, J. A. e ROBERTSON, S. (2008). "A new rank correlation coefficient for information retrieval". In *Proceedings of the 31st ACM SIGIR conference on Research and development in information retrieval* (pp. 587-594). ACM.
- YU, J., ZHA, Z. J., WANG, M. e CHUA, T. S. (2011). "Aspect ranking: identifying important product aspects from online consumer reviews". In *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies-Volume 1* (pp. 1496-1505).
- ZAVADSKAS, E. K., TURSKIS, Z. e KILDIENĖ, S. (2014). "State of art surveys of overviews on MCDM/MADM methods". *Technological and economic development of economy*, 20(1), 165-179.
- ZHA, Z. J., YU, J., TANG, J., WANG, M., e CHUA, T. S. (2014). "Product aspect ranking and its applications". *IEEE Transactions on knowledge and data engineering*, 26(5) 1211.
- ZHANG, K., NARAYANAN, R., e CHOUDHARY, A. N. (2010). *Voice of the Customers: Mining Online Customer Reviews for Product Feature-based Ranking*. WOSN, 10, 11-11.
- ZHOU, B. e YAO, Y. (2010). "Evaluating information retrieval system performance based on user preference". *Journal of Intelligent Information Systems*, 34(3), pp.227-248.
- ZIN, T.T., TIN, P., TORIU, T. e HAMA, H. (2014). "A Human Behavior Analyzer Framework for consumer product search engines". In *Consumer Electronics (GCCE), IEEE 3rd Global Conference on* (pp. 138-139). IEEE.

APÊNDICE A


TIPO DE VALOR	FORMA DE UTILIZAÇÃO DADA PELO ESPECIALISTA	EXEMPLO
Valor direto	O próprio valor é utilizado. Quanto maior, melhor.	Resolução da tela.
Valor inverso (*)	O valor é elevado ao expoente -1. Quanto maior, pior.	Peso do aparelho.
Porcentagem	Índice de qualidade de determinada feature. É utilizado de 0 a 100.	Filtragem de impurezas.
Multiplicação	Quando determinada feature contém mais de uma medida.	Largura x Altura x Profundidade.
Existência	Possui recurso? Valor 0 ou 1.	Tem (ou não) garantia.
Tempo	No formato Hora + Minutos é convertido apenas em minutos	Tempo de duração de bateria.
Intervalo	Capacidade de extensão/variação de determinada feature. Quando os valores foram levados em consideração em conjunto. Valor máximo menos o valor mínimo fornecido	Altura permitida.
Extremos	Valor máximo e mínimo da feature. Quando os valores foram levados em consideração. Conversão em duas features separadas, sendo que o valor mínimo é invertido (elevado a -1).	Resposta de frequência (em Hertz).

Escala ordinal	<p>Nota de qualidade de determinada feature.</p> <p>Normalmente utilizada por órgãos que certificam o produto.</p> <p>Valores A, B, C, D, E, etc. são convertidos em números na ordem (1, 2, 3, 4, 5, etc) e posteriormente invertidos (elevados a -1) .</p>	Eficiência energética.
Nominal	Cada valor é convertido em um número conforme orientação do especialista.	Tipo de ajuste: manual (=1), automático (=2)

(*) Qualquer feature pode ser de um tipo de valor "inverso", desde que explicitado pelo especialista. Nestes caso, após a conversão adequada para o tipo de valor, elevamos o resultado final ao expoente -1.

APÊNDICE B

Suponha que uma estrutura AHP contém 3 alternativas que devem ser avaliadas. O tomador de decisões deve primeiramente comparar as mesmas utilizando a escala Saaty, conforme ilustração abaixo:



Ou seja, para cada par de alternativas, é atribuído um valor que representa o julgamento de quanto um é melhor do que outro, subjetivamente. A matriz então será preenchida conforme abaixo:

$$\begin{bmatrix} 1 & 8 & 6 \\ 1/8 & 1 & 1/3 \\ 1/6 & 3 & 1 \end{bmatrix}$$

Porém, por se tratar de uma avaliação subjetiva, essa matriz pode conter inconsistências como, por exemplo:

$$ALTERNATIVA 1 > ALTERNATIVA 2$$

$$ALTERNATIVA 1 < ALTERNATIVA 3$$

$$ALTERNATIVA 2 > ALTERNATIVA 3$$

Neste caso, uma taxa de inconsistência da matriz é calculada para saber se esse julgamento pode ser considerado aceitável para o cálculo de priorização. A técnica para este cálculo utiliza autovetor (*eigenvector*) e autovalor (*eigenvalue*).

