

**UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS**

Bruna Vicente Ribeiro

**FMEA orientada ao cliente: uma abordagem multicritério não
compensatória baseada em *text analytics***

São Carlos

2023

Bruna Vicente Ribeiro

FMEA orientada ao cliente: uma abordagem multicritério não compensatória baseada em *text analytics*

Monografia apresentada ao Curso de Engenharia de Produção, da Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Engenheiro de Produção.

Orientador: Prof. Dr. Lucas Gabriel Zanon

São Carlos
2023

AUTORIZO A REPRODUÇÃO TOTAL OU PARCIAL DESTE TRABALHO,
POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS
DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pela Biblioteca Prof. Dr. Sérgio Rodrigues Fontes da
EESC/USP com os dados inseridos pelo(a) autor(a).

R484f Ribeiro, Bruna Vicente
FMEA orientada ao cliente: uma abordagem
multicritério não compensatória baseada em text
analytics / Bruna Vicente Ribeiro; orientador Lucas
Gabriel Zanon. São Carlos, 2023.

Monografia (Graduação em Engenharia de
Produção) -- Escola de Engenharia de São Carlos da
Universidade de São Paulo, 2023.

1. Valor Percebido pelo Cliente. 2. Análise de
Sentimentos Baseada em Aspectos. 3. FMEA. 4. Inferência
Fuzzy. 5. Redes sociais. 6. Tomada de Decisão
Multicritério. 7. Smartphones. I. Título.

FOLHA DE APROVAÇÃO

Candidato: Bruna Vicente Ribeiro
Título do TCC: FMEA orientada ao cliente: uma abordagem multicritério não compensatória baseada em <i>text analytics</i>
Data de defesa: 13/12/2023

Comissão Julgadora	Resultado
Professor Doutor Lucas Gabriel Zanon (orientador)	Aprovada
Instituição: EESC - SEP	
Professor Titular Luiz Cesar Ribeiro Carpinetti	Aprovada
Instituição: EESC - SEP	
Doutorando Rafael Ferro Munhoz Arantes	Aprovada
Instituição: EESC - SEP	

Presidente da Banca: **Professor Doutor Lucas Gabriel Zanon**

*A todos aqueles que, de tantas formas,
apoaram-me ao longo desta jornada.*

AGRADECIMENTOS

Aos meus queridos pais, Cássia e Carlos, à minha amada irmã Luisa e a toda minha família, agradeço por serem meu alicerce e fonte inesgotável de apoio e amor.

Ao meu namorado, Yuichi, agradeço por compartilhar comigo cada desafio, por acreditar no meu potencial e por ser a minha força nos momentos mais difíceis.

Aos meus amigos, que tornaram minha jornada mais leve e divertida, agradeço por estarem sempre presentes.

Ao meu orientador, Lucas Gabriel Zanon, meu sincero agradecimento pela paciência, pela orientação e pelo valioso suporte ao longo deste trabalho.

Aos professores e funcionários do Departamento de Engenharia de Produção da EESC-USP, agradeço pela educação excepcional e pelo ambiente acolhedor que proporcionaram nos últimos anos.

Aos membros da banca, agradeço por aceitarem o convite para participar deste trabalho e contribuir com suas análises.

*“Pour ce qui est de l’avenir, il ne s’agit pas
de le prévoir, mais de le rendre possible.”*

Antoine de Saint-Exupéry

RESUMO

RIBEIRO, B. V. **FMEA orientada ao cliente: uma abordagem multicritério não compensatória baseada em *text analytics***. 2023. 83p. Monografia (Trabalho de Conclusão de Curso) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2023.

Capturar a percepção de valor do cliente é crucial para impulsionar melhorias na lealdade dos consumidores e na lucratividade da empresa. Nesse contexto, a análise de sentimentos nas redes sociais possibilita a obtenção de *insights* relevantes sobre a percepção de valor dos clientes em relação a diferentes atributos de um produto. O YouTube, em particular, se popularizou por ser uma plataforma cujos usuários disponibilizam conteúdo de avaliação de produtos e seus aspectos. Assim, abordagens de reconhecimento de fala automático (ASR) combinadas com processamento de linguagem natural de ponta, como análise de sentimentos baseada em aspectos (ABSA), têm o potencial de abordar essa questão. Além disso, a subjetividade inerente aos sentimentos extraídos deve ser considerada, o que pode ser feito por meio da teoria dos conjuntos *fuzzy*. A Análise de Modos de Falha e seus Efeitos (FMEA) é uma ferramenta de avaliação de riscos usada para identificar modos de falha potenciais que devem ser priorizados para mitigação. Para um resultado mais refinado, é essencial que ela aborde alguns aspectos, como: a não compensação entre critérios; a categorização dos modos de falha, em vez de sua ordenação, já que torna mais fácil o entendimento e apoio a tomadas de decisão; e a inclusão da visão do cliente. No entanto, não foram encontrados estudos na literatura que abordassem simultaneamente todos esses aspectos. Portanto, este trabalho propõe um modelo de análise de modos de falhas com o método de tomada de decisão multicritério ELECTRE TRI e incluindo a percepção de valor do cliente, a qual é capturada por meio da combinação de ASR, ABSA e sistemas de inferência *fuzzy*. Uma aplicação piloto do modelo foi conduzida com *smartphones* da série iPhone 15. Os principais resultados mostraram que o uso de perspectivas não compensatórias e a internalização da percepção de valor dos consumidores presente em vídeos do YouTube pode modificar a categorização dos modos de falha em relação à FMEA tradicional e melhorar o processo de tomada de decisão. Além disso, o uso da ABSA no contexto de *smartphones* foi validado, tendo sido observada a identificação assertiva dos aspectos do produto e uma ocorrência de cada um alinhada com as estratégias competitivas da marca.

Palavras-chave: Valor Percebido pelo Cliente. Análise de Sentimentos Baseada em Aspectos. FMEA. Inferência *Fuzzy*. Redes sociais. Tomada de Decisão Multicritério. *Smartphones*.

ABSTRACT

RIBEIRO, B. V. **Customer-oriented FMEA: a non-compensatory multi-criteria approach based on text analytics.** 2023. 83p. Monograph (Conclusion Course Paper) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2023.

Capturing customer value perception is crucial for driving improvements in consumer loyalty and company profitability. In this context, sentiment analysis on social media enables the extraction of relevant insights about customer value perception regarding different product attributes. YouTube, in particular, has become popular as a platform where users provide content evaluating products and their aspects. Thus, approaches using automatic speech recognition (ASR) combined with cutting-edge natural language processing, such as aspect-based sentiment analysis (ABSA), have the potential to address this issue. Furthermore, the inherent subjectivity in the feelings extracted must be considered, which can be done through fuzzy set theory. The Failure Modes and Effects Analysis (FMEA) is a risk assessment tool used to identify potential failure modes that should be prioritized for mitigation. For a more refined result, it is essential that it addresses some aspects, such as: the non-compensation between criteria; the categorization of failure modes, instead of ranking them, as it makes it easier to understand and support decision-making; and the inclusion of the customer's perspective. However, no studies were found in the literature that simultaneously addressed all these aspects. Therefore, this work proposes a failure mode analysis model with the ELECTRE TRI multi-criteria decision-making method, including customer value perception, captured through the combination of ASR, ABSA, and fuzzy inference systems. A pilot application of the model was conducted with iPhone 15 series smartphones. The main results showed that the use of non-compensatory perspectives and the internalization of consumer value perception found in YouTube videos can modify the categorization of failure modes compared to traditional FMEA and enhance the decision-making process. Additionally, the use of ABSA in the context of smartphones was validated, with an assertive identification of product aspects and their occurrences aligned with the brand's competitive strategies.

Keywords: Customer Perceived Value. Aspect-Based Sentiment Analysis. FMEA. Fuzzy Inference. Social Media. Multi-criteria Decision Making. Smartphones.

LISTA DE FIGURAS

Figura 1 – Sequência de etapas compondo a metodologia para realização do trabalho	21
Figura 2 – Ilustração do mecanismo da ABSA	25
Figura 3 – Etapas para a ASBA	26
Figura 4 – Pré-processamento de dados transcritos do YouTube	27
Figura 5 – Número Fuzzy Triangular	31
Figura 6 – Funções de pertinência para os termos linguísticos da Tabela 1	32
Figura 7 – Definição das categorias delimitadas por limites inferiores e superiores	38
Figura 8 – Definição das relações binárias S , I e R	40
Figura 9 – Modelo de apoio à tomada de decisão	41
Figura 10 – Desenvolvimento da ABSA	43
Figura 11 – Código de mineração de dados do YouTube	44
Figura 12 – Pré-processamento	46
Figura 13 – Tokenização e classificação gramatical	47
Figura 14 – Junção dos substantivos compostos	47
Figura 15 – Remoção de stopwords	48
Figura 16 – Identificação das relações de dependência	48
Figura 17 – Associação semântica	50
Figura 18 – Cálculo das funções de polaridade e subjetividade	50
Figura 19 – Funções de pertinência dos termos linguísticos das variáveis antecedentes	52
Figura 20 – Funções de pertinência dos termos linguísticos da variável consequente	52
Figura 21 – Cálculo da concordância parcial $c_j(a, b_h)$	54
Figura 22 – Cálculo da concordância total $c(a, b_h)$	54
Figura 23 – Cálculo da discordância $d_j(a, b_h)$	55
Figura 24 – Cálculo do índice de credibilidade $\sigma(a, b_h)$	55
Figura 25 – Cálculo das relações de preferência	56
Figura 26 – Classificação em categorias pelo procedimento pessimista	56
Figura 27 – Classificação em categorias pelo procedimento otimista	57
Figura 28 – <i>Market share</i> das vendas de <i>smartphones</i> por marca: Estados Unidos	59
Figura 29 – Resultados da mineração para o iPhone 15	60
Figura 30 – Resultados do pré-processamento para o iPhone 15	60
Figura 31 – Um exemplo de identificação de dependência nas frases mineradas	61
Figura 32 – Um exemplo de classificação gramatical nas frases mineradas	61
Figura 33 – Um exemplo de clusterização final na extração de aspectos das frases mineradas	61
Figura 34 – Resultado da extração de aspectos	62
Figura 35 – Resultados iniciais da análise de sentimentos	62
Figura 36 – Resultados finais da análise de sentimentos para o iPhone 15	63

Figura 37 – Resultados para iPhone 15: Áudio e Conectividade	64
Figura 38 – Resultados para iPhone 15: Bateria	65
Figura 39 – Resultados para iPhone 15: Câmera	65
Figura 40 – Resultados para iPhone 15: Desempenho	65
Figura 41 – Resultados para iPhone 15: <i>Design</i>	66
Figura 42 – Resultados para iPhone 15: <i>Display</i>	66
Figura 43 – Resultados para iPhone 15: Preço	66
Figura 44 – Quantidade de citações por <i>feature</i> e representatividade em % do total acumulado	67
Figura 45 – Enfoque às câmeras no <i>website</i> oficial do iPhone 15	68
Figura 46 – CPV em função da subjetividade e da polaridade	71
Figura 47 – CPV em função da importância para as necessidades dos cliente e da polaridade	72

LISTA DE TABELAS

Tabela 1 – Termos linguísticos e conjuntos <i>fuzzy</i> correspondentes	32
Tabela 2 – Diferentes definições de <i>Customer Perceived Value</i>	35
Tabela 3 – Principais relações de dependência: definição e exemplos	49
Tabela 4 – Termos linguísticos para avaliar o antecedente “polaridade”	51
Tabela 5 – Termos linguísticos para avaliar os antecedentes “subjetividade” e “importância para as necessidades do cliente”	51
Tabela 6 – Termos linguísticos para avaliar o consequente “CPV”	52
Tabela 7 – Número de adjetivos relacionados aos aspectos estudados	64
Tabela 8 – Impressões gerais do iPhone 15	64
Tabela 9 – Subjetividade e polaridade médias por aspecto	68
Tabela 10 – Subjetividade, polaridade e importância para as necessidades do cliente por aspecto	69
Tabela 11 – Base de regras do sistema de inferência <i>fuzzy</i>	70
Tabela 12 – CPV por aspecto	71
Tabela 13 – Avaliação dos critérios de entrada para o ELECTRE TRI	73
Tabela 14 – Descrição dos modos de falha	73
Tabela 15 – Definição dos limites das categorias	74
Tabela 16 – Índices de credibilidade, relações de preferência e categorias	74
Tabela 17 – Modos de falha por categoria	74
Tabela 18 – Modos de falha por categoria desconsiderando o CPV	75

LISTA DE ABREVIATURAS E SIGLAS

ABSA	<i>Aspect-Based Sentiment Analysis</i>
ASR	<i>Automatic Speech Recognition</i>
API	<i>Application Programming Interface</i>
CoA	<i>Center-of-area</i>
CPV	<i>Customer Perceived Value</i>
ELECTRE	<i>Élimination Et Choix Traduisant la Réalité</i>
FIS	<i>Fuzzy Inference System</i>
ICN	<i>Importance to Customer Needs</i>
MCDM	<i>Multi-Criteria Decision Making</i>
NLP	<i>Natural Language Processing</i>
RPN	<i>Risk Priority Number</i>
UGC	<i>User Generated Content</i>

SUMÁRIO

1	INTRODUÇÃO	16
1.1	Contextualização e lacunas de pesquisa	16
1.2	Objetivos e questão de pesquisa	18
1.2.1	Questão de pesquisa	18
1.2.2	Objetivo geral	19
1.2.3	Objetivos específicos	19
2	METODOLOGIA	20
2.1	Entendimento inicial da pesquisa	20
2.2	Fundamentação teórica	20
2.3	Desenvolvimento dos modelos computacionais	21
2.4	Aplicação piloto	22
2.5	Análise de resultados	22
3	REVISÃO BIBLIOGRÁFICA	23
3.1	Analise de Sentimentos	23
3.1.1	<i>Aspect-Based Sentiment Analysis (ABSA)</i>	25
3.1.2	TextBlob	28
3.1.3	Mídias Sociais e YouTube	29
3.2	<i>Fuzzy Inference Systems (FIS)</i>	30
3.3	<i>Customer Perceived Value (CPV)</i> e <i>customer-FMEA</i>	33
3.4	Métodos de tomada de decisão multicritério	36
3.4.1	ELECTRE TRI	38
4	MODELO DE TOMADA DE DECISÃO E IMPLEMENTAÇÃO COMPUTACIONAL	41
4.1	Implementação da análise de sentimentos baseada em aspectos	43
4.1.1	Mineração de dados	44
4.1.2	Pré-processamento	45
4.1.3	Extração de aspectos	45
4.1.4	Análise de sentimentos	49
4.2	Implementação do sistema de inferência <i>fuzzy</i>	50
4.3	Implementação do ELECTRE TRI	53
5	EXEMPLO DE APLICAÇÃO	58
5.1	Análise de sentimentos baseada em aspectos	59
5.1.1	Mineração de dados	59

5.1.2	Pré-processamento	60
5.1.3	Extração de aspectos	61
5.1.4	Análise de sentimentos	61
5.1.5	Sumarização dos dados	63
5.2	Sistema de inferência <i>fuzzy</i>	69
5.3	ELECTRE TRI e FMEA orientada ao cliente	72
6	CONCLUSÃO	76
	REFERÊNCIAS	79

1 INTRODUÇÃO

Este capítulo apresenta a contextualização e as lacunas de pesquisa que basearam o trabalho (Seção 1.1), bem como seus objetivos e a questão de pesquisa correspondente (Seção 1.2).

1.1 Contextualização e lacunas de pesquisa

A satisfação dos clientes vem ganhando espaço nas discussões das empresas à medida que sua importância e suas implicações passam a ser observadas. Definida como a percepção do usuário sobre o nível em que um produto ou serviço consegue atender às suas exigências, a satisfação do cliente tem um impacto direto em sua lealdade. A lealdade, por sua vez, é o que leva os consumidores à recorrência de compras, impede a perda de clientes para competidores e ainda os motiva a recomendar a empresa para terceiros (MADZÍK; SHAHIN, 2021).

Segundo Shah *et al.* (2006), embora o caminho para a adoção de uma abordagem “Cliente no Centro” ainda seja um desafio, não se trata de um conceito novo: o administrador e professor Peter Drucker já havia concluído, na década de 1950, que o cliente é quem determina o que um negócio produz e se ele vai prosperar. O autor afirma também que o foco das empresas não deve ser a venda de produtos, mas o atendimento das necessidades dos consumidores. Segundo ele, as organizações que investissem no desenvolvimento de práticas ligadas ao conceito de centralização do cliente teriam um retorno sobre investimentos de *marketing* consideravelmente superior ao de seus concorrentes.

Diante de clientes exigentes e bem-informados, competição global e economias instáveis, proporcionar valor aos *stakeholders* e mercados torna-se mais crucial do que nunca. As corporações globalmente discutem que toda atividade de *marketing* significativa deve ser direcionada à criação de valor para o cliente (ZEITHAML *et al.*, 2020). Para Lin *et al.* (2018), na era da internet, informações de redes sociais oferecem muitas oportunidades para que consumidores, um dos principais *stakeholders*, exprimam suas opiniões. Assim, trata-se do ambiente ideal para capturar a percepção de valor dos clientes e oferecer uma rica fonte de dados para tomada de decisão.

O YouTube, por exemplo, tem uma média mensal de 2,49 bilhões de usuários ativos, a segunda plataforma de mídias sociais mais ativa do mundo (WE ARE SOCIAL, 2023), onde grande parte do conteúdo é gerado por consumidores de determinadas marcas e produtos. Esses vídeos têm como objetivo o compartilhamento de opiniões, de conhecimento e de informações sobre os produtos, gerando debate entre os usuários da rede (SOKOLOVA; KEFI, 2020). Trata-se de um conteúdo disponível publicamente, que pode ainda ser transcrito para análise por meio de APIs (Interface de Programação de Aplicações) *open-source* de reconhecimento de fala

automático, como o Whisper, desenvolvido pela OpenAI. Assim, o *website* apresenta um grande potencial para capturar a percepção de valor do cliente.

Com a disseminação de *reviews* de produtos, expressão de opiniões e outras manifestações *online*, a opinião tornou-se uma espécie de ativo virtual para empresas que buscam promover seus produtos, descobrir novas oportunidades e preservar suas reputações, com os clientes desempenhando o papel de cocriadores de valor (PRAHALAD; RAMASWAMY, 2000). Assim, as organizações têm demonstrado crescente interesse em automatizar o processo de busca a respeito de conteúdo significativo sendo discutido sobre elas e compreender as interações nas redes sociais. Nesse contexto, a busca por soluções de análise de sentimentos têm sido impulsionada (CHAE, 2015).

Porém, com o enorme volume de dados disponível, a identificação de informações relevantes e sua interpretação ainda é um grande desafio, o qual justifica o desenvolvimento de técnicas de análise de sentimentos. Essas técnicas são conhecidas como técnicas de processamento de linguagem natural (NLP) e têm como objetivo identificar se a opinião expressa em um texto é positiva ou negativa (STINE, 2018). Entretanto, categorizar a polaridade do texto de maneira abrangente não é ideal no contexto da análise de como a percepção de valor é influenciada, já que um único texto frequentemente aborda múltiplos aspectos de maneira independente. Portanto, uma abordagem mais apropriada é a Análise de Sentimentos Baseada em Aspectos (*Aspect Based Sentiment Analysis*), que classifica os sentimentos relativos a aspectos específicos e permite uma delimitação mais granular de elementos positivos ou negativos no texto (NOH; PARK; PARK, 2019). Consequentemente, a técnica permite identificar com mais clareza como cada elemento afeta a impressão do cliente em relação a um produto ou serviço.

O envolvimento do cliente e a consideração de sua percepção é de suma importância também no que se refere à gestão de modos de falha, pois este é um *stakeholder* que será diretamente impactado por qualquer defeito ou problema que o produto venha a apresentar. O desenvolvimento de uma avaliação de modos de falha orientada ao cliente não apenas contribui para a identificação e prevenção desses diferentes modos, como tem um impacto direto na retenção e satisfação de clientes, fatores com consequências econômicas. Assim, esforços têm sido empreendidos no sentido de adaptar a Análise de Modo e Efeitos de Falha (FMEA), uma das principais ferramentas de gestão de modos de falha de produtos, para incluir a perspectiva do cliente (KOOMSAP; CHAROENCHOKDIOK, 2018).

Tradicionalmente, a FMEA avalia riscos por meio de três fatores: probabilidade de ocorrência (O), severidade dos efeitos (S) e capacidade de detecção (D), os quais são multiplicados para calcular o Número de Prioridade de Risco (RPN). Embora a simplicidade do cálculo facilite a implementação da ferramenta, isso também gera algumas preocupações, a exemplo da importância equivalente para todos os fatores (S, O e D), do efeito compensatório do cálculo e, principalmente, da ausência da perspectiva do cliente (KOOMSAP; CHAROENCHOKDIOK, 2018).