APÊNDICE C

Formato do arquivo de entrada para teste:

1ª Linha: Nome da categoria

2ª Linha: Nome dos produtos separados por vírgula

3ª Linha: Notas dos produto, atribuída pelo especialista, separadas por vírgula

4ª Linha: Critérios de necessidade separados por vírgula

A partir da 5ª Linha: Uma linha para cada conjunto de features que compõem um critério.

Então, se existirem 3 critérios de necessidade, as linhas 5, 6 e 7 irão conter o nome das features de cada um deles, separadas por vírgula.

Próximas linhas: uma linha para cada feature, contendo os valores destas em cada produto, separados por vírgula.

APÊNDICE D

A tabela a seguir apresenta os resultados dos nossos testes de forma analítica. Cada linha contém informações e características de cada categoria. Sua organização está definida da seguinte forma:

- **Primeira coluna:** o nome da categoria conforme foi extraído do *TopTenReview*, pelo parser de *HTML*.
- **Segunda coluna:** informa a quantidade de alternativas, ou seja, produtos que o especialista avaliou e atribuiu notas para a mesma categoria.
- **Terceira coluna:** contém (para a quantidade de *features* extraídas da especificação técnica do produto, e que foram levadas em consideração pelo especialista para realizar sua *review*).
- **Quarta coluna:** quantidade de critérios de necessidades que o especialista utilizou para agrupar as *features* correspondentes.
- **Quinta coluna (*):** valor mínimo da distância euclideana calculada após a execução do Algoritmo Genético.
- **Sexta coluna (*):** valor da medição de correlação (Spearman) entre o *ranking* do especialista e da nossa solução.
- **Sétima coluna (*):** valor da medição de precisão ($p@k$) entre o *ranking* do especialista e da nossa solução.
- **Oitava coluna (*):** valor da medição do ganho cumulativo (*nDCG*) entre o *ranking* do especialista e da nossa solução.

(*) Os valores dessas medições correspondem a média aritmética calculada após a execução de todo o ciclo da validação cruzada pra cada categoria.

CATEGORIA	QUANTIDADE DE ALTERNATIVAS AVALIADAS	QUANTIDADE DE FEATURES UTILIZADAS	QUANTIDADE DE CRITÉRIOS DE NECESSIDADES AGRUPADORES	D.E. MÍNIMO	SC	P@K	nDCG
3D Blu-ray Player	10	20	4	0.01133485	0.964848485	1	0.965935829
3d Printer	15	37	5	0.00456575	0.972380952	0.941666667	0.997488155
3D TV	10	30	4	0.00292217	0.953803798	0.98	0.977472189
ACTION CAMCORDERS	10	24	4	0.0081758	0.976969697	0.98	0.987778553
AIR PURIFIER	33	36	4	0.02070407	0.928719008	0.921568627	0.871786964
Alarm Clocks	10	30	4	0.01273492	0.940606061	0.98	0.944735686
ALL-IN-ONE PC	10	22	4	0.01193161	0.829090909	0.98	0.747267281
All-In-One Printer	10	27	4	0.00812158	0.964138192	0.94	1
Android Phone	11	38	5	0.00813479	0.981818182	0.848484848	0.972909227
Android POS	10	24	4	0.00857434	0.979393939	1	0.950499645
AV Receiver	12	37	4	0.03234601	0.923391813	0.805555556	0.982499915
Baby Car Seats	10	27	4	0.01558543	0.784198151	0.9	0.75650056
Baby Sound Machine	9	20	4	0.0213754	0.931481481	0.955555556	0.973407189
Baby Video Monitor	10	25	4	0.03169785	0.438787879	0.6	0.810805624
BASE BOARD	10	13	3	0.03059813	0.905454545	0.8	0.992103792
BASS HEADPHONE	12	26	4	0.02937753	0.803613054	0.819444444	0.764264906
BATHROOM SCALE	10	28	4	0.01469222	0.906666667	0.86	0.971454245
Big Screen TV	8	30	4	0.01707944	0.931547619	0.90625	0.992788652
BIKE GPS	10	25	4	0.02532344	0.928484848	1	0.755387739
Binoculars	15	20	3	0.00376512	0.973607776	1	0.962516383
BLENDER	10	22	4	0.02141908	0.876363636	0.82	0.950838815
Blu-Ray Player	10	22	4	0.00593337	0.988454414	1	0.975680595
Bluetooth Car Kit	10	28	4	0.01401986	0.946666667	0.94	0.983903113
Bluetooth Headphone	10	22	4	0.02032628	0.831515152	0.98	0.763539482
Bluetooth Headset	10	29	5	0.00545029	0.979393939	0.98	0.997387885
Bluetooth Speakers	16	24	4	0.01470763	0.917095588	0.8828125	0.987154066

Bookshelf Speakers	14	20	4	0.01396211	0.929984301	0.857142857	0.930688841
BRIDGE CAMERA	11	39	4	0.00816738	0.927272727	0.984848485	0.996327478
Budget Micro Projectors	9	26	4	0.01546149	0.972222222	1	0.990190828
CANISTER VACCUUM	10	17	4	0.0121074	0.730909091	0.8	0.973859979
Car Alarm	5	22	2	0.02143949	1	1	1
Car Audio	14	40	5	0.06891181	0.984154454	0.87755102	0.999883229
Car Battery Charger	11	39	5	0.01030546	0.974380165	1	0.976529059
Car Inverter	9	29	3	0.02364852	0.944444444	0.933333333	0.943383945
Car Speakers	10	30	4	0.00575882	0.991515152	0.96	0.995523073
Car Subwoofer	10	16	4	0.01734754	0.883636364	0.98	0.898085559
CAR VACCUUM	10	22	4	0.02523785	0.627966427	0.62	0.942176872
Carpet Cleaner	10	27	4	0.02333624	0.913939394	0.92	0.934765984
Cell Phone Booster	10	29	4	0.0056407	0.978181818	0.98	0.994106638
Center Speaker	9	18	4	0.01031739	0.56253398	0.733333333	0.861679417
Central Air							
Conditioning	11	23	4	0.00972014	0.98612805	1	0.995772976
Chainsaws	10	35	4	0.01453758	0.93313501	1	0.873369613
Chemistry Sets	10	37	4	0.00877271	0.993939394	1	0.999439736
Chest Freezers	10	13	3	0.02683756	0.88902439	0.84	0.847371537
Circular Saws	10	29	4	0.00697987	0.951515152	0.88	0.946503526
Coffee Makers	10	25	4	0.01537901	0.978181818	0.88	0.998952832
Compact Digital Camera	10	39	4	0.0231038	0.907878788	0.98	0.88382347
Compact Microwave	10	23	3	0.02138705	0.114286242	0.42	0.600278346
Cordless Drills	10	26	4	0.01734916	0.961212121	0.84	0.978421458
Cordless Phones	10	29	4	0.01087366	0.976296303	0.98	0.972951238
Crank Radio	10	28	4	0.03399662	0.892121212	0.92	0.936291305
Curling Irons	10	15	3	0.01026831	0.868089116	0.8	0.860219428
Deep Fryers	10	27	4	0.00961236	0.964848485	0.96	0.970581719
Dehumidifiers	10	24	4	0.00492462	0.968484848	0.98	0.900781448