Dentre as abordagens de FMEA orientada ao cliente, Shahin (2004) propôs integrar a perspectiva do cliente na FMEA usando a severidade como ponto de conexão. No entanto, esta abordagem tem suas limitações. Por exemplo, ela assume que a severidade é uma função da ocorrência, o que nem sempre é verdade, dado que modos de falha raros, mas graves, podem causar insatisfação significativa. Em suma, severidade e insatisfação do cliente são duas variáveis importantes, mas há interesse em uma abordagem em que elas sejam determinadas de maneira independente, sem influenciar uma à outra.

Buscando melhorar esse modelo, Koomsap e Charoenchokdilok (2018) desenvolveram uma abordagem que apresenta severidade e ocorrência como elementos essenciais para a determinação da insatisfação dos clientes, com a severidade variando exponencialmente de acordo com uma versão modificada do modelo Kano. O RPN, então, foi definido como uma função da detecção e da insatisfação. Essa nova abordagem conseguiu refletir melhor que a anterior a voz dos clientes. Entretanto, a insatisfação dos clientes continuou sendo expressa a partir dos fatores de risco previamente estabelecidos pela FMEA, estando a opinião direta dos clientes limitada à determinação, via questionário, do fator exponencial atrelado à severidade de cada modo de falha (2, 1, 0 ou -1). Além disso, todos os modelos supracitados utilizam perspectivas compensatórias.

Quando há compensação entre critérios, um critério com desempenho elevado pode compensar um critério com performance mais baixa. Isso pode neutralizar o mau desempenho de certos critérios para os tomadores de decisão, diminuindo a visibilidade de modos de falha graves que necessitariam de maior atenção. Em contraste, abordagens não compensatórias estabelecem um padrão mínimo de desempenho exigido para cada critério, evitando a amenização de situações críticas (ARANTES *et al.*, 2022). Na FMEA, o uso de um método não compensatório para o cálculo do RPN é vantajoso, pois permite identificar aspectos com grande impacto à percepção de valor do cliente dependendo da forma com que este comprehende os critérios, sem tratar todos os critérios com uma régua única e a avaliação de fatores de risco como um valor médio.

Entretanto, não foram encontrados na literatura trabalhos que trouxessem uma FMEA orientada ao cliente calculada por meio de métodos não compensatórios e contemplando a opinião de usuários exposta de maneira espontânea das redes sociais. Além disso, embora muitos trabalhos tenham sido desenvolvidos usando dados do X, antigo Twitter, ou de comentários em vídeos do YouTube para mineração de dados e análise de sentimentos, a utilização dos vídeos da plataforma com esse fim ainda foi pouco explorada.

1.2 Objetivos e questão de pesquisa

1.2.1 Questão de pesquisa

A questão de pesquisa que motiva a elaboração deste trabalho é: a abordagem da FMEA orientada ao cliente é robustecida por meio da inclusão da percepção de valor obtida do grande volume de dados presente no YouTube a partir da aplicação da ABSA e da adoção de uma técnica de cálculo não compensatória?

1.2.2 Objetivo geral

O presente Trabalho de Conclusão de Curso objetiva propor um modelo de tomada de decisão para melhoria de produto e gestão de modos de falha a partir de uma abordagem que combina uma medida de valor percebido pelo cliente - capturado das mídias sociais por meio de ABSA - com os critérios tradicionais da FMEA.

A relevância do trabalho está na aglutinação de vários conceitos importantes na literatura, aprimorando o processo de gestão de modos de falha em termos de assertividade por meio de duas mudanças: a inclusão do valor para o cliente com ajuda de dados disponíveis *online* e de ferramentas de *machine learning*; e a utilização de métodos não compensatórios mais representativos da realidade. Não foram encontrados na literatura registros de modelos similares, que visassem à aplicação de tais análises em conjunto.

1.2.3 Objetivos específicos

O objetivo geral se desdobra nos seguintes objetivos específicos:

- (I) Revisar a literatura sobre *Aspect Based Sentiment Analysis*, sistemas de inferência *fuzzy*, valor percebido pelo cliente, FMEA orientada ao cliente, FMEA aplicada a *smartphones* e métodos de tomada de decisão multicritério não compensatórios;
- (II) Desenvolver uma aplicação computacional utilizando a linguagem de programação Python, com a finalidade de obter um código que possibilita a mineração e transcrição de dados do YouTube via ASR, Tratamento dos Dados, Extração de Aspectos e Classificação de Sentimentos de maneira não supervisionada;
- (III) Desenvolver um sistema de inferência *fuzzy* em MATLAB® com a finalidade de utilizar os resultados da ABSA para calcular um índice de percepção de valor pelo cliente (CPV);
- (IV) Desenvolver um cálculo de *Risk Priority Number* categorizado para FMEA orientada ao cliente, utilizando valores da literatura e o CPV calculado, por meio de uma técnica de tomada de decisão multicritério não compensatória - em particular o ELECTRE TRI;
- (V) Aplicar o modelo em um caso real, utilizando um *smartphone* líder de mercado como exemplo, e identificar modos de falha que oferecem maior risco à empresa por meio da captura da percepção de valor pelo cliente;
- (VI) Analisar resultados e potenciais vantagens no uso do modelo como auxílio na tomada em decisão em processos de gestão de modos de falha.

2 METODOLOGIA

Este trabalho pode ser classificado como quantitativo, axiomático e normativo, propondo um modelo integrador com base em lacunas na literatura e estudos prévios. A abordagem quantitativa axiomática normativa visa a prescrever soluções para problemas específicos. Modelos quantitativos envolvem variáveis em um domínio específico, estabelecendo relações causais. A pesquisa axiomática, por sua vez, busca soluções e *insights* sobre a estrutura do problema, gerando conhecimento sobre o comportamento das variáveis com base em suposições e manipulações no modelo (BERTRAND; FRANSOO, 2009).

A estrutura da metodologia adotada para este trabalho foi pensada a fim de permitir a realização de duas etapas: uma análise de sentimentos baseada em aspectos (ABSA), que gera insumos para a criação e estudo de um índice de valor percebido pelo cliente (CPV) e, em seguida, uma segunda etapa que se baseia nas anteriores para o cálculo de uma FMEA orientada ao cliente, adaptada por meio da técnica ELECTRE TRI.

Assim, a Figura 1 ilustra os diferentes passos envolvidos no desenvolvimento das etapas supracitadas: entendimento inicial da pesquisa, fundamentação teórica, desenvolvimento do código, estudo de caso e análise de resultados.

2.1 Entendimento inicial da pesquisa

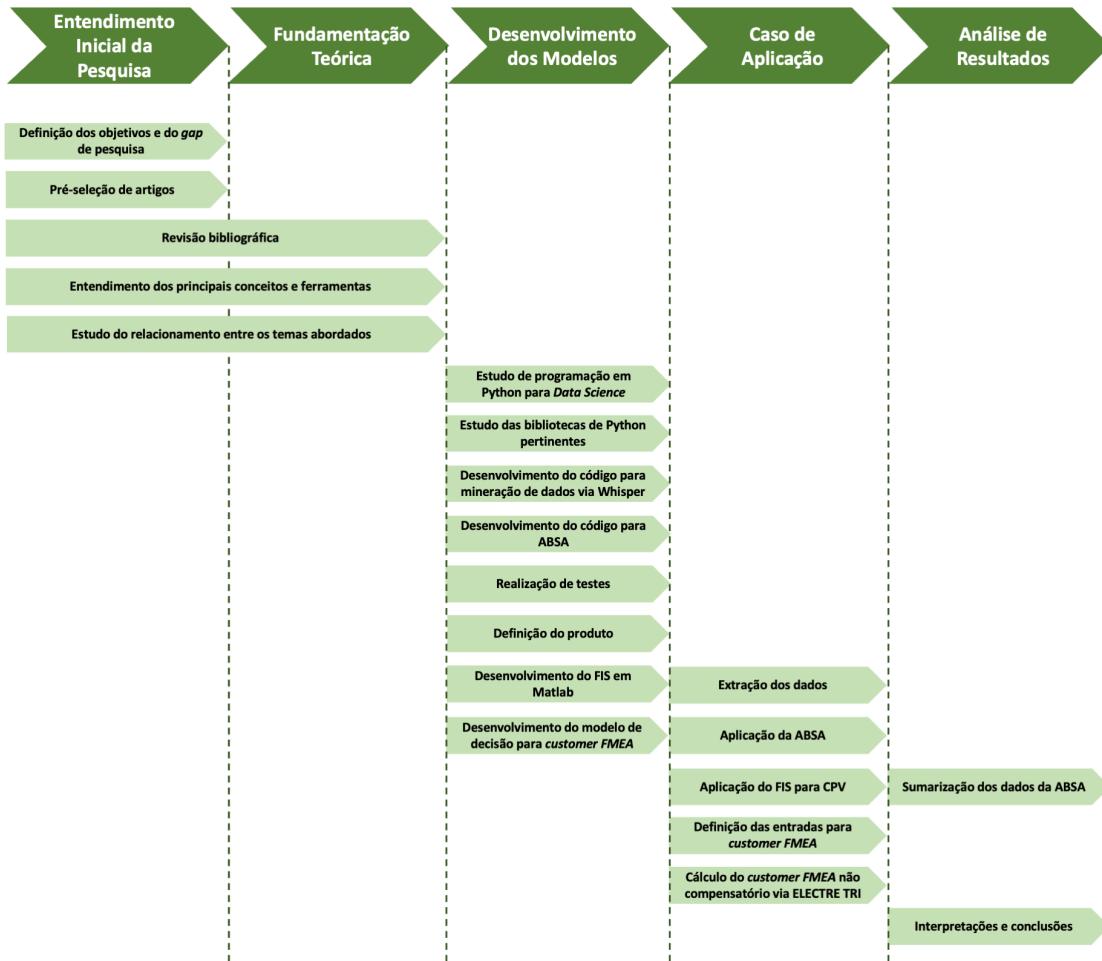
Nesta fase inicial, foi conduzido um estudo abrangente dos tópicos pertinentes à pesquisa. Realizou-se uma pré-seleção e leitura crítica dos principais artigos relacionados aos temas de interesse, além da assimilação dos conceitos-chave e ferramentas relevantes. Durante esse processo, ocorreu a identificação de lacunas de pesquisa e a definição clara dos objetivos a serem alcançados no estudo.

2.2 Fundamentação teórica

Após definição dos objetivos, foi realizada uma seleção mais aprofundada de artigos relacionados aos temas de interesse e às suas correlações. Para busca desse material, foram selecionadas as bases de dados Web of Science (apps.webofknowledge.com), SCOPUS (www.scopus.com) e EMERALD (www.emeraldinsight.com) devido à sua extensa coleção.

Nesta etapa, visava-se encontrar a melhor abordagem para aplicar as diferentes análises necessárias ao tema proposto, tanto de maneira isolada quanto em conjunto. Assim, foi conduzida uma breve revisão da literatura para identificar o estado atual no contexto da análise de sentimentos baseada em aspectos (ABSA), da definição e cálculo do valor percebido pelo cliente (CPV), da FMEA orientada ao cliente, da aplicação da FMEA em *smartphones* e do uso de modelos de apoio à tomada de decisão multicritério (MCDM), em particular o ELECTRE TRI.

Figura 1 – Sequência de etapas compondo a metodologia para realização do trabalho



Fonte: Elaboração própria (2023).

Além disso, foram buscadas referências quanto à relevância do YouTube como fonte de dados e seu poder de influência, bem como ao uso de sistemas de inferência *fuzzy* (FIS) e sistemas de reconhecimento de fala automáticos (ASR) em conjunto com a ABSA. Essa última combinação se provou ainda pouco discutida, em particular utilizando dados de vídeos extraídos do YouTube.

Durante a fase de fundamentação teórica, os textos revisados foram examinados na íntegra e empregados para aprofundar o entendimento teórico relacionado à pesquisa. Essa etapa teve como principal objetivo estabelecer uma base sólida que permitisse o desenvolvimento e a aplicação eficaz do código, aproveitando o conhecimento prévio das ferramentas e abordagens mencionadas na literatura. Os resultados dessa etapa são detalhados no Capítulo 3.

2.3 Desenvolvimento dos modelos computacionais

Nesta fase, elaborou-se um código em Python no ambiente Google Colab, dividido em quatro etapas essenciais: Mineração e Transcrição de Dados de vídeos do YouTube via API Audio

do OpenAI, baseada no modelo Whisper; Pré-processamento; Extração dos aspectos; e Análise de Sentimentos Baseada em Aspectos nos dados obtidos. Testes periódicos foram realizados durante o desenvolvimento, utilizando um vídeo curto de teste para a fase de transcrição e uma lista de frases como exemplo para validação do código relacionado ao ABSA.

Além disso, foi utilizado o Fuzzy Logic Designer do MATLAB® para aplicar o sistema de inferência *fuzzy* sobre os resultados da ABSA, gerando o índice de valor percebido pelo cliente. Por fim, foram definidos critérios, com base na FMEA orientada ao cliente, para a realização de um ELECTRE TRI no MATLAB®, a fim de permitir a categorização de diferentes aspectos do produto analisado. Detalhes adicionais sobre essa atividade serão apresentados no Capítulo 4.

2.4 Aplicação piloto

Para a análise de caso, optou-se pelo uso da série de dispositivos móveis iPhone 15. Essa seleção foi motivada pela presença de aspectos distintos e bem definidos nos produtos, além de seu lançamento recente com significativa repercussão nas redes sociais, em particular *reviews* no YouTube. Além disso, a aplicação de Análise Baseada em Sentimentos em Aspectos (ABSA) é amplamente reconhecida no contexto de avaliações de *smartphones*. Essa fase abrange a mineração e transcrição de dados reais do YouTube, utilizando filtros específicos para os produtos, duração dos vídeos e número de visualizações; o pré-processamento desses dados; a extração de aspectos; a classificação dos sentimentos e subjetividade por meio do TextBlob; a geração do índice de valor percebido pelo cliente para cada aspecto do iPhone 15 por meio do FIS; e uso do CPV e de valores encontrados na literatura para classificação dos aspectos segundo os conceitos da FMEA orientada ao cliente e do modelo de tomada de decisão multicritério ELECTRE TRI. Os detalhes do caso de aplicação serão apresentados no Capítulo 5.

2.5 Análise de resultados

Por fim, esta etapa permite a consolidação das informações geradas pelo uso conjunto da ABSA, FIS e MCDM. Os dados da ABSA foram sumarizados e organizados em tabelas e gráficos. Já o modelo em conjunto foi utilizado para o estudo da impressão dos clientes sobre diferentes aspectos do produto e para a definição daqueles que oferecem maior risco à empresa e, assim, gerar recomendações e direcionamentos que ajudem a tomada de decisão em relação a possíveis melhorias e mitigações.

3 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta as bases teóricas necessárias para fundamentar este trabalho, abordando os conceitos de Análise de Sentimentos Baseada em Aspectos (ABSA), *Fuzzy Inference Systems (FIS)*, *Customer Perceived Value (CPV)* e *Customer-oriented FMEA, Multi-Criteria Decision-Making (MCDM) Techniques*, especialmente o ELECTRE TRI, bem como suas definições na literatura. Caracteriza também a importância das mídias sociais, em particular do YouTube, como fonte de dados relacionados à percepção do cliente.

3.1 Análise de Sentimentos

Esta seção aborda o conceito de Análise de Sentimentos e, mais especificamente, a Análise de Sentimentos Baseada em Aspectos. Ela também discute a importância do YouTube como fonte de dados, bem como a maneira com que a rede social pode ser usada para aplicação de análise de sentimentos, a fim de obter informações relevantes em processos de tomada de decisão.

O campo da Análise de Sentimentos, também conhecido como mineração de sentimentos, consiste na utilização de técnicas que atribuem rótulos a opiniões, sentimentos e outras informações subjetivas expressas em formato textual. Geralmente, os rótulos indicam a polaridade, isto é, se o texto expressa um parecer positivo, negativo ou neutro. Além disso, na maioria dos casos, assume-se que o texto apresenta uma avaliação feita pelo autor a respeito de determinada entidade da qual ele é usuário, a exemplo da opinião de um cliente sobre um produto (STINE, 2018).

A análise de sentimentos pode ocorrer em três níveis distintos: no *Document Level*, a avaliação considera o texto como um todo, determinando se é favorável ou desfavorável. Essa abordagem é crucial para identificar a polaridade geral de uma revisão; já no *Sentence Level*, a análise se aprofunda, reconhecendo que opiniões podem variar entre as frases, exigindo uma classificação específica para cada afirmação; por fim, no *Feature Level*, a análise foca nas opiniões do autor sobre diversos tópicos abordados na revisão, incluindo qualidades e características do produto ou serviço avaliado. Esse enfoque permite uma análise mais detalhada, considerando palavras específicas e aspectos relevantes em cada sentença ou parágrafo (PANDITA; GONDHI, 2021).

No mundo contemporâneo, empresas, organizações e consumidores individuais buscam ativamente opiniões sobre produtos, serviços e marcas. Enquanto buscar opiniões tradicionalmente envolvia criação de pesquisas por e-mail ou telefone e discussões com amigos e familiares, o advento das redes sociais revolucionou esse processo. A proliferação de plataformas *online*, incluindo fóruns, *blogs* e redes sociais, tornou-as uma fonte crucial para a tomada de decisões.

Organizações agora podem acessar uma infinidade de informações publicamente disponíveis, eliminando a necessidade do uso dos métodos clássicos e alcançando um público mais abrangente, com custos reduzidos. Por outro lado, o imenso volume de opiniões torna difícil a extração e resumo das opiniões expressas. Assim, sistemas de análise de sentimentos automatizados desempenham um papel crucial para enfrentar esses desafios (LIU, 2012).

A técnica tem como objetivo detectar e classificar automaticamente opiniões, sentimentos e atitudes por meio de uma abordagem multidisciplinar que combina mineração de dados, recuperação de informações, processamento de linguagem natural e, em alguns casos, *machine learning* (BALAHUR; JACQUET, 2015 apud ZANON, 2022).

A análise de *big data* é definida pelo conjunto de dados, ferramentas analíticas, algoritmos computacionais e técnicas usados com o objetivo de extrair *insights* significativos e padrões de grandes conjuntos de dados. Essa abordagem oferece potencial para gestores entregarem valor contínuo e vantagem competitiva (KAMBLE; GUNASEKARAN, 2019). O YouTube, uma plataforma de *streaming* de vídeos pertencente ao Google, recebe 400 horas de vídeo a cada minuto, gerando enormes quantidades de dados. Com um número de vídeos publicamente acessíveis que se aproxima do bilhão, o *website* se configura como uma fonte potencial importante de *big data* (SUBHA; BHARATHI, 2023).

A computação de fluxo de *big data* baseia-se em programas que processam dados gerados em fluxo contínuo, proporcionando um processamento rápido de *big data* por meio de arquiteturas paralelas em larga escala. Essa abordagem torna-se a solução mais rápida e eficiente para obter conhecimento útil a partir das mídias sociais, permitindo que as organizações reajam rapidamente diante de problemas ou antecipem novas tendências (SUN *et al.*, 2015). Isso fortalece a ideia do uso da Análise de Sentimentos para uma tomada de decisão rápida e mais assertiva em relação ao valor percebido pelos clientes para produtos.

Segundo Balazs e Velásquez (2016), as opiniões desempenham um papel fundamental no processo de tomada de decisão tanto para indivíduos quanto para organizações, uma vez que influenciam profundamente as atitudes e crenças das pessoas. Para os autores, o interesse em usufruir do poder de detectar e compreender automaticamente opiniões é tão significativo que hoje esse campo é uma das áreas de pesquisa mais populares nas comunidades de Processamento de Linguagem Natural e Ciência da Computação.

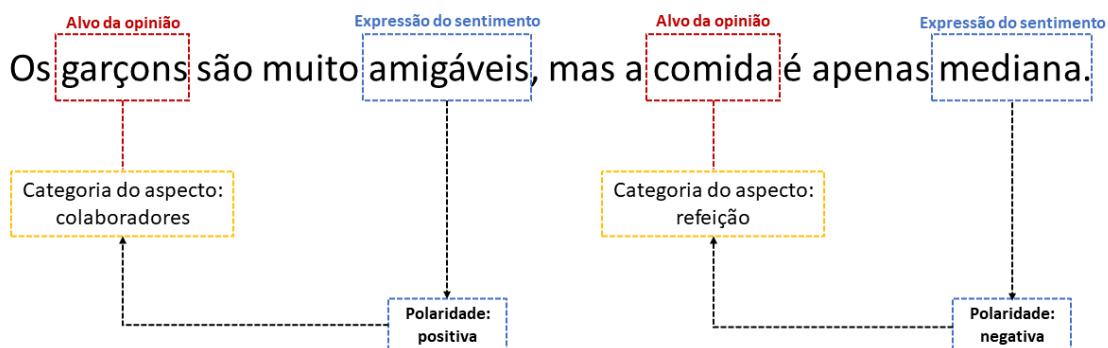
Entretanto, a análise de sentimentos padrão classifica o sentimento geral de um texto, mas não identifica a entidade, tópico ou aspecto específico a que se refere. Assim, ela pode ser insuficiente para documentos que expressam sentimentos variados em relação a diferentes aspectos (HOANG; BIHORAC; ROUCES, 2019). Identificar opiniões associadas a um aspecto específico no texto é uma tarefa mais complexa, conhecida como Análise de Sentimento Baseada em Aspecto (ABSA). A principal vantagem da ABSA é que, além de permitir a análise do conteúdo das sentenças em grande escala, é possível identificar qual aspecto está sendo abordado na sentença e qual é o sentimento atribuído a esse aspecto em investigação (ZANON, 2022).

3.1.1 Aspect-Based Sentiment Analysis (ABSA)

Aspect-Based Sentiment Analysis (ABSA) refere-se à análise detalhada de sentimentos, envolvendo a identificação e classificação do sentimento associado a termos específicos, como aspectos ou alvos. Essa abordagem busca uma análise mais granular em comparação com métodos de análise de sentimento mais amplos (PENG *et al.*, 2020). Para uma análise de sentimentos mais aprofundada, é essencial examinar os diferentes aspectos de um texto de forma independente, em vez de analisar a sentença como um todo. Isso se torna crucial na mineração de opiniões, uma vez que um único texto geralmente aborda vários aspectos distintos (NOH; PARK; PARK, 2019).

Como exemplo, pode-se mencionar a frase “Os garçons são muito amigáveis, mas a comida é apenas mediana”, em que os termos “garçons” e “comida” representam a extração do aspecto, enquanto a classificação do sentimento em positivo, negativo ou neutro se dará pelos adjetivos “amigáveis” e “mediana” (PENG *et al.*, 2020). Esse mecanismo pode ser observado na Figura 2.

Figura 2 – Ilustração do mecanismo da ABSA

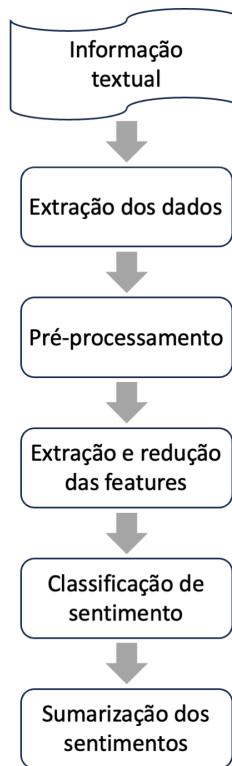


Fonte: Elaboração própria (2023).

De acordo com Pandita e Gondhi (2021), é possível descrever as principais etapas da análise de sentimentos baseada em aspectos conforme mostrado na Figura 3, cujos passos são explicados de forma mais detalhada.

- Extração dos Dados: A análise de sentimentos começa com a coleta de dados e avaliação de sua usabilidade. Para fins acadêmicos e de pesquisa, muitos conjuntos de dados pré-processados estão disponíveis *online*, mas carecem da complexidade, riqueza e atualização dos dados. Dados reais são frequentemente acessíveis *online*, como *posts* em mídias sociais, artigos de notícias, avaliações de produtos, etc. O primeiro passo é coletar e arquivar informações do *site online* em uma pasta local. Este é um passo crucial, pois a precisão dos dados coletados pode influenciar a saída da análise de sentimentos.

Figura 3 – Etapas para a ASBA

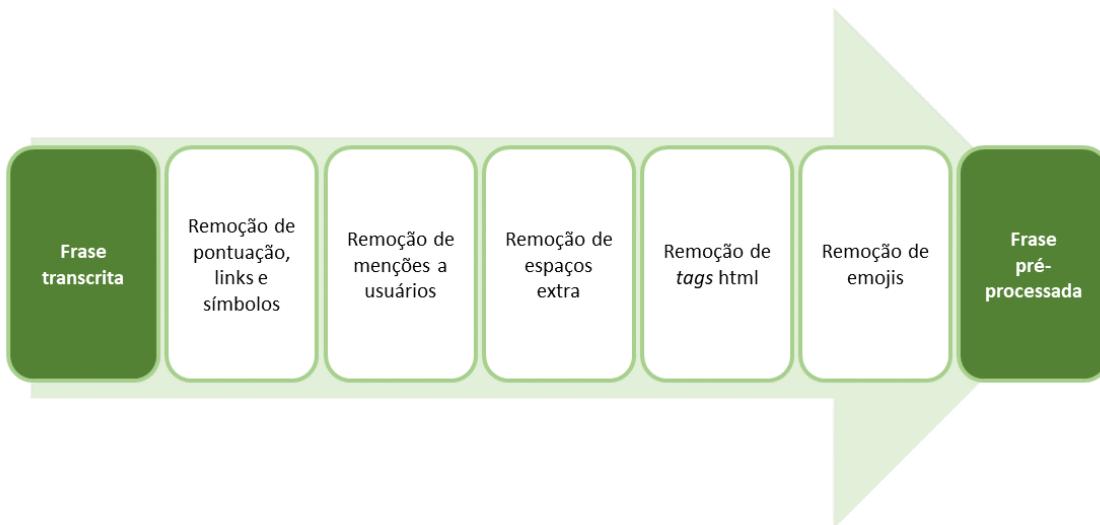


Fonte: Adaptado de Pandita e Gondhi (2021).

- Pré-processamento dos Dados: Em qualquer sistema de mineração de dados, o pré-processamento é a primeira atividade após a coleta de dados. O pré-processamento envolve a preparação de texto não estruturado para o reconhecimento de emoções. Isso é necessário, já que conjuntos de dados da vida real frequentemente contêm elementos que fazem parte da linguagem coloquial *online*, mas que podem comprometer a análise de sentimentos. Portanto, esses dados ruidosos são limpos para que a extração de aspectos e a detecção de sentimentos ocorram da melhor maneira possível. Um exemplo seria a frase extraída: “Comprei meu novo smartphone no site <https://www.cellphonestore.com/>, que achei ótimo, e o #iphone15 é simplesmente I-N-C-R-Í-V-E-L!!! ☺”. Após o pré-processamento, ela teria o seguinte formato: “Comprei meu novo smartphone no site, que achei ótimo, e o iphone15 é simplesmente incrível”. O método de pré-processamento é ilustrado na Figura 4.
- Extração e Redução de *Features*: Na ABSA, a extração de aspectos é uma etapa necessária. Escolher as *features* certas é crucial, pois a tarefa de classificação pode ser prejudicada, resultando em baixa precisão do sistema. O método *Bag of Words* é frequentemente usado para identificar aspectos em frases. Um ou mais atributos de palavras, como “qualidade da imagem”, podem ser o foco. Os aspectos identificados, muitas vezes chamados de conjunto de *features* candidatas, podem conter muitas *features*, várias das quais não terão importância posteriormente. Esses aspectos desnecessários, também chamados de

atributos irrelevantes, são observados e eliminados do vetor de aspectos no processo de redução de características. Atributos de várias palavras, como “vida da bateria”, devem ser identificados como um único aspecto, sendo tratados apenas como “bateria”, por exemplo.

Figura 4 – Pré-processamento de dados transcritos do YouTube



Fonte: Elaboração própria (2023).

- **Classificação de Sentimentos:** As sentenças são, neste ponto, classificadas como positivas, negativas ou neutras. No entanto, em muitos casos, a implementação da análise de sentimentos conta apenas com duas classes: a positiva e a negativa.
- **Sumarização dos Sentimentos:** Os resultados dos dados analisados são resumidos para tornar a tomada de decisões mais assertiva. Comumente, os tomadores de decisão consideram uma variedade de análises para tomar uma decisão específica. Portanto, *dashboards* de negócios são desejáveis para resumir as conclusões feitas a partir dos grandes conjuntos de dados.

Na ABSA, a classificação de sentimentos é realizada em determinado texto, para um aspecto referenciado, dando origens a várias tuplas. No exemplo da frase “Os garçons são muito amigáveis, mas a comida é apenas mediana”, as tuplas formadas seriam: (“são muito amigáveis”, colaboradores) e (“é apenas mediana”, refeição). Cada tupla tem categorização diferente, com colaboradores sendo classificado como positivo e refeição como negativo (NOH; PARK; PARK, 2019).

Existem três abordagens principais a serem seguidas na fase de classificação de sentimentos: algoritmos supervisionados ou de *machine learning*, dicionários e sistemas baseados em regras. A primeira abordagem oferece excelentes resultados em termos de precisão, mas requer um extenso conjunto de dados previamente rotulado. As duas últimas são não supervisionadas e

só precisam de ferramentas ou recursos dedicados à análise de sentimentos. As técnicas supervisionadas mais utilizadas no estado da arte são Árvores de Decisão, Support Vector Machines (SVM), Naive Bayes e, mais recentemente, Algoritmos de *Deep Learning*, devido aos excelentes resultados que proporcionam em tarefas de Processamento de Linguagem Natural. Entre as ferramentas não supervisionadas mais utilizadas estão SenticNet 6.0, SentiWordNet, WordNet-Affect, TextBlob, VADER, entre outras (GUTIERREZ; VILA; MARTIN-BAUTISTA, 2021).

Abordagens supervisionadas, que dependem de treinamento, não apresentam bom desempenho em contextos variáveis, enfrentando uma barreira para escalar a aplicação do método em diferentes domínios. Por outro lado, abordagens não supervisionadas evitam esse tipo de dificuldade quanto à mudança de contextos, uma vez que não requerem treinamento ou dados previamente rotulados (DING; LIU; YU, 2008). Além disso, de acordo com Liu (2012), a abordagem baseada no léxico - tipicamente não supervisionada - se provou superior em performance em diversos domínios.

3.1.2 TextBlob

Neste trabalho, a ferramenta TextBlob foi escolhida para classificação dos sentimentos. TextBlob é uma biblioteca do Python para processamento de dados em formato de texto. Ela permite realizar a análise de sentimentos e fornece uma API para realizar tarefas de processamento de linguagem natural, a exemplo de categorização de acordo com a classe morfossintática, classificação, tradução, extração de sintagmas nominais, entre outros (ZANON, 2022).

Quando a análise de sentimento é realizada, dois *scores* são obtidos para cada documento analisado: a polaridade e a subjetividade. O *score* de subjetividade é um valor entre 0 e 1, onde 0 é muito objetivo e 1 é muito subjetivo. Já o *score* da polaridade assume valores entre -1 e 1, representando o sentimento geral do documento, de forma que valores negativos correspondem a opiniões negativas e valores positivos equivalem a opiniões positivas (ZANON, 2022). Ambos serão utilizados neste trabalho.

O uso do TextBlob é justificado por algumas vantagens que a ferramenta apresenta na execução de análises de sentimentos em relação a outros métodos (GUTIERREZ; VILA; MARTIN-BAUTISTA, 2021):

- A ferramenta é não supervisionada, ou seja, não é necessário um conjunto de dados classificados, tornando a abordagem mais genérica e menos dependente do conjunto de dados utilizado;
- Ela funciona perfeitamente com dados de redes sociais;
- Ela é rápida o suficiente para ser utilizada com dados de *streaming*;
- Ela permite saber se um documento é positivo ou negativo, e o quanto ele é positivo ou negativo. Essa característica é de grande interesse, pois permite a definição do conjunto de

termos *fuzzy* e de suas respectivas funções de pertinência a partir do valor do índice de polaridade.

3.1.3 Mídias Sociais e YouTube

Rede social ou mídia social é um termo utilizado para descrever plataformas que permitem a interação entre grupos ou indivíduos, na qual eles produzem, compartilham e, por vezes, trocam ideias, imagens, vídeos e muito mais pela internet e em comunidades virtuais (AKRAM; KUMAR, 2017).

As redes sociais estão transformando fundamentalmente a maneira como as pessoas se comunicam e colaboram entre si, representando um impacto significativo da tecnologia da informação nos negócios. Essas plataformas alteraram abruptamente a forma como as pessoas interagem, criando novas conexões e aprimorando o compartilhamento de informações (ARAL; DELLAROCAS; GODES, 2013).

As redes sociais desempenham um papel fundamental nos recentes avanços relacionados à inferência de preferência dos consumidores. Empresas e setores utilizam as funcionalidades das redes sociais para se promoverem, se comunicarem com consumidores e com a sociedade, e cocriarem novos recursos e complementos que podem contribuir para a evolução das próprias redes sociais. Esse engajamento ativo não apenas fortalece a presença *online* das organizações, mas também possibilita a colaboração direta com o público (ARAL; DELLAROCAS; GODES, 2013).

Segundo o relatório “Digital 2023 October Global Statshot Report”, elaborado pela organização We Are Social (2023), 65,7% (5,30 bilhões de pessoas) da população mundial usa a internet - dos quais 95,8% acessam-na via celulares -, com cerca de 4,95 bilhões de pessoas (61,4%) como usuários ativos de redes sociais. Ainda de acordo com o relatório, o YouTube sozinho tem uma média mensal de 2,49 bilhões de usuários ativos, tornando-o o segundo no *ranking* das plataformas de mídia social mais ativas do mundo.

Para enfatizar a relevância desse *website* em particular, alguns números podem ser apresentados: entre abril e junho de 2023, os usuários globais passaram cerca de 27,5h na rede mensalmente (WE ARE SOCIAL, 2023) e mais de 400 horas de vídeo são carregadas no YouTube a cada minuto (SUBHA; BHARATHI, 2023). Desses, grande parte são os chamados *User Generated Content* (UGC), que se provaram mais populares e efetivos que anúncios profissionais, sucedendo o tradicional boca a boca (SOKOLOVA; KEFI, 2020). Assim, segundo o autor, marcas e usuários participam de um processo de troca de conhecimento e compartilhamento de informações sobre o produto. Nesse processo, *vloggers* conhecidos como influenciadores podem se tornar formadores de opinião e alcançar milhares de pessoas, influenciando-as no que concerne a percepção e intenção de compra sobre marcas e produtos.

Portanto, dado o grande volume de dados de caráter compartilhado, com potencial

de grande influência e alcance, a plataforma pode ser explorada para obter conhecimentos de negócio mais aprofundados, identificar tendências ocultas e adquirir outras informações relevantes (SUBHA; BHARATHI, 2023). Para analisar propriamente esses dados, podem ser utilizadas técnicas chamadas de *automatic speech recognition* (ASR), que têm se popularizado para geração de traduções automáticas e realização de pesquisas em *machine learning* e NLP de forma mais rápida e menos custosa (BUSSE; DUMRUKCIC; KLEIBER, 2023). O Whisper, desenvolvido pela OpenAI, é um sistema *open-source* de ASR. Ele foi treinado com 680000 horas de áudios em múltiplas línguas e se aproxima da robustez e precisão do nível humano no reconhecimento de fala em inglês (RADFORD *et al.*, 2022).

Embora diversos estudos tenham sido conduzidos aplicando ABSA aos comentários da plataforma YouTube, o estudo do conteúdo dos vídeos com o viés da análise de sentimentos baseada em aspectos ainda não foi muito abordado. Assim, os áudios transcritos do YouTube com ajuda do Whisper podem ser submetidos a uma ABSA, revelando a opinião de influenciadores sobre diferentes aspectos de importantes produtos disponíveis no mercado e permitindo a inferência dos efeitos de tais conteúdos nos consumidores.

3.2 *Fuzzy Inference Systems (FIS)*

A computação suave é um conjunto de técnicas que visa a explorar a tolerância à imprecisão e à incerteza em sistemas complexos, buscando alcançar praticidade, robustez e baixo custo na obtenção de soluções (ZADEH; KLIR; YUAN, 1996). Segundo Lima Junior e Carpinetti (2017), a teoria dos conjuntos *fuzzy* - ou conjuntos nebulosos - se destacou dentre essa técnicas, sendo aplicada de forma bem-sucedida em inúmeros campos.

Na lógica clássica ou binária, os objetos pertencem ou não a uma determinada classe ou conjunto, isto é, o pertencimento de um elemento ao conjunto é total ou nulo. Em processos de tomada de decisão, entretanto, essa lógica não consegue contemplar a subjetividade, imprecisão e incerteza do mundo real. Na lógica *fuzzy*, por sua vez, o grau ou nível de pertencimento de um elemento em determinado conjunto pode assumir diferentes valores, incluindo valores intermediários. Além disso, há sobreposição de conjuntos, que representa a transição entre duas classificações (CARPINETTI; ZANON, 2022a).

Na lógica *fuzzy*, a função de inclusão de um elemento em um conjunto é flexibilizada para que os objetos possam pertencer a um conjunto com grau de pertinência variando entre 0 e 1. Neste caso, a função de inclusão ou função de pertinência é dada pela seguinte expressão: $\mu_A(x) : x \rightarrow [0, 1]$; onde $x \in X$, sendo que $\mu_A(x)$ retorna o grau de pertinência do elemento x , pertencente ao universo de discurso X , em relação ao conjunto *fuzzy* A . Valores entre 0 e 1 representam pertencimento parcial ao conjunto (CARPINETTI; ZANON, 2022a).

Segundo Carpinetti e Zanon (2022b), todo número *fuzzy* deve satisfazer as condições de normalidade e convexidade. A normalidade é satisfeita quando ao menos um dos elementos tem

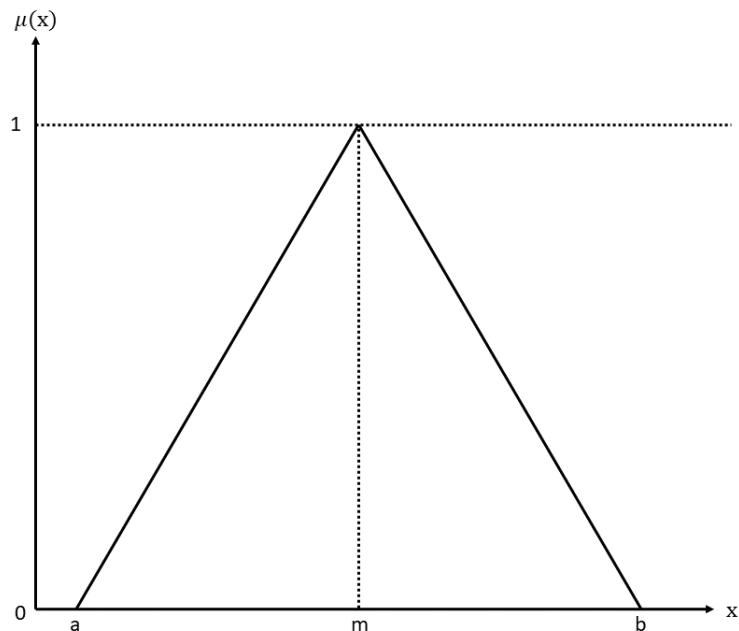
grau de pertinência igual a 1, isto é, $\sup \tilde{A}(x)_{x \in X} = 1$. A condição de convexidade é satisfeita pela Equação 1:

$$\tilde{A}[\lambda x_1 + (1 - \lambda)x_2 \geq \min[A(x_1), A(x_2)]] , \forall x_1, x_2 \in X \text{ e } \forall \lambda \in [0, 1] \quad (1)$$

Os números *fuzzy* mais comuns são aqueles cuja função de pertinência são triangulares ou trapezoidais (LIMA JUNIOR; CARPINETTI, 2017). Para a função de pertinência triangular, temos $a < m < b$, sendo m o ponto de máximo e $[a, b]$ o intervalo fora do qual o pertencimento é nulo. A função pode ser representada pela Equação 2 e pela Figura 5.

$$\mu_A(x_i) = \begin{cases} 0 , \text{ para } x_i < a \\ \frac{x_i-a}{m-a} , \text{ para } a \leq x_i \leq m \\ \frac{b-x_i}{b-m} , \text{ para } m \leq x_i \leq b \\ 0 , \text{ para } x_i > b \end{cases} \quad (2)$$

Figura 5 – Número *Fuzzy* Triangular



Fonte: Elaboração própria (2023).

Em geral, termos linguísticos qualitativos são usados para classificação da performance de diferentes alternativas em processos de tomada de decisão e outros contextos. Cada um desses termos, definidos em linguagem natural, pode ser associado a um número *fuzzy*, que será usado para traduzir de maneira quantitativa a avaliação expressa de forma subjetiva (CARPINETTI; ZANON, 2022b).