Die Cutting Machines	10	39	4	0.01655233	0.846060606	0.8	0.817926288
Digital Cameras for Children	10	27	4	0.019555997	0.930909091	0.98	0.971613805
Digital Grill Thermometers	10	26	3	0.01257661	0.712727273	0.66	0.924682516
Digital Pen	9	21	3	0.01427626	0.87962963	0.911111111	0.982875443
Digital Photo Frame	7	25	4	0.01855648	0.81122449	0.75	0.968848719
Dishwasher	23	43	5	0.001799	0.987927479	0.989130435	0.994250835
Donut Makers	8	17	4	0.03445083	0.851190476	0.84375	0.945108525
Dryers	17	46	4	0.00659327	0.973904268	0.993464052	0.951340086
DVR	12	40	4	0.01483999	0.900932401	0.833333333	0.823844417
eBook Reader	7	20	4	0.01533389	0.964285714	0.928571429	0.99889653
Electric Cooktop Ranges	9	36	4	0.00408253	0.988888889	1	0.996905915
Electric Cooktop	10	22	4	0.01602654	0.978181818	0.98	0.99778358
Electric Fireplace	10	19	4	0.00442169	0.92	1	0.928843405
Electric Hair Clippers	10	27	4	0.0118372	0.865454545	0.86	0.949917733
Electric Head Shavers	9	16	3	0.0575999	0.725925926	0.866666667	0.705030801
Electric Lawn Mowers	10	26	5	0.00744765	0.973333333	1	0.998640709
Electric Razors	11	24	4	0.01100727	0.936363636	0.818181818	0.98643727
Electric String Trimmer	10	20	4	0.02083855	0.816969697	0.78	0.922806093
Electric Toothbrushes	10	21	3	0.02601769	0.84	0.86	0.921953615
Electric Wall Double Ovens	10	23	4	0.00926952	0.911515152	0.86	0.977412438
Electric Wheelchairs	10	19	3	0.00885216	0.952727273	0.86	0.976923648
Electronic Translator	8	37	4	0.04391017	0.922619048	0.9375	0.979317765
Elliptical Machines	10	43	5	0.00529004	0.983030303	0.96	0.979259996

Emergency Cell Phone	10	41	4	0.01601232	0.884502566	0.9	0.829840944
Entry-Level DSLR							
Cameras	10	27	4	0.02426247	0.913939394	0.8	0.969351397
Espresso Machine	10	35	4	0.01621183	0.884848485	0.96	0.940828874
Exercise Bike	13	19	3	0.00449139	0.994758638	0.978021978	0.994258804
External Battery Packs	8	23	4	0.01226579	0.925595238	0.84375	0.919412807
Fitness Trackers	10	27	5	0.00952434	0.844848485	0.84	0.94883506
Floor Standing Speakers	10	19	4	0.01485742	0.92969697	0.82	0.972747175
Food Processors	10	20	3	0.00962902	0.907878788	1	0.850982707
Food Scales	10	24	4	0.01546449	0.858181818	0.92	0.880249644
Food Steamers	8	23	4	0.0094033	0.976190476	0.9375	0.99796122
French Door Refrigerator	10	31	5	0.01075863	0.853333333	0.98	0.949315086
Front-Load Washer	10	49	5	0.00723038	0.927272727	0.98	0.958081191
Game Camera	10	22	5	0.03224635	0.916363636	0.8	0.950983959
Gaming Keyboards	10	27	4	0.00889212	0.962424242	0.98	0.984691241
Gaming Laptop	11	22	5	0.01382396	0.848760331	0.833333333	0.970284844
Gaming PC	10	23	4	0.02753178	0.598787879	0.8	0.919264422
Gaming Steering Wheel	10	29	4	0.02187321	0.923636364	0.92	0.987472037
Garage Door Openers	10	28	4	0.00720312	0.96969697	1	0.969291832
Gas Cooktop	10	18	4	0.02602313	0.733333333	0.74	0.951547483
Gas Furnaces	10	14	3	0.01047421	0.832727273	0.8	0.920826395
Gas Grills	10	25	4	0.01487153	0.924848485	0.96	0.874131007
Gas Lawn Mowers	10	20	4	0.00578624	0.879031416	0.88	0.899907426
Gas Ranges	10	25	4	0.00813029	0.758787879	0.82	0.845491383
GPS Navigation	10	36	4	0.00472942	0.992727273	1	0.999420941
GPS Tracker	10	27	5	0.03166202	0.734545455	0.74	0.751526415
Graphics Cards	10	36	4	0.00584734	0.936969697	0.96	0.984574134

Hair Dryers	10	16	4	0.01390997	0.91030303	0.8	0.964562649
Hair Straighteners	9	34	3	0.04140075	0.566666667	0.777777778	0.871962197
Handheld Game Console	5	28	4	0.04457545	0.74	1	0.804271843
Handheld Vacuum	10	21	4	0.00718435	0.907878788	0.78	0.970308144
Hardwood Floor Vacuum Cleaners	9	28	5	0.04544336	0.627777778	0.822222222	0.712706848
HD Camcorder	10	34	4	0.01778529	0.926060606	0.94	0.951579263
HDMI Switcher	10	21	4	0.01314484	0.935757576	0.98	0.978131407
HDTV Antenna	10	17	4	0.02097332	0.762424242	0.74	0.894032055
Heart Rate Monitor Watches	10	28	4	0.01268318	0.941818182	0.9	0.992263398
Home Automation Systems	10	24	3	0.01271324	0.926060606	0.96	0.97455382
Home Gyms	10	31	4	0.0150729	0.916363636	0.94	0.974601548
Home Security Systems	13	39	4	0.00686942	0.972527473	0.956043956	0.805989967
Home Subwoofers	9	17	4	0.01270968	0.948148148	0.955555556	0.958002415
Home Theater In A Box System	7	31	3	0.01910342	0.954081633	0.892857143	0.969083346
Home Theater Projectors	8	28	3	0.02866241	0.488095238	0.65625	0.835193395
Home Theater Speakers	10	12	2	0.0205337	0.71030303	0.62	0.929299243
Hot Plates	10	14	3	0.01567171	0.938181818	1	0.960562709
Humidifier	10	23	4	0.01765664	0.881212121	0.98	0.925510085
Ice Cream Makers	10	12	3	0.03520236	0.763636364	0.8	0.786680338
In-Dash Navigation	10	23	4	0.00671268	0.995151515	0.96	0.999673414
Indoor Electric Grills	10	27	4	0.01025458	0.956363636	0.94	0.97518323
Induction Cooktop	10	18	4	0.00872636	0.989090909	1	0.997620708
Infrared Cameras	10	28	5	0.01156675	0.970909091	1	0.899225133
Infrared Grills	10	25	4	0.01986392	0.586666667	0.76	0.684018631
iPad POS Systems	11	38	5	0.00624827	0.996694215	1	0.999773416

iPad Restaurant POS	10	64	5	0.00365687	0.987878788	0.98	0.997655833
iPhone Lens Kits	8	15	3	0.01374982	0.977434358	1	0.996770856
iPhone Screen Protector	13	26	4	0.03146228	0.83292852	0.956043956	0.616112394
Irons	10	48	4	0.02356336	0.938181818	0.96	0.826936755
Juicers	10	30	4	0.01194762	0.964848485	0.96	0.992780004
Kids Microscope	15	30	4	0.01706366	0.966428571	0.916666667	0.935445932
Kids Tablets	10	20	4	0.00711684	0.993939394	1	0.967795223
Kindle	8	17	4	0.01709116	0.785714286	0.625	0.968275073
Kitchen TV	5	27	4	0.01445788	0.96	0.933333333	0.994195225
Laptop Computers	10	24	5	0.01576071	0.722424242	0.72	0.813087745
Laser Line Levels	10	29	4	0.02320677	0.878787879	0.92	0.946574535
LASER PRINTER	10	27	4	0.01330786	0.786021868	0.78	0.928540384
Leaf Blowers	10	17	4	0.00713563	0.970909091	0.98	0.946988085
LED Light Bulbs	10	19	3	0.00237983	0.975080492	0.82	0.998793305
LED TV	9	43	5	0.01825082	0.92962963	0.977777778	0.886692693
Marine Speakers	10	27	5	0.01048267	0.776969697	0.62	0.951833357
Meat Grinders	10	27	4	0.0515396	0.836363636	0.8	0.939806012
Meat Slicers	10	18	3	0.02224698	0.841212121	0.94	0.914726947
Meat Thermometers	10	16	3	0.01526861	0.848484848	0.9	0.81808208
Metal Detector	9	31	4	0.02611576	0.890740741	0.888888889	0.945256954
Mini Projector	7	16	3	0.04681653	0.428571429	0.75	0.845594276
Mixer	10	27	4	0.00833611	0.99030303	1	0.975366288
Mold Test Kits	13	24	4	0.02707129	0.954533339	0.934065934	0.876107265
Nanny Cam	10	22	4	0.01375643	0.812121212	0.82	0.863739717
Noise-Cancelling Headphone	20	25	4	0.01237329	0.889421189	0.875	0.978703498
Online POS	10	30	5	0.00795411	0.972121212	1	0.987744393
Over-the-Range Microwave	8	29	4	0.00374032	0.797918497	0.8125	0.916934246
Pay-As-You-Go Cell Phone	8	16	3	0.043228	0.904761905	0.9375	0.956690222