Por exemplo, cinco termos linguísticos podem ser usados para avaliar alternativas em relação a um critério: “Muito Ruim”, “Ruim”, “Médio”, “Bom” e “Muito Bom” (CARPINETTI;

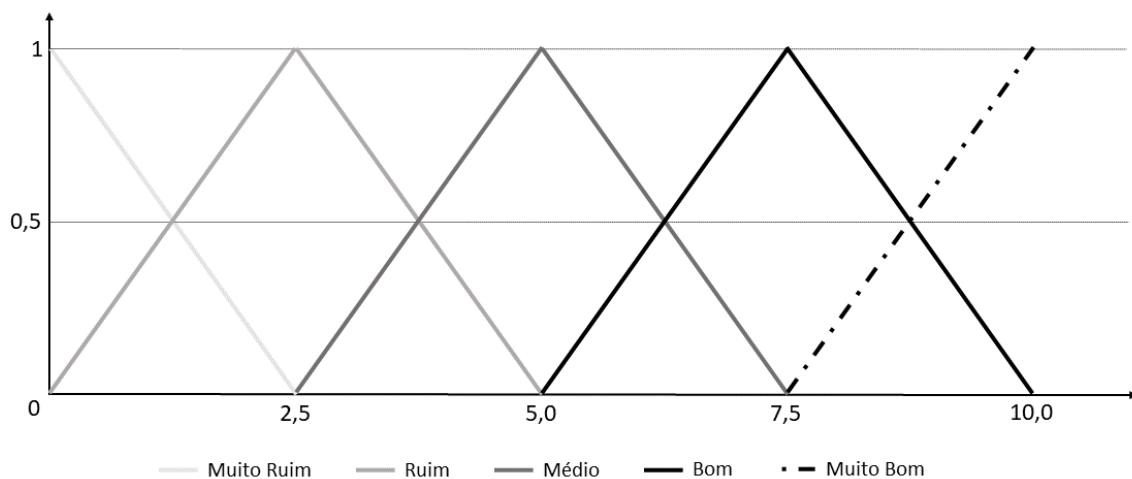
ZANON, 2022b). A Tabela 1 mostra os números *fuzzy* correspondentes, e a Figura 6 representa as respectivas funções de pertinência.

Tabela 1 – Termos linguísticos e conjuntos *fuzzy* correspondentes

Termos Linguísticos	Número <i>Fuzzy</i> (a; m; b) Correspondente
Muito Ruim	(0; 0; 2,5)
Ruim	(0; 2,5; 5,0)
Médio	(2,5; 5,0; 7,5)
Bom	(5,0; 7,5; 10,0)
Muito Bom	(7,5; 10,0; 10,0)

Fonte: Elaboração própria (2023).

Figura 6 – Funções de pertinência para os termos linguísticos da Tabela 1



Fonte: Elaboração própria (2023).

Os sistemas de inferência *fuzzy* ou *fuzzy inference systems* (FIS) têm como papel ajudar a quantificar informações em processos de tomada de decisão, por meio de regras baseadas na lógica “se-então” (KHAN *et al.*, 2018).

O processo de inferência em um FIS conta com variáveis de entrada e de saída, as quais têm termos linguísticos correspondentes, bem como os respectivos valores expressos na forma de conjuntos *fuzzy* (ZANON *et al.*, 2021). O processo se inicia com a fuzzificação dos valores numéricos das variáveis de entrada. Posteriormente, o conjunto fuzzificado passa pelas operações de inferência, combinando as regras de implicação ativas para gerar um conjunto *fuzzy* de saída, que será, em seguida, defuzzificado (GERAMIAN *et al.*, 2017).

Sejam X_1, \dots, X_F as F variáveis de entrada e Y a variável de saída. Uma regra *fuzzy* R^j típica é expressa como na Equação 3:

$$R^j = \text{SE } X_1 \text{ é } \tilde{A}_{1,2} \text{ E } X_2 \text{ é } \tilde{A}_{2,3} \text{ E } \dots \text{ E } X_F \text{ é } \tilde{A}_{F,2} \text{ ENTÃO } Y \text{ é } \tilde{C}_3, \quad (3)$$

onde $\tilde{A}_{f,i}$ e \tilde{C}_j são termos linguísticos associados a conjuntos *fuzzy* definidos respectivamente nos universos das variáveis de entrada e de saída (ZANON *et al.*, 2021).

A conjunção "E", que conecta cada proposição na porção antecedente das regras, é implementada por meio de um operador *t-norm*, mais comumente o mínimo (POURJAVAD; SHAHIN, 2018). Uma regra é ativada se cada elemento do vetor de entrada $\hat{\mathbf{x}} = [\hat{x}_1, \dots, \hat{x}_F]$ pertencer ao conjunto *fuzzy* correspondente no antecedente da regra R^j com um grau de pertinência diferente de zero (ZANON *et al.*, 2021), conforme a Equação 4.

$$\mu_{Ant}^j = \min(\mu_{\tilde{A}_{1,2}}(\hat{x}_1), \mu_{\tilde{A}_{2,3}}(\hat{x}_2), \dots, \mu_{\tilde{A}_{F,2}}(\hat{x}_F)) \quad (4)$$

Para cada regra de decisão ativada, o sistema de inferência *fuzzy* aplica o operador de implicação entre o antecedente e o consequente \tilde{C} da regra (POURJAVAD; SHAHIN, 2018). O operador de mínimo é expresso pela Equação 5:

$$\mu^j(y) = \min(\mu_{Ant}^j, \mu_{\tilde{C}_3}(y)) \quad (5)$$

As saídas de cada regra são agregadas em um único conjunto *fuzzy* por meio de um operador de agregação, como mínimo, máximo, média aritmética ou geométrica, entre outros (ZANON *et al.*, 2021). O operador de máximo é mostrado na Equação 6, em que Q é o número de regras ativadas.

$$AG(y) = \max(\mu^1(y), \mu^2(y), \dots, \mu^Q(y)) \quad (6)$$

Por fim, é realizada uma defuzzificação, transformando o número *fuzzy* em um número *crisp* ou convencional. A defuzzificação pode ser realizada utilizando-se o método do centro de área (CoA), que calcula o valor de saída com base em todos os valores de pertinência. O centro de área é calculado de acordo com a Equação 7:

$$CoA = \bar{y} = \frac{\int y \cdot AG(y)dy}{\int AG(y)dy} \quad (7)$$

3.3 Customer Perceived Value (CPV) e customer-FMEA

O conceito de valor sempre foi entendido como base fundamental para as atividades de *marketing*, norteadas pelo princípio de que, em uma relação de mercado, todos os envolvidos esperam um ganho de valor e os compradores selecionam a oferta que lhes proporciona a maior expectativa de ganho de valor (GRAF; MAAS, 2008). Nos últimos anos, entretanto, o conceito de *Customer Value* passou a ser investigado de forma mais frequente, sendo influenciado por

estudos em áreas como Cadeia de Valor, Comportamento do Cliente, Qualidade Percebida, Satisfação dos Clientes (PAYNE; HOLT, 2001). Em particular, existe uma estrita relação com os dois últimos, que são muitas vezes tratados como sinônimos na literatura.

Para Graf e Maas (2008), criar valor para o cliente é um pré-requisito essencial para o futuro sucesso das empresas. Além disso, segundo Song, Cadeaux e Yu (2016), entender a forma com que consumidores avaliam e percebem o valor de um serviço ou produto é fundamental para obter vantagens competitivas e melhorar intenções de compra. A gestão de valor para o cliente é essencial para as organizações, pois envolve a identificação do valor percebido pelos usuários em comparação com a concorrência e a medição do valor que eles trazem para a empresa. Isso permite direcionar estratégias de *marketing*, maximizar a satisfação do cliente e, consequentemente, a competitividade e a lucratividade da organização (EVANS, 2002). A percepção de valor do usuário é influenciada por fatores como qualidade percebida, preço relativo e risco percebido, sendo essencial compreender e gerenciar esses elementos (BENEKE *et al.*, 2013). Segundo os autores, a satisfação do consumidor desempenha um papel crítico na decisão de compra e lealdade à marca, contribuindo para a competitividade, *market share* e lucratividade da empresa.

Assim, inúmeras abordagens surgiram para definir, modelar e medir o chamado *Customer Perceived Value* (CPV). A Tabela 2 apresenta várias definições de valor percebido pelo cliente encontradas na literatura.

As diversas definições apresentam, entretanto, baixo nível de consenso entre si (GRAF; MAAS, 2008) e pouco foco em desenvolver uma forma prática e operacional de analisar o valor percebido objetivamente em uma perspectiva multidimensional (SWEENEY; SOUTAR, 2001). Além disso, estudos recentes que tentam mensurar o valor percebido pelo cliente têm relatado desafios relacionados à quantificação do valor (ZANON *et al.*, 2020).

Por outro lado, Songailiene, Winklhofer e Mckechnie (2011) destacam que, apesar da variedade de definições do conceito de CPV, há alguns pontos de concordância na literatura: a percepção de valor é individual e subjetiva; ele incorpora um *trade-off* entre o que será recebido e o que se abre mão para tal; é sempre relativo à concorrência; é uma construção de alto nível, orientada por uma série de construções menores sobre um produto ou serviço. Outros estudos ressaltaram que utilizar estratégias para melhorar o desempenho de indicadores diretamente ligados aos clientes permite a melhoria da percepção do valor do cliente (TRIGOS; VAZQUEZ; CÁRDENAS-BARRÓN, 2019).

No contexto em que a percepção de valor pelo cliente tem tanta relevância, o envolvimento dos consumidores é de suma importância também no que se refere à Análise de Modo e Efeitos de Falha (FMEA), dado que ele é o *stakeholder* que será diretamente afetado pelas falhas e defeitos que o produto venha a apresentar (KOOMSAP; CHAROENCHOKDIOK, 2018).

Tabela 2 – Diferentes definições de *Customer Perceived Value*

Autores	Campo	Jornal	Ano	Definição de CPV
Sweeney e Soutar	Varejo	Journal of Retailing	2001	Uma combinação de quatro dimensões: emoção, social, qualidade/performance e preço/valor por dinheiro.
Song et al.	Marketing/ Serviços	Industrial Marketing Management	2016	Avaliação do comprador nos âmbitos econômico e técnico, além de avaliar as relações de benefícios em troca de um preço pago.
Hanninen e Karjaluo	Cadeia de Suprimentos	Journal of Cleaner Production	2017	Avaliação do valor que é ganho por meio de uma relação com o fornecedor.
Walsh et al.	Varejo	Journal of Business Research	2014	A avaliação geral do usuário do produto (ou serviço) baseadas nas percepções do que é dado.
Li et al.	Tomada de Decisão	Discrete Dynamics in Nature and Society	2015	O que o consumidor está disposto a pagar em troca do que é oferecido pelo produto.
Petrick	Lazer	Journal of Leisure Research	2011	O que o consumidor recebe para o que ele abre mão.
Boksberger e Melsen	Marketing/ Serviços	Journal of Services Marketing	2011	Uma combinação de avaliações da percepção dos consumidores em relação aos benefícios e sacrifícios com a preferência comportamental afetando a situação geral.
Songailiene et al.	Serviços B2B	European Journal of Marketing	2011	Avaliação das dimensões financeira, estratégica e co-criação de valor determinadas pelo consumidor.

Fonte: Adaptado de Zanon *et al.* (2020)

A FMEA é uma ferramenta de análise de riscos criada na década de 1960 pela indústria aeroespacial, a fim de identificar modos de falha potenciais em produtos ou processos e tomar medidas corretivas para evitá-los (KOOMSAP; CHAROENCHOKDILOK, 2018). Desde então, a ferramenta se popularizou em diversas indústrias e se provou efetiva em atingir tais objetivos. Em seu formato original, ela envolve a avaliação de três fatores de risco: a probabilidade de ocorrência (O), a severidade dos efeitos (S) e a capacidade de detecção (D). Esses fatores são multiplicados para calcular, de maneira intuitiva, o Número de Prioridade de Risco (RPN), um *index* de avaliação do risco para cada modo de falha. A simplicidade da avaliação, por outro lado, também tem algumas desvantagens, pois leva à atribuição de importância equivalente para todos os fatores (S, O e D), a problemas na interpretação da escala para cada critério, a um efeito compensatório entre critérios e, principalmente, não é capaz de capturar a perspectiva do cliente

(KOOMSAP; CHAROENCHOKDILOK, 2018).

Kadëna *et al.* (2022), por exemplo, realizaram uma FMEA utilizando a abordagem *fuzzy* (F-FMEA) para investigar as falhas em *smartphones*. A escolha do produto para o estudo é justificada pelos autores devido à sua relevância cada vez mais significativa para o público. No entanto, apesar da centralidade do cliente nesse contexto, a perspectiva direta do usuário não foi incorporada, sendo os fatores de risco tradicionais avaliados pela visão de dois grupos de especialistas, como no modelo padrão.

Apesar disso, o desenvolvimento de uma FMEA orientada ao cliente tem sido explorado por alguns autores, como Shahin (2004) e Koomsap e Charoenchokdilok (2018). Adaptando os resultados de Tan e Shen (2000), Shahin (2004) propôs que a severidade poderia ser representada como uma função exponencial da ocorrência, em que os valores 2, 1, 0 e -1 podem ser atribuídos ao expoente de acordo com o modelo Kano tradicional. Segundo ele, essa seria uma abordagem para incluir a perspectiva do cliente. No entanto, ela tem algumas limitações: por exemplo, a severidade é tratada como função da detecção, o que não é válido em todos os casos; assim como nem sempre a severidade é uma função da ocorrência, dado que modos de falha raros, mas graves, podem causar insatisfação significativa.

Na busca por aprimorar esse modelo, Koomsap e Charoenchokdilok (2018) desenvolveram uma abordagem que incorpora ambas a severidade e ocorrência como elementos fundamentais para avaliar a insatisfação dos clientes. Nessa perspectiva, a severidade varia de maneira exponencial, seguindo uma versão adaptada do modelo Kano. O Número de Prioridade de Risco (RPN) foi então definido como uma função tanto da detecção quanto da insatisfação. Essa nova metodologia demonstrou uma capacidade mais precisa de refletir a voz dos clientes em comparação com a anterior. No entanto, a insatisfação dos clientes ainda é derivada dos fatores de risco inicialmente estabelecidos pela FMEA e não de um novo critério de avaliação. Aqui, a opinião direta dos clientes é obtida apenas por meio de questionários para determinar o fator exponencial associado à severidade de cada modo de falha (2, 1, 0 ou -1).

Por fim, Madzik e Shahin (2021) buscaram obter uma medição da satisfação dos clientes inspirada da FMEA, por meio da relação da satisfação com a lealdade dos consumidores. O chamado *loyalty priority number* (LPN) permite uma segmentação dos clientes de acordo com níveis de satisfação - assim como a FMEA é utilizada para priorizar riscos - e pode ser calculado a partir da frequência de compra, do valor da compra do cliente e da lealdade do cliente. Os resultados são obtidos exclusivamente com base nos fatores que definem o LPN, cujas notas são atribuídas pelos especialistas respondentes.

3.4 Métodos de tomada de decisão multicritério

Um modelo de tomada de decisão multicritério (MCDM - *Multi-Criteria Decision Making*) é definido como uma situação em que um tomador de decisão deve escolher entre

uma ou mais alternativas a partir da avaliação de dois ou mais critérios (DYER *et al.*, 1992). Diante da ambiguidade, da incerteza ou de um grande número de opções, esse tipo de abordagem permite ao tomador de decisão uma capacidade maior de selecionar as melhores alternativas (ROY, 1990).

Abordagens multicritério passaram da fundamentação teórica à aplicação de métodos computacionais para ajudar processos de tomada de decisão a partir da década de 1980 (DYER *et al.*, 1992) e tiveram um crescimento significativo em termos de variedade de técnicas e volume da literatura nas últimas décadas (GALO, 2018).

Classificam-se os métodos de tomada de decisão em três categorias distintas: (1) métodos aditivos, que podem ser determinísticos ou probabilísticos; (2) métodos de sobreclassificação; (3) outras abordagens, abrangendo programação matemática, métodos fundamentados em conjuntos *Fuzzy* ou *Rough Sets*, e técnicas de negociação e tomada de decisão em grupo. Entretanto, as inúmeras técnicas verificadas na literatura não são acompanhadas de muitos estudos que colaborem para a escolha adequada de um método de tomada de decisão conforme a situação. Além disso, embora a literatura sobre esses métodos seja vasta, é importante manter como prioridade encontrar um modelo útil sem perder a simplicidade, avaliando a relevância de se adicionar complexidade ao modelo conforme o contexto (ALMEIDA *et al.*, 2015 apud GALO, 2018).

Roy e Słowiński (2013) definiram uma série de questões a fazer para orientar o processo de seleção de métodos. Segundo esses autores, uma característica distintiva entre vários métodos de apoio à tomada de decisão é o tipo de resultado produzido, que pode categorizá-los entre método de escolha, de ordenação ou de categorização. Os métodos de escolha buscam identificar a melhor solução ou o menor número possível de soluções que justifiquem a eliminação das demais. Por outro lado, os métodos de ordenação proporcionam uma classificação hierárquica das alternativas. Já os métodos de categorização classificam as alternativas em categorias de desempenho, idealmente com níveis mínimos claramente definidos para cada critério.

Além disso, em MCDM, é necessário estar atento à existência de métodos que realizam compensação entre critérios. Quando ocorre a compensação, um critério que apresenta uma performance elevada em sua avaliação pode compensar outro que tem um desempenho avaliado mais baixo. Isso pode mascarar critérios com baixa performance para os tomadores de decisão e amenizar uma situação que exigiria mais atenção. Por outro lado, técnicas não compensatórias estabelecem um nível mínimo de performance exigido para cada um dos critérios (ARANTES *et al.*, 2022).

Na análise de modos de falha, há interesse na utilização de métodos não compensatórios que tornem a saída da FMEA mais representativa da realidade que o RPN tradicional. Por exemplo, o RPN não explica bem grandes catástrofes, que são muito graves, mas com baixíssima chance de ocorrência; tampouco reflete de maneira adequada o risco associado a eventos muito frequentes, mas nada severos (KOOMSAP; CHAROENCHOKDIOK, 2018). Assim, a Seção

3.4.1 apresenta um método de tomada de decisão não compensatório para categorização, que será empregado no modelo proposto neste trabalho.

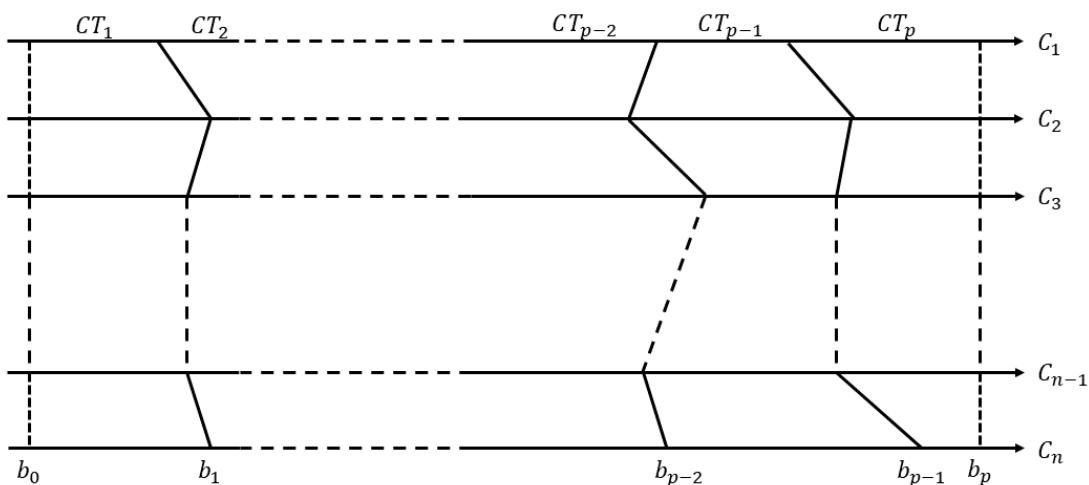
3.4.1 ELECTRE TRI

Os métodos da família ELECTRE (*Élimination Et Choix Traduisant la Réalité* - Eliminação e Escolha Expressando a Realidade) tiveram origem por volta de 1965 e podem ser utilizados tanto para escolha, como para ordenação e categorização (FIGUEIRA; GRECO; EHREGOTT, 2016 apud GALO, 2018).

Particularmente, a variação ELECTRE TRI é uma técnica de categorização multicritério utilizada para atribuir alternativas avaliadas em cada critério a categorias predefinidas e ordenadas com base em perfis de referência (CERTA *et al.*, 2017). Ele se encaixa adequadamente ao problema de avaliação de modos de falha devido a várias características, tais como: a não compensação entre critérios; a capacidade de lidar com escalas heterogêneas sem necessidade de normalização; e a possibilidade de uso de critérios qualitativos (GALO, 2018).

Conforme ilustrado na Figura 7, as categorias ordenadas dentro das quais as alternativas serão classificadas são definidas a partir de limites inferiores e superiores, adaptados para cada critério (GALO, 2018). Para um conjunto de n critérios $C_j (j = 1, 2, \dots, n)$, um limite inferior b_h e um limite superior b_{h+1} podem ser definidos, limitando a categoria CT_{h+1} . A relação de sobreclassificação S é construída por meio da comparação entre as alternativas e os limites $b_h (h = 0, 1, \dots, p)$. Então, cada alternativa é designada a uma categoria (MICALE; LA FATA; LA SCALIA, 2019).

Figura 7 – Definição das categorias delimitadas por limites inferiores e superiores



Fonte: Adaptado de Galo, Calache e Carpinetti (2018).

Se a alternativa a_i é pelo menos tão boa quanto o limite b_h , há uma relação de sobreclassificação S representada como “ $a_i S b_h$ ”. A validação dessa relação depende do índice de

credibilidade que é calculado na Equação 8, onde $c(a, b_h)$ é o índice de concordância global, que traduz o grau com que todos os critérios avaliados são consistentes com a afirmação “ $a_i S b_h$ ”. Por outro lado, $d_j(a, b_h)$ é o índice de discordância, que apresenta a contribuição do critério j contra a afirmação “ $a_i S b_h$ ”, sendo que $d_j(a, b_h) \geq c(a, b_h)$ (GALO; CALACHE; CARPINETTI, 2018).

$$\sigma(a, b_h) = c(a, b_h) \prod_{j=1}^n \frac{1 - d_j(a, b_h)}{1 - c(a, b_h)}, \quad (8)$$

Seja w_j o peso do critério j . O índice de concordância global é obtido de acordo com a Equação 9 (MICALE; LA FATA; LA SCALIA, 2019), onde $c_j(a, b_h)$ é o índice de concordância parcial que representa a contribuição do critério j para a afirmação “ $a_i S b_h$ ”.

$$c(a, b_h) = \frac{\sum_{j=1}^n w_j \cdot c_j(a, b_h)}{\sum_{j=1}^n w_j}, \quad (9)$$

Seja $g_j(a)$ a avaliação da alternativa “ a ” no critério j e $g_j(b_h)$ o limite b_h definido para o critério j . Consideram-se os limiares $p_j(b_h)$ e $q_j(b_h)$, respectivamente parâmetros de preferência e indiferença definidos *a priori*. O índice de concordância parcial pode ser calculado pela Equação 10 (GALO, 2018).

$$c_j(a, b_h) = \begin{cases} 1 & \text{se } g_j(a) - g_j(b_h) \leq q_j \\ \frac{g_j(b_h) - g_j(a) + p_j}{p_j - q_j} & \text{se } q_j < g_j(a) - g_j(b_h) \leq p_j \\ 0 & \text{se } g_j(a) - g_j(b_h) > p_j \end{cases} \quad (10)$$

Seja v_j o limiar voto. O índice de discordância $d_j(a, b_h)$ é obtido por meio da Equação 11 (GALO, 2018).

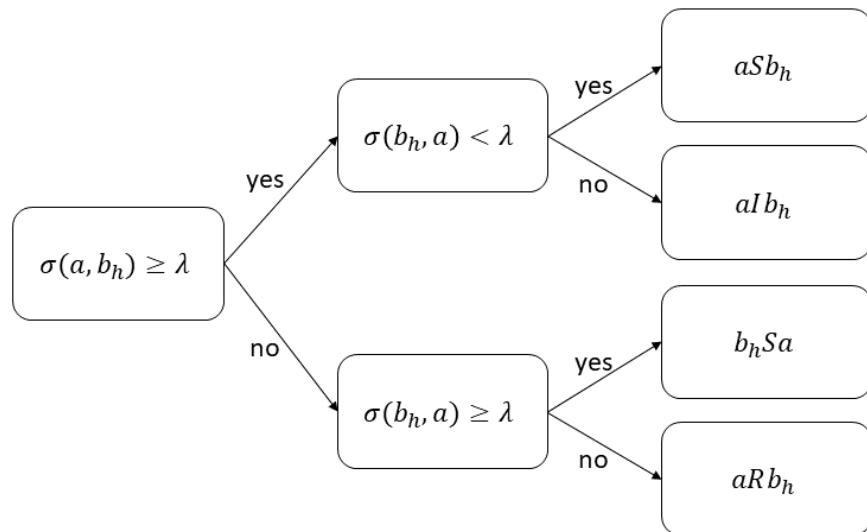
$$d_j(a, b_h) = \begin{cases} 1 & \text{se } g_j(a) - g_j(b_h) \geq v_j \\ \frac{g_j(a) - g_j(b_h) - p_j}{v_j - p_j} & \text{se } p_j \leq g_j(a) - g_j(b_h) < v_j \\ 0 & \text{se } c_j(a, b_h) \neq 0 \end{cases} \quad (11)$$

O limiar de preferência $p_j(b_h)$ representa a maior diferença $g_j(a) - g_j(b_h)$ para a qual se mantém a preferência de a em relação a b_h no critério g_j . Por sua vez, o limiar de indiferença $q_j(b_h)$ especifica a menor diferença $g_j(a) - g_j(b_h)$ em que a indiferença entre a e b_h é mantida no critério g_j . Por fim, o limiar voto $v_j(b_h)$ caracteriza a menor diferença $g_j(b_h) - g_j(a)$ que anula completamente a relação de sobreclassificação S (CERTA *et al.*, 2017).

Após o cálculo dos índices de credibilidade $\sigma(a, b_h)$ e $\sigma(b_h, a)$, as relações de preferência entre a e b_h são definidas pelo nível de corte λ , com $\lambda \in [0, 5; 1]$ definido *a priori*. As regras estão representadas a seguir, bem como na Figura 8 (CERTA *et al.*, 2017).

- $\sigma(a, b_h) \geq \lambda$ e $\sigma(b_h, a) \geq \lambda$: aSb_h e b_hSa , portanto a é indiferente em relação a b_h (aIb_h);
- $\sigma(a, b_h) \geq \lambda$ e $\sigma(b_h, a) < \lambda$: aSb_h e não b_hSa , portanto a é preferível em relação a b_h (aSb_h);
- $\sigma(a, b_h) < \lambda$ e $\sigma(b_h, a) \geq \lambda$: b_hSa e não aSb_h , portanto b_h é preferível em relação a a (b_hSa);
- $\sigma(a, b_h) < \lambda$ e $\sigma(b_h, a) < \lambda$: não aSb_h e não b_hSa , portanto a é incomparável em relação a b_h (aRb_h);

Figura 8 – Definição das relações binárias S , I e R



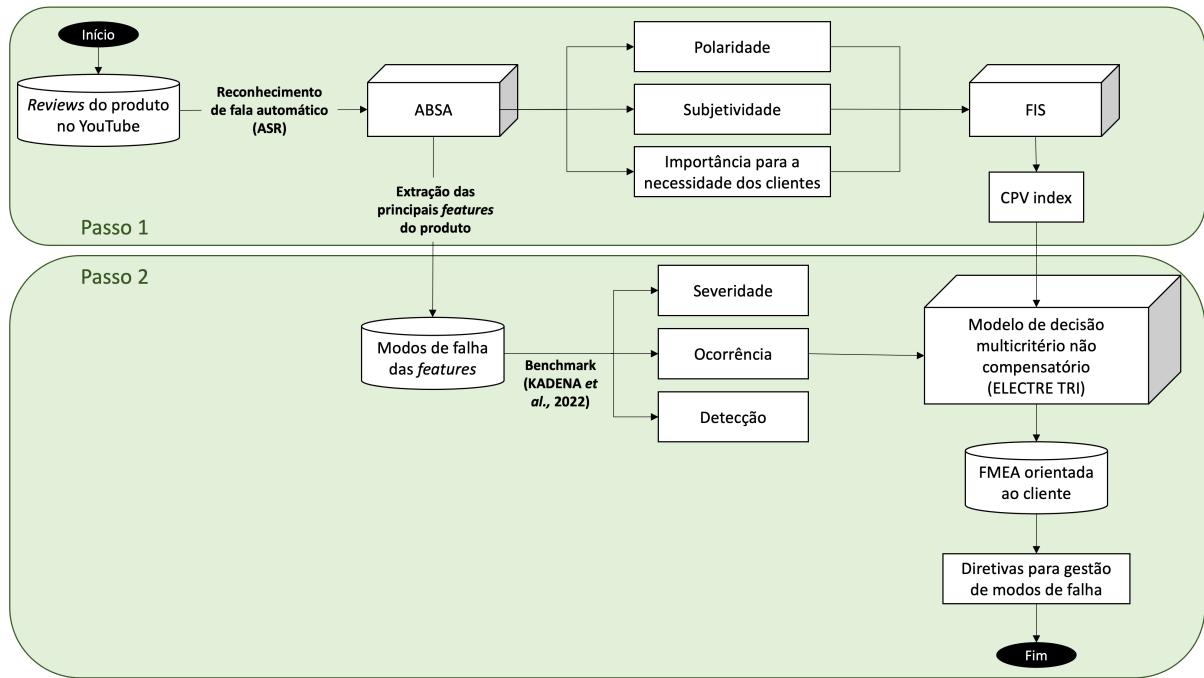
Fonte: Adaptado de Certa *et al.* (2017).

Uma vez que as regras de relação de preferência tenham sido verificadas, o procedimento de atribuição deve ser realizado de duas maneiras diferentes: a pessimista e a otimista. No procedimento pessimista ou conjuntivo, cada alternativa a é comparada sucessivamente com os limites $b_h (h = 0, 1, \dots, p)$ e a alternativa é atribuída à categoria mais alta CT_h em que aSb_{h-1} . Por sua vez, no processo otimista ou disjuntivo, cada alternativa é comparada sucessivamente com os limites $b_h (h = 0, 1, \dots, p)$ e a alternativa é atribuída à menor categoria CT_h na qual b_hSa (RAMEZANIAN, 2019).

4 MODELO DE TOMADA DE DECISÃO E IMPLEMENTAÇÃO COMPUTACIONAL

O modelo de tomada de decisão é estruturado com base em cinco importantes *frameworks* teóricos: análise de sentimentos baseada em aspectos (ABSA), sistemas de inferência *fuzzy* (FIS), valor percebido pelo cliente (CPV), análise de modos de falha e seus efeitos (FMEA) e tomada de decisão multicritério (MCDM). O modelo tem como objetivo extrair dados do YouTube em grande escala e analisá-los por meio de uma ABSA não supervisionada. Em seguida, sistemas de inferência *fuzzy* e métodos de análise de diferentes fatores de risco utilizam essas informações para ajudar na tomada de decisão em relação a modos de falha dos produtos incluindo a perspectiva do cliente. A Figura 9 ilustra o modelo de maneira detalhada.

Figura 9 – Modelo de apoio à tomada de decisão



Fonte: Elaboração própria (2023).

A primeira etapa do modelo consiste na escolha de um produto-chave do mercado, com lançamento recente e repercussão relevante nas redes sociais. Em seguida, é necessário definir uma fonte de dados de mídia social para mineração de texto, que possua um grande volume de dados de acesso gratuito e disponível publicamente, publicados e renovados constantemente. Nesse caso, foi escolhido o YouTube, por atender às características supracitadas, além de contar com a publicação orgânica e espontânea de análises do produto, as quais alcançam milhares e até milhões de pessoas. Uma API, que usa o modelo Whisper desenvolvido pela OpenAI, torna possível transcrever seu conteúdo e obter dados gerados pelo usuário. No entanto, o modelo de análise de sentimentos proposto pode também extrair informações de outras fontes, como X,

Reddit e as seções de comentários de consumidores em plataformas de venda em grande escala, como a Amazon.

Neste trabalho, foi desenvolvido um código em Python integrando o processo de mineração de texto dos vídeos - que capture os conteúdos relacionados a características do produto e segmenta-os em frases - com a abordagem não supervisionada de ABSA para analisar sua polaridade. O passo a passo da implementação computacional dessa abordagem, incluindo suas respectivas linhas de código, é apresentado na Seção 4.1.

Além disso, com o uso do TextBlob para operacionalizar o processo de análise de sentimentos, os *scores* de subjetividade e polaridade são obtidos para cada sentença analisada. Conforme definido na Subseção 3.1.2, a pontuação de subjetividade varia entre 0 e 1 e a polaridade é um valor dentro da faixa [-1,1], que representa o sentimento geral da frase.

Após calcular a subjetividade e a polaridade para cada sentença extraída, o valor médio de ambas foi calculado para cada aspecto identificado. As médias de subjetividade e polaridade ajudam os tomadores de decisão a identificar a opinião geral de um grande número de clientes em relação à característica fornecida. Além disso, o nível de importância de uma característica para as necessidades do cliente pode ser obtido calculando a frequência de ocorrência desse aspecto em comparação ao número total de relações entre *features* e adjetivos identificadas.

Para concluir a primeira etapa do modelo proposto, esses índices de polaridade, subjetividade e importância para o cliente, adaptados para uma escala de 0 a 10, foram as variáveis antecedentes de um sistema de inferência *fuzzy* (FIS). Este retornou como consequência uma variável chamada índice CPV, ou índice de valor percebido pelo cliente, que varia entre zero e dez e é o resultado da base de regras e da máquina de inferência. Quanto maior o valor do CPV, maior a percepção de valor pelo cliente. Além disso, uma superfície de resposta CPV pode ser gerada, simulando o nível do índice como uma função do nível das variáveis de entrada. Essa superfície é usada para apoiar a elaboração de diretrizes de planos de ação. Os termos linguísticos e os números difusos correspondentes, a base de regras e operadores dessa máquina de inferência são apresentados na Seção 4.2.

O índice CPV foi, então, utilizado em uma segunda etapa do modelo, para o cálculo de uma FMEA orientada ao cliente. O valor, definido para cada aspecto do produto analisado, foi uma entrada de um método de categorização multicritério não compensatório, o ELECTRE TRI. As demais entradas foram os critérios tradicionais da FMEA, severidade (S), ocorrência (O) e detecção (D), cujas notas foram extraídas de um estudo similar de Kadêna *et al.* (2022). Os autores determinaram, com ajuda de dois grupos de *experts*, os principais modos de falha e os valores de S, O e D correspondentes, para um produto análogo - da mesma marca e de geração anterior ao deste trabalho. Assim, é possível estender o uso à presente análise sem perda de correspondência com o produto. Para associar os valores de S, O e D com o índice de CPV, foi necessário estabelecer uma correlação dos modos de falha com a característica do produto com a qual eles se relacionam. Por exemplo, para um *smartphone*, o modo de falha da bateria pode ser

ligado à percepção que os clientes têm da bateria, de forma mais geral.

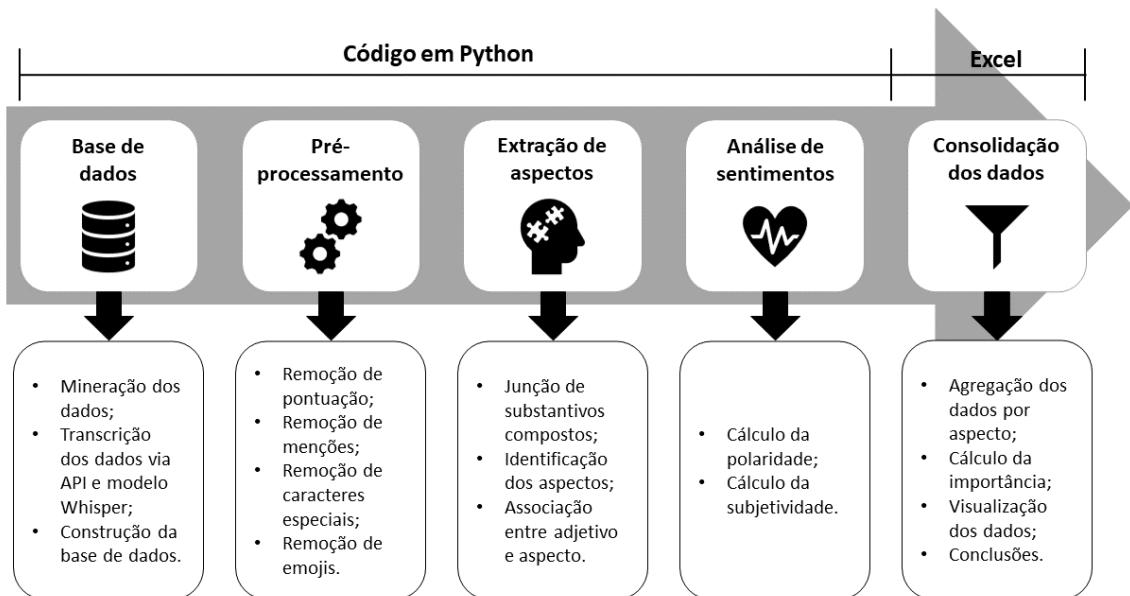
A saída do ELECTRE TRI é a FMEA orientada ao cliente, isto é, a avaliação do risco de cada um dos modos de falha. No caso do método multicritério utilizado, gerou-se uma classificação de cada modo de falha dentro de categorias pré-estabelecidas, de acordo com uma visão pessimista e uma visão otimista. O passo a passo da implementação do ELECTRE TRI está pormenorizado na Seção 4.3. Por fim, os resultados da FMEA orientada ao cliente permitem direcionar a política de gestão de modos de falha da empresa e facilitar a tomada de decisão.

4.1 Implementação da análise de sentimentos baseada em aspectos

Para a criação do código, foi utilizada a plataforma Google Colab e a linguagem de programação Python. A plataforma Colab é um serviço em nuvem gratuito hospedado pelo próprio Google, a qual permite a combinação de código-fonte (geralmente em Python) e texto enriquecido (geralmente em *markdown*) com imagens e resultados do código, uma técnica conhecida como *notebook* (ZANON, 2022).

O código foi segmentado em quatro seções principais, que englobam quatro das cinco etapas da ABSA discutidas na Seção 3.1.1 da revisão bibliográfica e detalhadas na Figura 10. A quinta etapa, resumo dos dados, foi realizada por meio do Microsoft Excel, devido à maior variedade de opções para visualização dos resultados. Essa escolha permite a criação de gráficos e filtros dinâmicos, facilitando a compreensão dos dados para este trabalho.

Figura 10 – Desenvolvimento da ABSA



Fonte: Elaboração própria (2023).

4.1.1 Mineração de dados

Para obter os dados do YouTube, devem ser definidas algumas regras de seleção, as quais podem variar de acordo com o problema. Para o exemplo de aplicação deste trabalho, esses critérios serão detalhados na Subseção 5.1.1.

Os vídeos selecionados foram, então, baixados e armazenados em uma pasta do Google Drive. A transcrição dos arquivos foi realizada utilizando-se a API Audio, que aplica o modelo Whisper, desenvolvido pela OpenAI. Um *loop* foi aplicado para alcançar cada arquivo da pasta de vídeos, transcrevê-lo com ajuda da API e reparti-lo em frases, para refinar a identificação de aspectos. A transcrição de cada arquivo foi enviada para o Google Drive em formato “pkl”, que pode ser diretamente carregado e lido como objeto Python posteriormente. Essa etapa permitiu evitar a necessidade de retranscrever a cada iteração da ABSA, melhorando a performance do *notebook*. O código para o processo de mineração de dados está apresentado na Figura 11.

Figura 11 – Código de mineração de dados do YouTube

```

1 !pip install openai
2 !openai migrate
3 from openai import OpenAI
4 import re
5 import pickle
6 import shutil
7 from google.colab import files
8 from google.colab import drive
9 drive.mount('/content/drive')
10
11 # Personal key generated on OpenAI page
12 api_key='sk-H1BCvndrkv4TkX8ivbNXT3B1bk85ugR8NZ0SW35cat'
13 # Initialization
14 client = OpenAI(
15     api_key=api_key,
16
17 # Function to transcribe an audio file and split the transcript into sentences
18 def transcribe_and_split(audio_file_path):
19     with open(audio_file_path, 'rb') as audio_file:
20         transcript = client.audio.transcriptions.create(
21             model="whisper-1",
22             file=audio_file,
23             response_format="text")
24         sentences = re.split(r'[.!?]', transcript)
25         sentences = [sentence.strip() for sentence in sentences if sentence.strip()]
26     return sentences
27 # Determine the number of audio files to transcribe
28 max_audio_file = 50 # Maximum number of files to transcribe
29
30 # Loop through the files and append the sentences to all_sentences
31 for i in range(1, max_audio_file + 1):
32     audio_file_path = f"/content/drive/My Drive/TCC/video{i}.mp3"
33     transcript_video = transcribe_and_split(audio_file_path)
34     print(transcript_video[:3]) # Only testing if the output is ok
35
36 # Creating file to store lists
37 with open(f'transcript_video{i}.pkl', 'wb') as file:
38     pickle.dump(transcript_video, file)
39 # Send files to Google Drive
40     shutil.copy(f'transcript_video{i}.pkl', '/content/drive/MyDrive/TCC')

```

Fonte: Elaboração própria (2023).

4.1.2 Pré-processamento

Redes sociais são plataformas orgânicas onde os usuários geralmente postam de uma forma diferente do que é encontrado em bases acadêmicas artificiais. Os usuários se expressam por meio de elementos coloquiais, os quais podem prejudicar o processamento natural da linguagem por algoritmos computacionais. Portanto, torna-se necessário realizar um pré-processamento nesses dados textuais.