PC Gaming Headsets	10	27	4	0.01209079	0.872727273	0.98	0.993658466
Pedometers	19	32	4	0.02753077	0.769344414	0.789473684	0.851086236
Plasma TV	15	31	4	0.00484664	0.984212487	1	0.956574383
Pocket CamCorder	8	26	4	0.02580535	0.958333333	1	0.988984767
Point and Shoot							
Camera	10	29	4	0.01496078	0.820606061	0.82	0.789689051
Popcorn Maker	10	18	4	0.03987019	0.686060606	0.6	0.945857861
Portable Air							
Conditioners	10	33	5	0.00418681	0.976969697	0.96	0.963343432
Portable DVD Player	10	29	4	0.01088969	0.91030303	0.96	0.889111637
Portable Generators	10	32	4	0.00606673	0.992727273	1	0.986849982
Portable Speakers	10	26	5	0.02438061	0.654545455	0.74	0.958831277
Portable Washing							
Machine	9	30	4	0.01372359	0.794444444	0.977777778	0.776506289
POS Hardware &							
Software	10	29	4	0.00513294	0.990886036	1	0.967253139
Power Scooter	10	23	4	0.01477716	0.490909091	0.6	0.716795533
Professional DSLR	10	37	5	0.03329963	0.581818182	0.8	0.820844207
Programmable							
Thermostats	11	31	4	0.01456969	0.943801653	0.924242424	0.985414566
Push Lawn Mowers	10	22	4	0.01834045	0.883636364	0.8	0.994005259
Radar Detectors	10	29	4	0.00509126	0.998787879	1	0.99997671
RC Drones	10	28	4	0.0237262	0.941818182	0.82	0.982299076
Rear-View Cameras	10	18	4	0.02592994	0.883636364	0.82	1
Remote Control							
Airplanes	10	20	3	0.00820524	0.991515152	1	0.999237035
Remote Control Boats	9	31	4	0.02573821	0.664814815	0.844444444	0.664451701
Remote Control Cars	10	23	4	0.02102262	0.895757576	0.98	0.912711352
Remote Control							
Helicopters	10	16	4	0.01979833	0.928484848	0.8	0.970661776



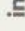


Restaurant POS Systems	10	66	5	0.00340585	0.941037782	0.88	0.996353865
Retail POS	10	27	5	0.00484176	0.96717772	0.98	0.987391884
Robot Vacuum	9	37	4	0.02404332	0.948148148	0.911111111	0.966153138
SANDWICH MAKER	10	22	4	0.01321663	0.776969697	0.8	0.858994073
Serger Sewing Machine	10	35	4	0.01119315	0.953939394	0.88	0.981363277
Sewing Machine	10	36	4	0.00832942	0.92969697	0.82	0.991871361
Shop Vacuums	10	30	4	0.01293686	0.854545455	0.86	0.866095995
Side-by-Side Refrigerator	10	37	5	0.01055365	0.899092299	0.98	0.930147612
Slide-In Range	10	30	4	0.01223737	0.84	0.78	0.97142215
Slow Cookers	10	24	4	0.06789272	0.88969697	0.84	0.929420776
Smart Locks	9	21	5	0.02684631	0.759259259	0.8	0.837137989
Smart TVs	9	34	4	0.01411914	0.935185185	0.933333333	0.977877529
SMARTPHONES	21	39	5	0.00795398	0.921439595	0.939393939	0.929339675
Smartwatch	10	36	4	0.01397865	0.821818182	0.78	0.939763562
Smoke Detectors	10	15	4	0.01657008	0.821818182	0.8	0.82870804
Snow Blowers	10	21	4	0.00996073	0.838787879	0.9	0.97773073
Solar Panels	9	27	5	0.02980109	0.974074074	1	0.994192975
Solar Phone Chargers	10	19	4	0.01532065	0.936969697	0.8	0.975070774
Sound Bar	10	25	4	0.01541409	0.963636364	0.92	0.985309289
Sound Machine	10	40	4	0.06416827	0.706666667	0.8	0.882095036
Space Heaters	10	16	4	0.00452365	0.977512114	0.92	0.963210887
Stick Vacuums	10	27	4	0.006804	0.974545455	0.98	0.980601954
Table Saws	10	23	4	0.0119927	0.836363636	0.98	0.945077548
TABLETS	11	18	5	0.02061469	0.730578512	0.742424242	0.913000044
Teeth Whiteners	10	20	4	0.0105865	0.980606061	0.98	0.999766586
Telescopes for Beginners	15	27	4	0.01688486	0.87452381	0.991666667	0.791167014
Toaster Ovens	11	24	4	0.02206998	0.683373071	0.803030303	0.873783832
Toaster	16	28	4	0.00899822	0.958455882	0.9921875	0.994004733