O pré-processamento consiste em moldar o conteúdo do vídeo transscrito para que ele se assemelhe o máximo possível a uma sentença formalmente escrita, sem abreviações, símbolos ou qualquer outro item que possa dificultar o processamento natural da linguagem humana. Nesta seção, foi utilizada a biblioteca Re, que auxilia no trabalho com expressões comuns e coloquiais em texto escrito.

Foi criada uma função chamada “Preprocessing” no código Python desenvolvido, a qual é dividida em pequenos blocos, cada um com seu próprio propósito, a saber:

- Limpeza de *links*, pontos, vírgulas, pontos e outros sinais de pontuação, bem como *hashtags*: remove todos esses caracteres do texto. Para *hashtags*, a alternativa foi remover apenas o sinal de hashtag (#) e manter o conteúdo, já que ele pode conter aspectos. Por exemplo, para a frase: “The #iphone15 is amazing!”, caso a *hashtag* fosse retirada como um todo, seria obtido “The is amazing!”. Somente removendo o caracter especial, a mesma frase ficaria “The iphone15 is amazing!”;
- Limpeza de *tags html*: *links* para outros *sites* são frequentemente encontrados em conteúdos sobre produtos. Este bloco de código remove esses elementos, que poluem o conteúdo do texto minerado;
- Limpeza de menções: embora no YouTube não seja tão comum realizar menções de perfis como em *posts* escritos, é possível que os autores se refiram a perfis próprios em outras redes ou perfis de outras pessoas, iniciando com um @. Nesse bloco, toda a menção é retirada, já que o identificador de uma conta não é de interesse para a análise de aspectos;
- Limpeza de emojis: é muito comum o uso de emojis em conteúdo em redes sociais. Na transcrição, foram observados emojis como “♫” para representar que havia som sem fala. Assim, o bloco de código - que remove os emojis, que não contribuem para o processo de análise de texto - foi mantido.

O código para pré-processamento e limpeza das frases pode ser observado na Figura 12.

4.1.3 Extração de aspectos

A extração de aspectos é um passo crucial para obter resultados consistentes, pois é o momento em que os adjetivos são atribuídos aos aspectos. Para isso, foram utilizadas as

Figura 12 – Pré-processamento

```

1 def Preprocessing(instancia):
2
3     #Limpa links, pontos, vírgulas, ponto e vírgula e traços
4     instancia = re.sub(r"http\S+","",instancia).lower().replace('.','').replace(';','')
5         .replace('-','').replace(':','').replace('#','')
6     #Limpa menções
7     instancia = re.sub(r"@[\s+","",instancia).lower()
8     ##Limpa espaços extras
9     #instancia = re.sub(r' +', ' ',instancia).lower()
10    #Limpa tags
11    instancia = re.sub(r'<.*?>', ' ',instancia).lower()
12    #Limpa emojis
13    emoji_pattern = re.compile("["
14        u"\U0001F600-\U0001F64F" # emoticons
15        u"\U0001F300-\U0001F5FF" # symbols & pictographs
16        u"\U0001F680-\U0001F6FF" # transport & map symbols
17        u"\U0001F1E0-\U0001F1FF" # flags (iOS)
18        u"\U00002500-\U00002BEF" # chinese char
19        u"\U00002702-\U000027B0"
20        u"\U00002702-\U000027B0"
21        u"\U000024C2-\U0001F251"
22        u"\U0001f926-\U0001f937"
23        u"\U00010000-\U0010ffff"
24        u"\u2640-\u2642"
25        u"\u2600-\u2B55"
26        u"\u200d"
27        u"\u23cf"
28        u"\u23e9"
29        u"\u231a"
30        u"\ufe0f" # dingbats
31        u"\u3030"
32        "+", re.UNICODE)
33    instancia = (emoji_pattern.sub(r'', instancia))
34    return(instancia)

```

Fonte: Elaboração própria (2023).

bibliotecas de Python Stanfordnlp, Stanza e NLTK.

Para melhor compreensão do processo de extração de aspectos, é interessante considerar um exemplo, como na seguinte frase: “The sound quality is great but the battery life is very bad”.

O primeiro passo é a *tokenização*, que consiste em processar cada palavra separadamente, como um elemento textual individual. O processo permite dividir uma *string* ou texto em uma lista de *tokens*. Pode-se pensar em um *token* como partes individuais de um elemento maior, isto é, uma palavra é um *token* em uma frase, e uma frase é um *token* em um parágrafo. Essas partes auxiliam na compreensão do contexto ou no desenvolvimento do modelo para o processamento de linguagem natural. A *tokenização* ajuda na interpretação do significado do texto ao analisar a sequência das palavras. Ao aplicar a função “word_tokenize” na frase de exemplo, obtém-se o seguinte resultado: “The”, “sound”, “quality”, “is”, “great”, “but”, “the”, “battery”, “life”, “is”, “very”, “bad”.

A partir da *tokenização*, as palavras recebem uma etiqueta indicando sua classificação gramatical, como Verbo (JJ), Substantivo (NN), Determinante (DT), entre outras. Aplicando a categorização ao exemplo, obtém-se o seguinte resultado: (“the”, “DT”), (“sound”, “NN”), (“quality”, “NN”), (“is”, “VBZ”), (“great”, “JJ”), (“but”, “CC”), (“the”, “DT”), (“battery”,

“NN”), (“life”, “NN”), (“is”, “VBZ”), (“very”, “RB”), (“bad”, “JJ”), (“.”, “.”). A implementação desse processo está detalhada na Figura 13.

Figura 13 – *Tokenização e classificação gramatical*

```

1 taggedList = []
2 for i in listaFrases:
3     listaTemporaria = []
4     for frase in i:
5         txt_list = nltk.word_tokenize(frase)
6         listaTemporaria.append(nltk.pos_tag(txt_list))
7     taggedList.append(listaTemporaria)

```

Fonte: Elaboração própria (2023).

O bloco de código seguinte, conforme ilustrado na Figura 14, é encarregado de unir os substantivos compostos em uma única palavra. De maneira simplificada, ele identifica a ocorrência de dois substantivos em sequência e os une em um único *token*. Com base no exemplo considerado, a sentença se tornaria: “The soundquality is great but the batterylife is very bad”.

Figura 14 – Junção dos substantivos compostos

```

1 compiladoFrases = []
2 for i in taggedList:
3     newwordList = []
4     flag = 0
5     listaSimples = i[0]
6     for i in range(0, len(listaSimples)-1):
7         if(listaSimples[i][1]==“NN” and listaSimples[i+1][1]==“NN”):
8             newwordList.append(listaSimples[i][0]+listaSimples[i+1][0])
9             flag=1
10        else:
11            if(flag==1):
12                flag=0
13                continue
14            newwordList.append(listaSimples[i][0])
15            if(i==len(listaSimples)-2):
16                newwordList.append(listaSimples[i+1][0])
17        finaltxt = ‘’.join(word for word in newwordList)
18        compiladoFrases.append(finaltxt)

```

Fonte: Elaboração própria (2023).

Na sequência, as *stopwords* são eliminadas. *Stopwords* são palavras que não adicionam informações semânticas relevantes, como preposições e conjunções. Geralmente, as palavras mais comuns usadas em um texto são “the”, “is”, “in”, “for”, “where”, “when”, “to”, “at” etc. A remoção dessas palavras é citada na literatura como uma das etapas da análise de texto com ABSA. O código que realiza essa ação é apresentado na Figura 15.

Posteriormente, uma ferramenta da biblioteca Stanza, do Python, é utilizada para identificar a natureza da dependência entre as palavras no texto. No exemplo considerado, teríamos o seguinte resultado: [“the”, “soundquality”, “det”], [“soundquality”, “great”, “nsubj”], [“is”, “great”, “cop”], [“great”, 0, “root”], [“but”, “bad”, “cc”], [“the”, “batterylife”, “det”], [“batterylife”, “bad”, “nsubj”], [“is”, “bad”, “cop”], [“very”, “bad”, “advmod”], [“bad”, “great”, “conj”],

Figura 15 – Remoção de *stopwords*

```

1 new_txt_list_final = []
2 listaSemStopWords = []
3 listaSemStopWordsTagged = []
4 for i in compiladoFrases:
5     stop_words = set(stopwords.words('english'))
6     new_txt_list = nltk.word_tokenize(i)
7     wordsList = [w for w in new_txt_list if not w in stop_words]
8     new_txt_list_final.append(new_txt_list)
9     listaSemStopWords.append(wordsList)
10    listaSemStopWordsTagged.append(nltk.pos_tag(wordsList))

```

Fonte: Elaboração própria (2023).

[“.”, “great”, “punct”]. O bloco de código associado a essa operação pode ser encontrado na Figura 16.

Figura 16 – Identificação das relações de dependência

```

1 nlp = stanza.Pipeline('en') # initialize English neural pipeline
2 count = 0
3 listaDep_node = []
4 for i in compiladoFrases:
5     try:
6         doc = nlp(i)
7         dep_node = []
8         for dep_edge in doc.sentences[0].dependencies:
9             dep_node.append([dep_edge[2].text, dep_edge[0].id, dep_edge[1]])
10        newwordList = new_txt_list_final[count]
11        count = count + 1
12    except:
13        print(f'essa frase foi descartada {i}')
14        count = count + 1
15    for i in range(0, len(dep_node)):
16        try:
17            if (int(dep_node[i][1]) != 0):
18                dep_node[i][1] = newwordList[int(dep_node[i][1]) - 1]
19            except:
20                print(f'essa frase foi descartada {count}')
21    listaDep_node.append(dep_node)
22 print(listaDep_node)

```

Fonte: Elaboração própria (2023).

A relação entre as palavras “the” e “soundquality” foi classificada como “det”, o que significa que uma delas é o sujeito da sentença e a outra é seu determinante. Para conhecer o significado de cada classificação, recomenda-se a consulta ao manual de dependências de Stanford, de Marneffe e Manning (2008). De acordo com os autores, as principais dependências encontradas no processamento de linguagem natural são as apresentadas na Tabela 3.

Por fim, são realizadas associações entre as dependências mapeadas e a classificação grammatical das palavras. Sabe-se que os aspectos são substantivos e o interesse é encontrar o adjetivo que está sendo atribuído ao aspecto, a fim de aplicar a análise de sentimentos. Assim, a principal dependência para este trabalho é “nsubj”, que representa um substantivo funcionando como sujeito da sentença. Portanto, com essa diretriz, as relações procuradas são encontradas, utilizando o código representado na Figura 17. A saída obtida quando o código é aplicado no

Tabela 3 – Principais relações de dependência: definição e exemplos

Relação de dependência	Definição	Exemplo
Root	A relação gramatical “root” aponta para a raiz da frase.	
Cc: Coordination	A coordenação é a relação entre um elemento de uma oração coordenada e a palavra de conjunção coordenativa da oração.	
Det	Um determinante é a relação entre o núcleo de uma sentença e seu determinante.	
Nsubj	Um sujeito nominal é um nominal que atua como sujeito sintático e o protoagente de uma oração. Isso significa que ele ocupa a posição que passa por testes gramaticais típicos para sujeitos, e esse argumento é o mais agentivo, o executor, ou o protoagente da oração.	
Cop	Uma cópula é a relação entre o complemento de um verbo copulativo e o próprio verbo copulativo.	
Conj	Uma conjunção é a relação entre dois elementos conectados por uma conjunção coordenativa, como “e” ou “ou”.	
Advmod	Um modificador adverbial de uma palavra é um advérbio ou frase adverbial (não oracional) que serve para modificar o significado da palavra.	
Punct	Isso é usado para qualquer pontuação em uma oração, se a pontuação estiver sendo mantida nas dependências digitadas.	

Fonte: Adaptado de Marneffe e Manning (2008).

exemplo acima é a seguinte: [“soundquality”, [“great”]], [“batterylife”, [“bad”]].

4.1.4 Análise de sentimentos

Como mencionado anteriormente, a análise de sentimentos nesta pesquisa foi realizada por meio de um método não supervisionado, ou seja, que não requer treinamento prévio para que o código funcione de forma satisfatória. Portanto, a escolha foi utilizar a biblioteca TextBlob em Python, uma vez que ela realiza suas classificações com base em um método de dicionário e não exige a entrada de dados previamente rotulados, além de ser capaz de calcular o grau de subjetividade da frase. Essa última característica é crucial para a integração da abordagem

Figura 17 – Associação semântica

```

1 finalcluster = []
2 ListaDic = []
3 for frasesTagged in featureList:
4     dic = {}
5     for i in frasesTagged:
6         dic[i[0]] = i[1]
7     ListaDic.append(dic)
8 count = 0
9 for frasesClustered in fcluster:
10    clusterIntermediario = []
11    dic = ListaDic[count]
12    for i in frasesClustered:
13        if(dic[i[0]]=="NNN"):
14            clusterIntermediario.append(i)
15    finalcluster.append(clusterIntermediario)
16    count = count + 1

```

Fonte: Elaboração própria (2023).

proposta em um modelo fuzzy MCDM: subjetividade e polaridade serão parâmetros das funções de pertinência *fuzzy* associadas aos termos linguísticos.

Nesta seção do código, foram criadas duas funções para calcular subjetividade e polaridade, respectivamente, como ilustrado na Figura 18.

Figura 18 – Cálculo das funções de polaridade e subjetividade

```

1 def getSubjectivity(text):
2     return TextBlob(text).sentiment.subjectivity
3 def getPolarity(text):
4     return TextBlob(text).sentiment.polarity
5 listaSub = []
6 listaPolaridade = []
7 for i in listaAdjetivos:
8     try:
9         listaSub.append(getSubjectivity(i))
10        listaPolaridade.append(getPolarity(i))
11    except:
12        listaSub.append(0.0)
13        listaPolaridade.append(0.0)
14 dfFinal['Sub'] = listaSub
15 dfFinal['Polaridade'] = listaPolaridade
16 dfFinal

```

Fonte: Elaboração própria (2023).

Essas funções definidas foram aplicadas a todos os adjetivos extraídos na etapa anterior. O resultado final é um quadro de dados com quatro colunas, a saber: Aspecto, Adjetivo, Subjetividade e Polaridade. Além disso, os resultados permitem gerar um nível de importância de uma *feature* para os clientes, calculando a frequência de ocorrência dessa *feature* em comparação com o número total de associações Aspecto-Adjetivo.

4.2 Implementação do sistema de inferência *fuzzy*

A rotina computacional para a técnica FIS foi implementada no *software* MATLAB®, por meio da plataforma *fuzzy toolbox*. Os números *fuzzy*, as funções de pertinência e as de termos

linguísticos do sistema de inferência utilizado no modelo de tomada de decisão proposto são detalhados a seguir.

Para avaliar cada variável antecedente do FIS, foi proposta uma hierarquia de três níveis de termos linguísticos, com base no trabalho de Zanon *et al.* (2021). Os termos diferem de uma variável para outra, isto é, a polaridade, a subjetividade e a importância para as necessidades do cliente serão avaliadas por termos diferentes. Isso é justificado, uma vez que essas variáveis de entrada têm naturezas distintas. Para avaliar a variável de polaridade, os termos propostos são: “negativa”, “neutra” e “positiva”. Para avaliar tanto a subjetividade quanto a importância para as necessidades do cliente, os termos propostos são: “baixa”, “média” e “alta”.

O consequente do FIS é o índice de CPV. Para avaliá-lo, foi proposta uma hierarquia de cinco níveis de termos linguísticos, refletindo a maneira com que a avaliação dos antecedentes nos termos mencionados poderia impactar na percepção de valor do cliente. Portanto, os termos propostos são: “negativo”, “um pouco negativo”, “neutro”, “um pouco positivo”, “positivo”. “Um pouco” busca refletir a influência da subjetividade no CPV. Por exemplo, ao construir a base de regras do primeiro FIS, se a polaridade for “positiva”, a subjetividade for “alta” e a importância para as necessidades do cliente for “média”, então o CPV pode ser modelado como “um pouco positivo”, uma vez que uma alta subjetividade influencia na determinação assertiva da percepção de valor do cliente.

Os números *fuzzy* correspondentes a esses termos linguísticos são apresentados nas Tabelas 4, 5 e 6. Como mostrado nas Figuras 19 e 20, funções de pertinência triangulares superpostas foram definidas tanto para os antecedentes como para os consequentes.

Tabela 4 – Termos linguísticos para avaliar o antecedente “polaridade”

Termos Linguísticos	Número Fuzzy Correspondente
Negativa	(0; 0; 5,0)
Neutra	(0; 5,0; 10,0)
Positiva	(5,0; 10,0; 10,0)

Fonte: Elaboração própria (2023).

Tabela 5 – Termos linguísticos para avaliar os antecedentes “subjetividade” e “importância para as necessidades do cliente”

Termos Linguísticos	Número Fuzzy Correspondente
Baixa	(0; 0; 5,0)
Média	(0; 5,0; 10,0)
Alta	(5,0; 10,0; 10,0)

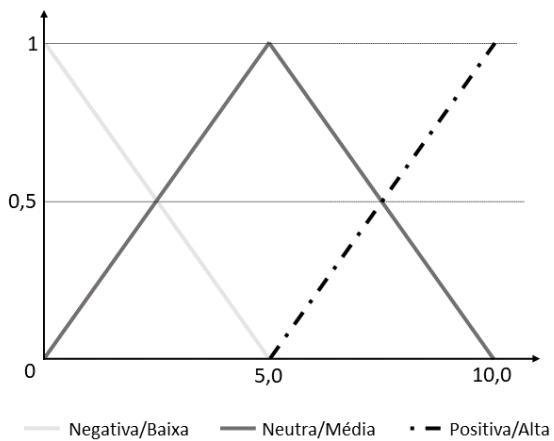
Fonte: Elaboração própria (2023).

Tabela 6 – Termos linguísticos para avaliar o consequente “CPV”

Termos Linguísticos	Número Fuzzy Correspondente
Negativo	(0; 0; 2,5)
Um pouco negativo	(0; 2,5; 5,0)
Neutro	(2,5; 5,0; 7,5)
Um pouco positivo	(5,0; 7,5; 10,0)
Positivo	(7,5; 10,0; 10,0)

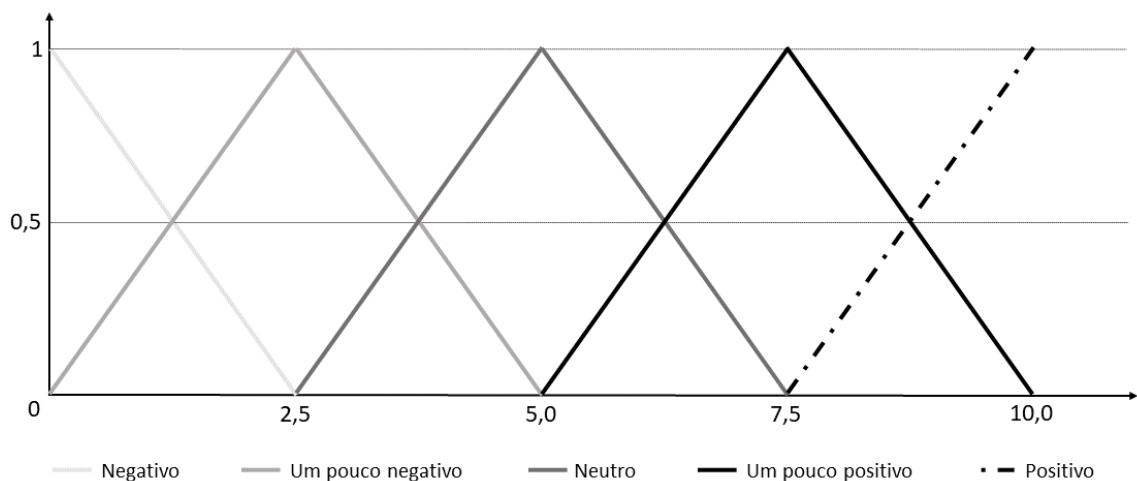
Fonte: Elaboração própria (2023).

Figura 19 – Funções de pertinência dos termos linguísticos das variáveis antecedentes



Fonte: Elaboração própria (2023).

Figura 20 – Funções de pertinência dos termos linguísticos da variável consequente



Fonte: Elaboração própria (2023).

4.3 Implementação do ELECTRE TRI

A implementação computacional do ELECTRE TRI foi realizada no *software* MATLAB®. A seguir, está detalhada a definição dos parâmetros necessários à aplicação, bem como a sequência de código para execução do método.