Top-Load Washing Machine	9	41	4	0.01043198	0.996296296	1	0.999366669
Tower Fan	10	19	3	0.0235259	0.905428582	0.8	0.952900638
Train Set	10	30	4	0.01307512	0.984242424	0.92	0.983184353
Treadmill	10	33	5	0.02240532	0.952727273	0.8	0.995897472
Turkey Fryers	10	24	4	0.00799031	0.869090909	0.76	0.975766695
TV LCD	8	21	3	0.04538271	0.732142857	0.75	0.924112222
TV Wall Mounts	10	16	4	0.02297319	0.943030303	1	0.996421129
Ultrabook	10	25	5	0.01695791	0.895757576	0.96	0.991258713
Universal Remote	6	35	3	0.02671329	0.923809524	1	0.998178121
Upright Freezer	10	18	4	0.00862687	0.937208618	0.92	0.982180522
Upright Vacuum Cleaner	14	35	5	0.00713319	0.936263736	0.918367347	0.990847099
VHS to DVD Converters	9	24	3	0.02187811	0.848148148	0.977777778	0.703100374
Video Game Consoles	9	41	4	0.02336738	0.916666667	0.888888889	0.978594754
Vinyl Converter	9	24	4	0.01220542	0.816666667	0.777777778	0.913326572
Turntable	9	28	4	0.02059903	0.92037037	0.911111111	0.994640047
Waffle Maker	9	28	4	0.004507	0.977777778	0.977777778	0.999446088
Walkie Talkie	9	28	4	0.00594715	0.955151515	0.92	0.912777048
Wall Air Conditioners	10	29	4	0.00608407	0.99702381	1	0.999921339
Washer Dryer Combo	8	31	4	0.01167082	0.903030303	0.82	0.979298266
Water Filter Systems	10	25	4	0.01268353	0.949090909	0.96	0.9795555
Waterproof Camera	10	47	6	0.01056506	0.888484848	0.98	0.900133456
Weed Whacker	10	25	4	0.00444668	0.99030303	0.98	0.99769699
Window Air Conditioners	10	31	4	0.00474495	0.934308282	0.897959184	0.998257011
Wine Cooler	14	29	3				

Wireless All-in-One Inkjet Printer	10	39	4	0.01542247	0.896969697	0.84	0.986089389
Wireless Charger	9	10	3	0.06943277	0.412962963	0.6	0.840269858
Wireless Digital Frames	7	40	4	0.02520331	0.852040816	0.964285714	0.893803174
Wireless Earbuds	10	26	5	0.0097267	0.781818182	0.88	0.850844243
Wireless Headphones	7	18	4	0.03758538	0.586734694	0.714285714	0.819881719
Wireless Laser Printer	10	32	4	0.01972435	0.867878788	0.82	0.966152456
Wireless Speakers	10	21	4	0.03152932	0.665454545	0.62	0.719619125


APÊNDICE E

+55 (21) 98351-2348 ✉ igor.veloso.custodio@gmail.com

 Lista de Desejos
  Carrinho
  Sair

Brasil ▼ Real (R\$) ▼




Questionário

Escolha uma categoria


COMPUTADOR -> SERVIDOR CELULAR CADEIRINHA DE MONTANHISMO

E-QQP


Lorem ipsum dolor sit amet, consectetur adipiscing elit, sed do eiusmod tempor




UNIRIO - PPGJ, Rio de Janeiro




Circle of Hands
24 DEC 2014



Circle of Hands
24 DEC 2014



Circle of Hands
24 DEC 2014



Circle of Hands
24 DEC 2014

SERVICE	QUOCK SHOP	POLICIES	ABOUT SHOPPER	ABOUT SHOPPER
Online Help	T-Shirt	Terms of Use	Company Information	<input type="text" value="Your email address"/>
Contact Us	Mens	Privecy Policy	Careers	Get the most recent updates from our site and be updated your self...
Order Status	Womens	Refund Policy	Store Location	
Change Location	Gift Cards	Billing System	Affiliate Program	
FAQ's	Shoes	Ticket System	Copyright	

APÊNDICE F

COMPUTADOR -> SERVIDOR

CELULAR

CADEIRINHA DE MONTANHISMO

FILTRO TIPO A:

<p>Tamanho da Tela (em pol.)</p> <p><input type="checkbox"/> Menor que 4</p> <p><input type="checkbox"/> Entre 4 e 11</p> <p><input type="checkbox"/> Maior que 11</p>
<p>Núcleos de Processador (em core)</p> <p><input type="checkbox"/> Menor que 2</p> <p><input type="checkbox"/> Entre 2 e 8</p> <p><input type="checkbox"/> Maior que 8</p>
<p>Velocidade do Processador (em GHz)</p> <p><input type="checkbox"/> Menor que 1</p> <p><input type="checkbox"/> Entre 1 e 2</p> <p><input type="checkbox"/> Maior que 2</p>
<p>Resolução da Tela</p>

FILTRO TIPO B:

<p>Tirar fotos bonitas (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p> <p><input type="radio"/> Essencial</p>
<p>Fazer vídeos com boa imagem (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p> <p><input type="radio"/> Essencial</p>
<p>Ter uma Tela com imagens bem definidas (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p>

FILTRO TIPO C:

<p>Armazenar muitos dados e arquivos (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p> <p><input type="radio"/> Essencial</p>
<p>Possuir Internet Rápida (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p> <p><input type="radio"/> Essencial</p>
<p>Tamanho da Tela (em pol.)</p> <p><input type="checkbox"/> Menor que 4</p> <p><input type="checkbox"/> Entre 4 e 11</p> <p><input type="checkbox"/> Maior que 11</p>
<p>Tirar fotos bonitas (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p> <p><input type="radio"/> Essencial</p>
<p>Fazer vídeos com boa imagem (em grau de Importância)</p> <p><input type="radio"/> Sem importância</p> <p><input type="radio"/> Pouco Importante</p> <p><input type="radio"/> Muito Importante</p>

APÊNDICE G

Questionário

Agradecemos sua participação até agora! Seria muito importante saber sua opinião através das perguntas abaixo.

Em relação as categorias de produto

➤ Informe o seu grau de conhecimento sobre os produtos de cada categoria abaixo.

Computador -> Servidor

Baixo 1 2 3 4 5 Alto

Celular

Baixo 1 2 3 4 5 Alto

Cadeira de Montanhismo

Baixo 1 2 3 4 5 Alto

APÊNDICE H

Questionário SUS

Formulário para identificar a percepção do usuário em relação a usabilidade de um sistema: System Usability Scale

Eu acho que gostaria de utilizar esse tipo de filtro de produtos frequentemente

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu achei esse tipo de filtro de produtos desnecessariamente complexo

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu achei esse tipo de filtro de produtos fácil de usar

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu acho que precisaria de suporte de um especialista para utilizar esse tipo de filtro de produtos

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu achei que os elementos desse tipo de filtro de produtos bem integrados

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu achei que existem muitas inconsistências nesse tipo de filtro de produtos

1	2	3	4	5
<input type="radio"/>	<input type="radio"/>	<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu posso imaginar que muitas pessoas aprenderiam a utilizar esse tipo de filtro de produtos muito rapidamente

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu achei esse tipo de filtro de produtos muito estranho para utilizar

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu me senti seguro em utilizar esse tipo de filtro de produtos

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Eu precisei aprender muitas coisas antes para poder continuar utilizando esse tipo de filtro de produtos

1	2	3	4	5
<input checked="" type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

ENVIAR