Neste trabalho, foram fixados os seguintes parâmetros:

- As categorias CT_{h+1} para definir o perfil de risco de um modo de falha associado a um aspecto do produto, a saber: CT_1 indicando um risco inaceitável, CT_2 um risco tolerável e CT_3 um risco aceitável;
- Os perfis b_h ($h = 0, 1, 2, 3$), que são os limites que separam as categorias pré-definidas. Aqui, para cada critério ou fator de risco C_j ($j = 1$, ocorrência; $j = 2$, severidade; $j = 3$, detecção; $j = 4$, índice CPV), tem-se: $\forall j, b_3 = 0$ e $b_0 = 10$; b_1 e b_2 variam conforme a natureza e os dados do problema estudado;
- Os modos de falha A_i ($i = 1, 2, \dots, a$), que dependem do produto estudado, onde a é o número de alternativas do modelo;
- O limiar de indiferença $q_j(b_h)$, que corresponde ao *gap* máximo de desempenho para o qual se mantém a indiferença no fator de risco j entre o modo de falha A_i e o perfil b_h . Neste modelo, adota-se $q_j = [0, 05; 0, 05; 0, 05; 0, 05]$, $\forall b_h$, com base em valores encontrados na literatura (ARANTES *et al.*, 2022);
- O limiar de preferência $p_j(b_h)$, que corresponde ao *gap* mínimo de desempenho para o qual se aplica a preferência estrita no fator de risco j entre o modo de falha A_i e o perfil b_h . Neste trabalho, assume-se $p_j = [0, 5; 0, 5; 0, 5; 0, 5]$, $\forall b_h$, de acordo com valores estabelecidos na literatura (ARANTES *et al.*, 2022);
- O limiar de veto $v_j(b_h)$, que significa a diferença que anula completamente a relação de sobreclassificação. Neste caso, assume-se $v_j = [0, 01; 0, 01; 0, 01; 0, 01]$, $\forall b_h$, conforme valores utilizados na literatura (ARANTES *et al.*, 2022);
- O nível de corte λ , que indica a situação de preferência entre A_i e o perfil b_h . No trabalho, o valor utilizado foi $\lambda = 1$;
- O peso de cada critério $w_j = [0, 25; 0, 25; 0, 25; 0, 25]$, igual para todos os critérios nesse modelo, a fim de não enviesar os resultados;
- $c = 3$ o número de categorias e $b = c - 1 = 2$ o número de limites com valores a definir.

Após todas as especificações, os cálculos foram performados para cada modo de falha conforme detalhado na Subseção 3.4.1:

- (I) Cálculo das concordâncias: parcial $c_j(a, b_h)$ (Figura 21), total $c(a, b_h)$ (Figura 22), parcial $c_j(b_h, a)$ e total $c(b_h, a)$, sendo as duas últimas análogas às respectivas anteriores;

Figura 21 – Cálculo da concordância parcial $c_j(a, b_h)$

```

1 som=1;
2
3 contb=1;
4
5 y=b*a;
6
7 while som<=y
8     lb=bh(contb,:);
9     for k=1:a
10        la = xa(k,:);
11        % INVERT HERE FOR c(bh, a)
12        r=lb-la;
13        c1(som,:)=r;
14        som=som+1;
15    end
16    contb=contb+1;
17 end
18
19 c1;
20
21 %Partial concordance calculation:
22
23 Cab=zeros(y,m);
24
25 for i=1:y
26     for j=1:m
27         if c1(i,j)>=p(j)
28             Cab(i,j)=0;
29         elseif c1(i,j)< q(j)
30             Cab(i,j)=1;
31         else
32             Cab(i,j)=(p(j)-c1(i,j))/(p(j)-q(j));
33         end
34     end
35 end
36
37 Cab;

```

Fonte: Elaboração própria (2023).

Figura 22 – Cálculo da concordância total $c(a, b_h)$

```

1 Cgab=zeros(y,1);
2
3 for i=1:y
4     for j=1:m
5         Cgab(i,1)=Cgab(i,1)+(Cab(i,j)*w(j))/sum(w);
6     end
7 end
8
9 Cgab;

```

Fonte: Elaboração própria (2023).

- (II) Cálculo dos índices de discordância $d_j(a, b_h)$ (Figura 23) e $d_j(b_h, a)$ (análogo ao primeiro);

Figura 23 – Cálculo da discordância $d_j(a, b_h)$

```

1 som=1;
2 contb=1;
3 y=b*a;
4
5 while som<=y
6     lb=bh(contb,:);
7     for k=1:a
8         la = xa(k,:);
9         % INVERT HERE FOR d(bh, a)
10        r=lb-la;
11        d1(som,:)=r;
12        som=som+1;
13    end
14    contb= contb+1;
15 end
16 d1;
17 %Discordance calculation d(a,bh):
18 Dab=zeros(y,m);
19 for i=1:y
20     for j=1:m
21         if d1(i,j)< p(j)
22             Dab(i,j)=0;
23         elseif d1(i,j)>= v(j)
24             Dab(i,j)=1;
25         else
26             Dab(i,j)=(-p(j)+ d1(i,j)) / (v(j)-p(j));
27         end
28     end
29 end
30 Dab;

```

Fonte: Elaboração própria (2023).

(III) Cálculo dos índices de credibilidade $\sigma(a, b_h)$ (Figura 24) e $\sigma(b_h, a)$ (análogo ao primeiro);

Figura 24 – Cálculo do índice de credibilidade $\sigma(a, b_h)$

```

1 prod=1;
2 sigmaab = Cgab;
3
4 for i=1:y
5     for j=1:m
6         if Dab(i,j) > Cgab(i,1)
7             for k=1:m
8                 prod=prod*(1-Dab(i,k)) / (1-Cgab(i,1));
9             end
10            sigmaab(i,1) = Cgab(i,1)*prod;
11            prod=1;
12        end
13    end
14 end
15 sigmaab;

```

Fonte: Elaboração própria (2023).

(IV) Cálculo das relações de preferência de acordo com o nível de corte λ , comparando $\sigma(a, b_h)$ e $\sigma(b_h, a)$ (Figura 25);

Figura 25 – Cálculo das relações de preferência

```

1 prod=1;
2 sigmaab = Cgab;
3
4 for i=1:y
5   for j=1:m
6     if Dab(i,j) > Cgab(i,1)
7       for k=1:m
8         prod=prod*(1-Dab(i,k))/(1-Cgab(i,1));
9       end
10      sigmaab(i,1) = Cgab(i,1)*prod;
11      prod=1;
12    end
13  end
14 end
15 sigmaab;

```

Fonte: Elaboração própria (2023).

(V) Definição das categorias segundo o procedimento pessimista (Figura 26) e otimista (Figura 27).

Figura 26 – Classificação em categorias pelo procedimento pessimista

```

1 %Pessimistic procedure
2 u=1;
3 x=1;
4 classep=zeros(b+1,1);
5
6 for i=1:a
7   classepa(i,1)=cls(1,1); %begin in the smaller category
8 end
9 for i=1:a
10   for j=u:a:y
11     if comp2(j,1) == 3
12       classep(i,1)=cls(x,1);
13       x=x+1;
14     if classep(i,1) < classepa(i,1);
15       classep(i,1) = classepa(i,1);
16     end
17     classepa(i,1)=classep(i,1);
18   elseif comp2(j,1) == 4
19     classep(i,1)=cls(x,1);
20     x=x+1;
21     if classep(i,1) < classepa(i,1);
22       classep(i,1)=classepa(i,1);
23     end
24     classepa(i,1)=classep(i,1);
25   else
26     classep(i,1)=cls(x+1,1);
27     x=x+1;
28     classepa(i,1)=classep(i,1);
29   end
30   end
31   x=1;
32   u=u+1;
33 end
34 classep;

```

Fonte: Elaboração própria (2023).

Figura 27 – Classificação em categorias pelo procedimento otimista

```

1 %Optimistic procedure
2 u=1;
3 x=1;
4 classeo=zeros (b+1,1);
5
6 for i=1:a
7     classeoa(i,1)=cls(1,1); %begin in the smaller category
8 end
9 for i=1:a
10    for j=u:a:y
11        if comp2(j,1) == 3
12            classeo(i,1)= cls(x,1);
13            x=x+1;
14            if classeo(i,1) < classeoa(i,1)
15                classeo(i,1)= classeoa i,1);
16            end
17            classeoa (i,1)=classeo(i,1);
18        else
19            classeo(i,1)=cls(x+1,1);
20            x=x+1;
21            classeoa (i,1)=classeo(i,1);
22        end
23    end
24    x=1;
25    u=u+1;
26 end
27 classeo;

```

Fonte: Elaboração própria (2023).

5 EXEMPLO DE APLICAÇÃO

O código computacional detalhado no Capítulo 4 possui flexibilidade para ser aplicado em vários contextos. Para fins ilustrativos e para destacar o potencial prático da abordagem proposta, este capítulo apresenta uma aplicação ilustrativa, realizada no campo dos *smartphones*, considerando um dos principais produtos do mercado: o iPhone 15 da Apple.

Esse contexto foi escolhido por quatro razões principais:

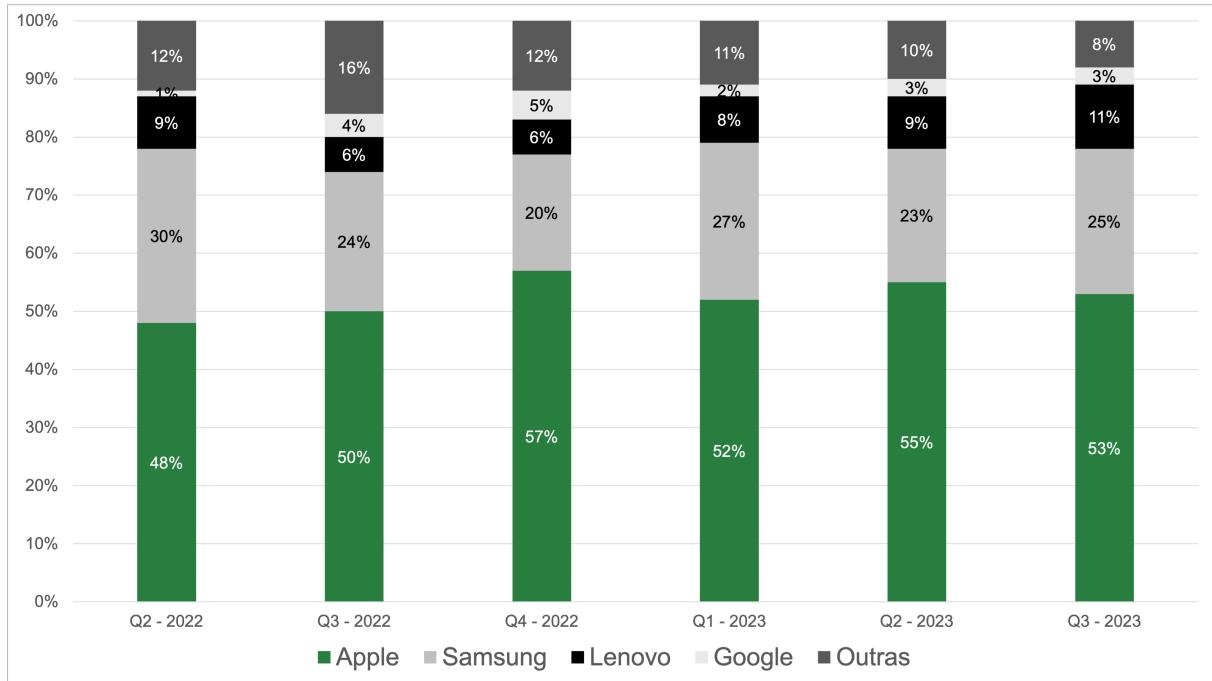
- O produto possui características bem definidas, facilmente encontradas no *site* da empresa ou no manual do usuário;
- O produto é utilizado por um grande número de usuários, despertando interesse público e impulsionando a publicação de conteúdo relacionado nas redes sociais;
- A literatura possui um *corpus* bem-estabelecido em torno de *smartphones* como objeto de pesquisa (SIVAKUMAR; UYYALA, 2021), além de apresentar aplicações de FMEA em modelos similares, como o iPhone 11 (KADËNA *et al.*, 2022);
- O iPhone 15 é o modelo de *smartphone* de última geração da Apple no momento.

A Apple, empresa responsável pelo *design* e fabricação do iPhone, é líder no segmento. Um relatório publicado por Team Counterpoint (2023) mostra que a empresa detém metade da participação de mercado nos Estados Unidos, como mostra a Figura 28, considerando o terceiro trimestre de 2023.

É interessante notar que a Apple oferece apenas o iPhone como *smartphone*, com poucas variações entre os modelos, enquanto a Samsung - principal concorrente da Apple, como mostra a Figura 28 - possui várias linhas de modelos de *smartphones* com os mais diversos níveis de sofisticação e preços, sendo o Galaxy S uma das ofertas de maior valor, em níveis semelhantes aos do iPhone.

As *features* escolhidas para a análise foram: Áudio & Conectividade, Bateria, Câmera, Desempenho, *Design*, *Display* e Preço. Esses atributos são explicitamente mencionados nos materiais promocionais da marca. Além disso, são algumas das principais características abordadas em trabalhos acadêmicos que consideram o contexto dos *smartphones* (SIVAKUMAR; UYYALA, 2021). Por se tratarem de diferentes *features* identificadas, o uso da análise de sentimento com base em aspectos é mais adequado em comparação com a abordagem tradicional de análise de sentimento. Isso ocorre porque avaliar apenas a polaridade de um vídeo relacionado a esse *smartphone* geralmente não seria representativo, já que um único vídeo costuma abordar vários módulos do produto.

Figura 28 – *Market share* das vendas de *smartphones* por marca: Estados Unidos



Fonte: Team Counterpoint (2023).

5.1 Análise de sentimentos baseada em aspectos

5.1.1 Mineração de dados

Para obter os dados do YouTube, é importante estabelecer algumas regras a fim de construir uma base de dados consistente. Assim, foram selecionados os 50 primeiros vídeos encontrados a partir da *string* de busca “iphone 15 review” que, ordenados por contagem de visualizações decrescente, atendessem aos seguintes critérios:

- (I) Língua inglesa como língua original da gravação;
- (II) Vídeos com mais de 4 minutos;
- (III) Vídeos que contivessem apenas conteúdo sobre a série de iPhones 15, evitando outras marcas e outros modelos da mesma marca;
- (IV) Vídeos que contivessem análise autoral de pelo menos uma *feature* do produto, evitando vídeos sobre a presença em eventos, *unboxing*, vídeos patrocinados ou elaborados pela própria marca e outros sem avaliação direta do produto.

Assim, obteve-se um volume de 9168 frases para o iPhone 15, como mostrado na Figura 29. Observa-se que as frases do exemplo, correspondentes ao início e ao fim de um vídeo, não revelam aspectos relevantes no contexto dos *smartphones*. Isso era esperado e acontece porque, em vídeos de *reviews* no YouTube, parte do tempo é dedicado à introdução, despedida e interação

com o público. Entretanto, essas frases de menor interesse serão removidas da análise após a ABSA, não impactando os resultados de polaridade e subjetividade.

Figura 29 – Resultados da mineração para o iPhone 15

9168	
	sentence
0	You know what's funny
1	When there's not that many changes, it really ...
2	Have you ever listened to a car reviewer descr...
3	Like this is a car that's looked more or less ...
4	And literally every time you watch or read a r...
...	...
9163	And he already has over two million subscribers
9164	So give him a look
9165	You may like it
9166	And it could be very useful
9167	Take care of yourself and each other

9168 rows × 1 columns

Fonte: Elaboração própria (2023).

5.1.2 Pré-processamento

Em seguida, a função de pré-processamento foi aplicada a cada uma das linhas do banco de dados construído, e o resultado foi armazenado em uma nova coluna no quadro de dados, chamada “preprocessed”. Na Figura 30, é possível ver a conversão de letras maiúsculas para minúsculas, por exemplo.

Figura 30 – Resultados do pré-processamento para o iPhone 15

	sentence	preprocessed
0	You know what's funny	you know what's funny
1	When there's not that many changes, it really ...	when there's not that many changes, it really ...
2	Have you ever listened to a car reviewer descr...	have you ever listened to a car reviewer descr...
3	Like this is a car that's looked more or less ...	like this is a car that's looked more or less ...
4	And literally every time you watch or read a r...	and literally every time you watch or read a r...
...
9163	And he already has over two million subscribers	and he already has over two million subscribers
9164	So give him a look	so give him a look
9165	You may like it	you may like it
9166	And it could be very useful	and it could be very useful
9167	Take care of yourself and each other	take care of yourself and each other

9168 rows × 2 columns

Fonte: Elaboração própria (2023).

5.1.3 Extração de aspectos

Durante a extração de aspectos, alguns resultados relevantes podem ser destacados. O primeiro está representado na Figura 31, onde as classificações das relações entre as palavras são identificadas.

Figura 31 – Um exemplo de identificação de dependência nas frases mineradas

```
print(listaDep_node)
['photos', 'worse', 'nsubj'], [',', 'photos', 'punct'], ['just', 'get', 'advmod'], ['before', 'get', 'mark'], ['you', 'get', 'nsubj'], ['get', 'worse', 'advcl']
```

Fonte: Elaboração própria (2023).

A classificação gramatical das palavras também é essencial para a extração de aspectos e pode ser observada na Figura 32. Note que a lista nesta figura contém apenas as palavras-chave da frase, uma vez que as chamadas *stopwords* já foram removidas.

Figura 32 – Um exemplo de classificação gramatical nas frases mineradas

```
print(featureList)
['build', 'NN'], ['new', 'JJ'], ['port', 'NN'], ['bottom', 'NN'], ['usb', 'JJ'], ['typec', 'NN'], ['big', 'JJ'], ['difference', 'NN'], ['people', 'NNS'], ['gadgets', 'NNS']
```

Fonte: Elaboração própria (2023).

Após as classificações e associações, obtém-se um agrupamento com os aspectos identificados e suas possíveis atribuições. Na Figura 33, observa-se que a associação entre Aspecto e Adjetivos não ocorre de maneira perfeita, algo já esperado devido à complexidade de interpretar a linguagem humana em redes sociais. Mais adiante, será aplicado mais um filtro que selecionará apenas as relações que possuem uma relação substantivo-adjetivo de valor.

Figura 33 – Um exemplo de clusterização final na extração de aspectos das frases mineradas

```
print(fcluster)
['new', ['iphone', 'colors']], ['colors', ['new', 'fun', 'get']]
```

Fonte: Elaboração própria (2023).

A partir do agrupamento ilustrado na Figura 33, são criadas duas listas resumidas no quadro de dados apresentado na Figura 34. Este quadro de dados exibe uma coluna de Aspectos e outra de Adjetivos. As relações ocorrem entre as palavras dentro da mesma linha.

5.1.4 Análise de sentimentos

As funções para calcular a subjetividade e a polaridade são aplicadas para cada linha da coluna de Adjetivos. Os resultados são apresentados nas duas últimas colunas da Figura 35.

Figura 34 – Resultado da extração de aspectos

	Aspectos	Adjetivos	:
0		know	you
1		glass	magnifying
2		glass	puts
3	generationporsche		latest
4	generationporsche	describe	
...
27197		carter	flossie
27198		channel	tech
27199		channel	has
27200		look	give
27201		care	take

27202 rows x 4 columns

Fonte: Elaboração própria (2023).

Figura 35 – Resultados iniciais da análise de sentimentos

	Aspectos	Adjetivos	Sub	Polaridade
0		know	you	0.0
1		glass	magnifying	0.0
2		glass	puts	0.0
3	generationporsche		latest	0.9
4	generationporsche	describe	0.0	0.0
...
27197		carter	flossie	0.0
27198		channel	tech	0.0
27199		channel	has	0.0
27200		look	give	0.0
27201		care	take	0.0

27202 rows x 4 columns

Fonte: Elaboração própria (2023).

Entretanto, é evidente que existem muitas relações sem valor, em que as palavras que estão na coluna de Adjetivos não são efetivamente adjetivos. Para aprimorar os resultados, as linhas que não apresentam nenhuma indicação de polaridade são removidas, e o resultado pode ser visualizado na Subfigura 36a. Portanto, a saída final consiste em 4009 associações para o iPhone 15. Esse quadro de dados é utilizado para criar gráficos que aprimorarão a análise dos resultados. Dessa forma, serão aplicados mais filtros para resumir os dados e destacar as *features* relevantes de acordo com a literatura e as divulgações da marca (exemplo na Subfigura 36b).

Figura 36 – Resultados finais da análise de sentimentos para o iPhone 15

	Aspectos	Adjetivos	Sub	Polaridade		Aspectos	Adjetivos	Sub	Polaridade	
3	generationporsche	latest	0.900000	0.500000		94	design	clearly	0.383333	0.100000
7	generation	new	0.454545	0.136364		124	iphone	dark	0.400000	-0.150000
9	time	single	0.214286	-0.071429		224	chip	new	0.454545	0.136364
16	time	single	0.214286	-0.071429		225	chip	powerful	1.000000	0.300000
19	formula	developed	0.300000	0.100000		255	iphone	great	0.750000	0.800000
...		266	iphone	new	0.454545	0.136364
27176	shout	special	0.571429	0.357143		298	chip	new	0.454545	0.136364
27177	stream	new	0.454545	0.136364		312	chip	new	0.454545	0.136364
27178	shout	special	0.571429	0.357143		347	chip	more	0.500000	0.500000
27181	shout	special	0.571429	0.357143		413	camera	primary	0.500000	0.400000
27183	thing	more	0.500000	0.500000	4009 rows x 4 columns					

(a)

(b)

Fonte: Elaboração própria (2023).

5.1.5 Sumarização dos dados

O *dataframe* contendo as colunas de Aspecto, Adjetivo, Polaridade e Subjetividade, apresentadas na Figura 36, foi convertido para o formato de arquivo CSV e carregado no Microsoft Excel. Em seguida, ele foi estratificado nas categorias das sete *features* do produto definidas no início deste capítulo. Para a categorização dos dados nos atributos, foi realizada uma classificação automática simples, cruzando as características com os aspectos extraídos, somada a uma classificação manual e detalhada realizada na sequência, abordando os aspectos individualmente. No caso da característica “bateria”, por exemplo, a abordagem automática consegue identificar todas as variações que incluem a palavra “battery”, como “batterylife”. Porém, além disso, analisando os aspectos manualmente, podem ser percebidos registros contendo a palavra “power” ou “charge” associados ao atributo em questão. Portanto, a análise combinada é essencial para identificar outras raízes de palavras correlatas. Outro exemplo é o caso do aspecto de desempenho: as variações vão além da palavra “performance”, incluindo termos como “speed” e “chip”. Também foi criada uma categoria adicional, além das sete características, que inclui aspectos relacionados ao *smartphone* de forma geral, sem estabelecer atributos específicos; essa categoria foi denominada “Dispositivo”. Nesta etapa, aspectos fora do escopo de aplicação foram descartados.

A quantidade de adjetivos associada a cada um dos atributos selecionados pode ser observada na Tabela 7.

A Tabela 8 mostra a impressão geral do iPhone 15 baseado no conteúdo analisado neste TCC.

As Figuras 37 a 43 apresentam os resultados indicando quais adjetivos e suas respectivas frequências foram atribuídos a cada um dos sete aspectos.

Tabela 7 – Número de adjetivos relacionados aos aspectos estudados

Atributos	Adjetivos - iPhone 15
Áudio & Conectividade	40
Bateria	111
Câmera	477
Desempenho	164
<i>Design</i>	396
<i>Display</i>	106
Preço	15

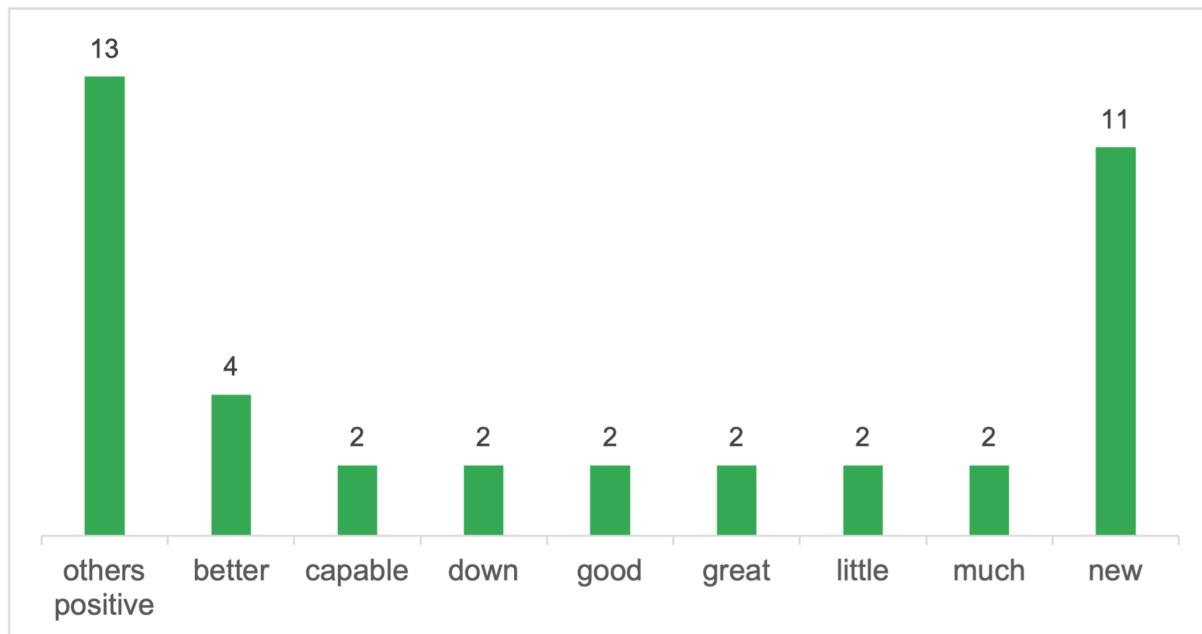
Fonte: Elaboração própria (2023).

Tabela 8 – Impressões gerais do iPhone 15

Índice	Média	Desvio padrão
Subjetividade	0,52	0,22
Polaridade	0,25	0,32

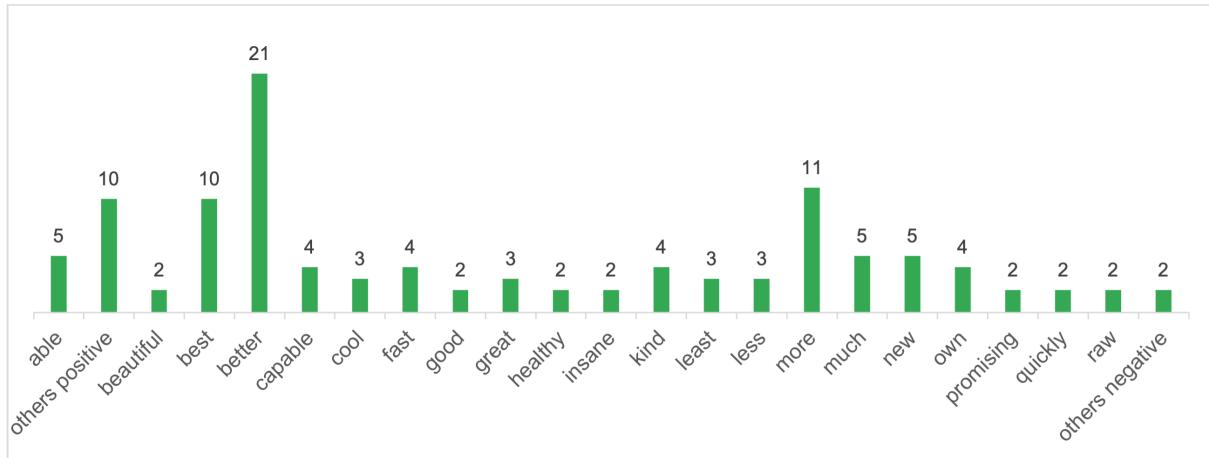
Fonte: Elaboração própria (2023).

Figura 37 – Resultados para iPhone 15: Áudio e Conectividade



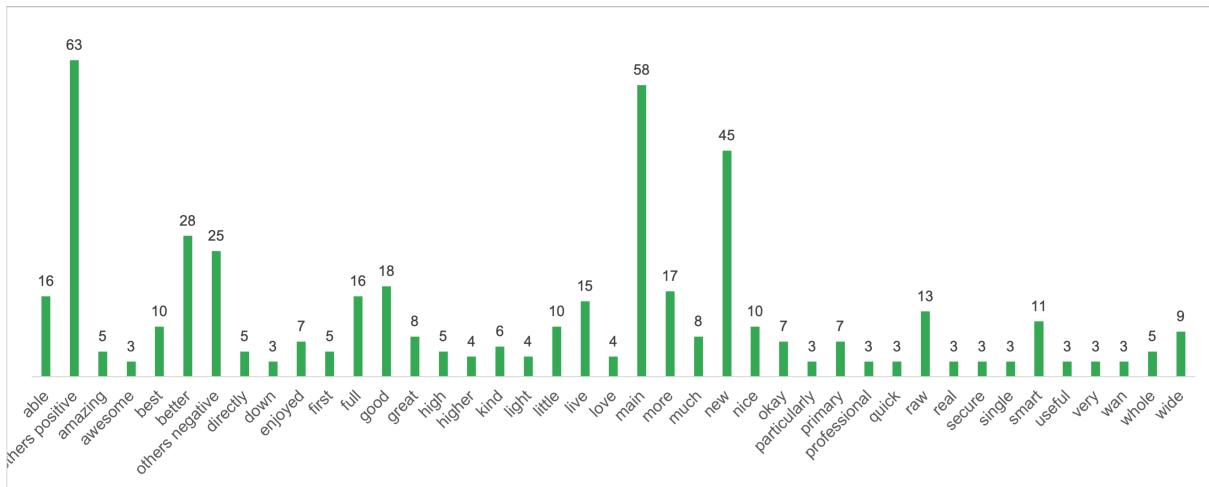
Fonte: Elaboração própria (2023).

Figura 38 – Resultados para iPhone 15: Bateria



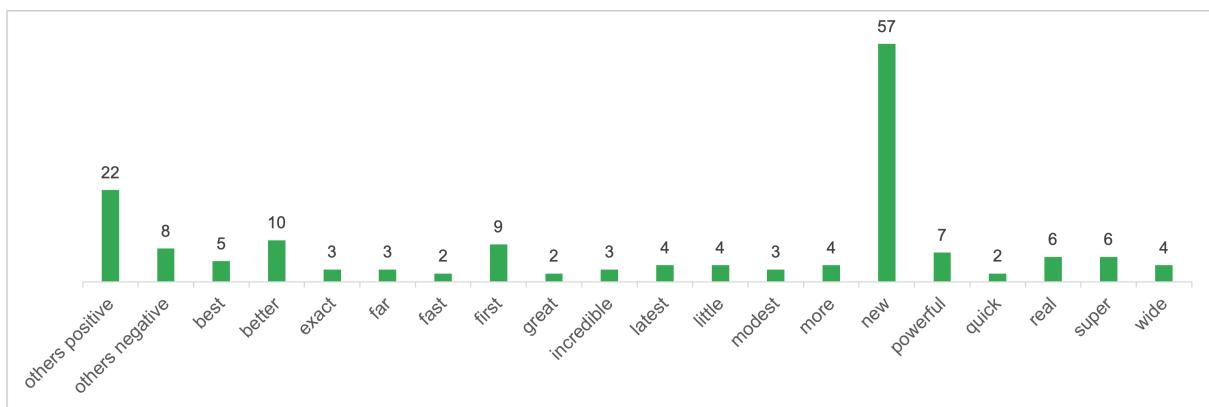
Fonte: Elaboração própria (2023).

Figura 39 – Resultados para iPhone 15: Câmera

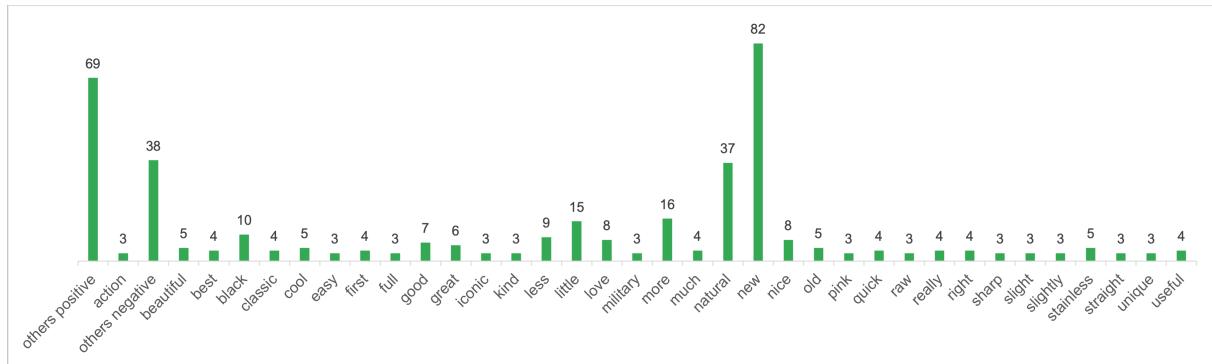


Fonte: Elaboração própria (2023).

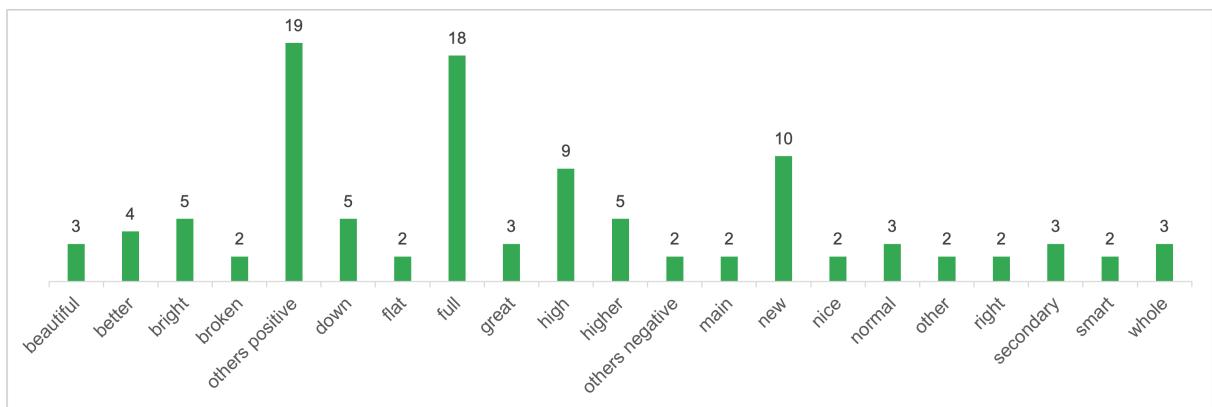
Figura 40 – Resultados para iPhone 15: Desempenho



Fonte: Elaboração própria (2023).

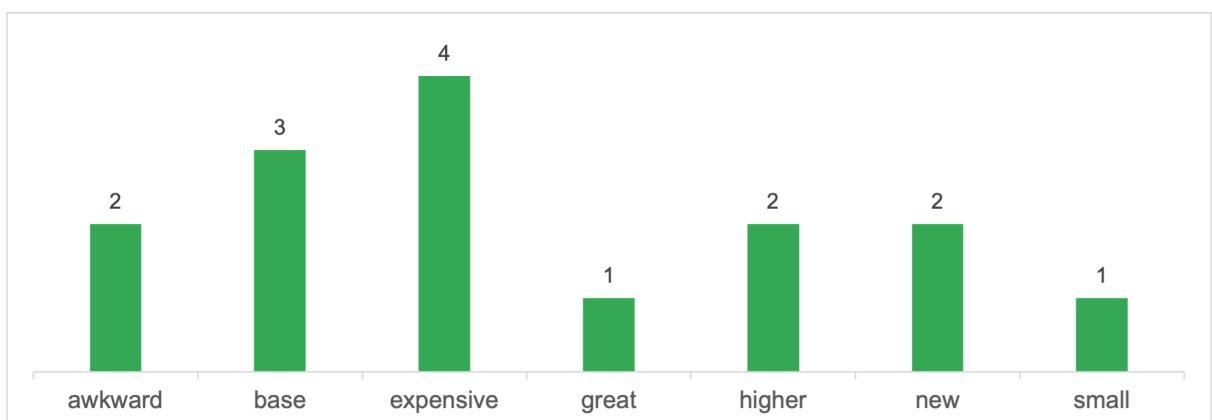
Figura 41 – Resultados para iPhone 15: *Design*

Fonte: Elaboração própria (2023).

Figura 42 – Resultados para iPhone 15: *Display*

Fonte: Elaboração própria (2023).

Figura 43 – Resultados para iPhone 15: Preço



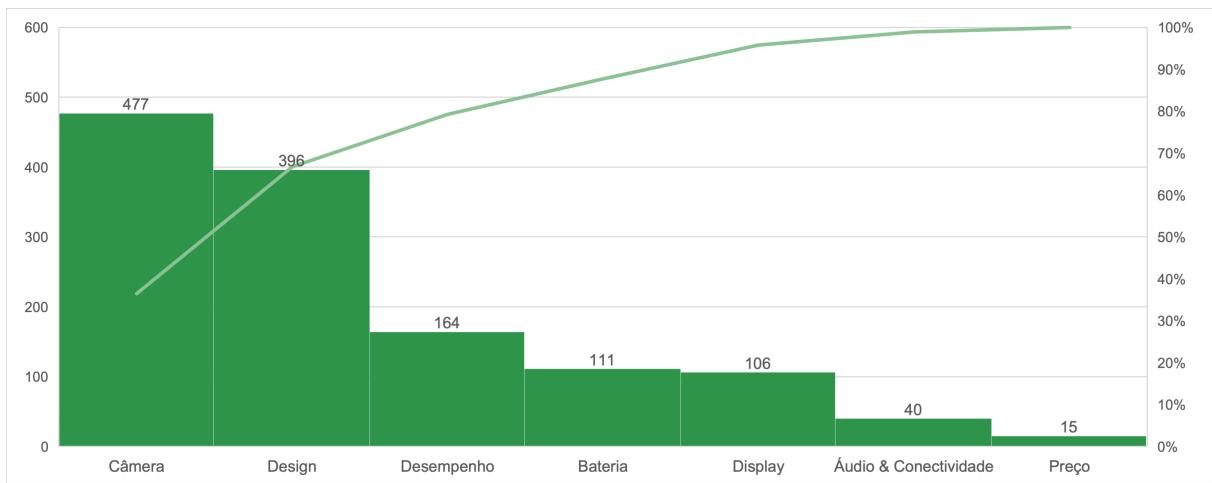
Fonte: Elaboração própria (2023).

Em relação à quantidade de resultados, observa-se uma diferença significativa ao comparar o número de frases transcritas (9168) com o número de combinações válidas de Aspectos-

Adjetivo (4009). Esses números indicam que, a cada duas frases, menos de uma relação válida é encontrada, o que significa que mais da metade dos textos não contêm conteúdo relevante. Isso é esperado devido à natureza da rede social e de vídeos de influenciadores, nos quais nem todos os textos são avaliações do produto, muitos deles podendo não expressar nenhum sentimento relacionado.

Ao somar as menções para Câmera, *Design* e Desempenho, obtém-se cerca de 80% das relações aspecto-adjetivo entre o total, como ilustrado na Figura 44. Esse resultado está alinhado com a evolução dos celulares e as estratégias adotadas pela Apple no último lançamento.

Figura 44 – Quantidade de citações por *feature* e representatividade em % do total acumulado



Fonte: Elaboração própria (2023).

As redes sociais passaram por transformações ao longo do tempo, e os formatos atuais têm como principal atrativo a publicação de fotos e vídeos, como podemos observar no YouTube, Instagram e TikTok, que estão entre os aplicativos mais utilizados em todo o mundo. A tendência desses aplicativos está cada vez mais associada à câmera do *smartphone*, permitindo que os usuários gerem conteúdo visual e tornando-a uma das ferramentas mais utilizadas entre as funcionalidades desses produtos (ZANON, 2022).

Alinhadas às tendências do mercado, as empresas estão investindo intensamente no desenvolvimento de câmeras aprimoradas e na divulgação dessas melhorias geração após geração. No *site* oficial do iPhone 15 (APPLE, 2023), um grande enfoque é oferecido às câmeras e suas tecnologias, como pode ser visto na Figura 45. Por meio do *site*, fica evidente que essa característica é um dos carros-chefe do aparelho.

Além disso, houve um investimento significativo em *design* para esse lançamento, oferecendo melhorias relevantes relacionadas à chamada *dynamic island*, ao uso de titânio como material de revestimento e à adesão ao cabo USB-C como porta de carregamento. O mesmo vale para o atributo “Desempenho”, pois o iPhone 15 utiliza o novo chip A16 Bionic, cuja GPU é até

Figura 45 – Enfoque às câmeras no website oficial do iPhone 15



Fonte: Apple (2023).

40% mais rápida que a do iPhone 12 (APPLE, 2023). Assim, é uma característica em alta e com grande probabilidade de ser comentada.

A Tabela 9 apresenta um compilado dos resultados da abordagem de Análise de Sentimento Baseada em Aspectos utilizando o TextBlob. Ela mostra a percepção do cliente em relação às características, individualmente, medida pelo índice de polaridade; além disso, apresenta o índice de subjetividade associado à medida de polaridade.

Tabela 9 – Subjetividade e polaridade médias por aspecto

Atributo	Subjetividade	Polaridade
Áudio & Conectividade	0,5549	0,3368
Bateria	0,5328	0,4084
Câmera	0,5041	0,2902
Desempenho	0,5336	0,2482
<i>Design</i>	0,4910	0,1790
<i>Display</i>	0,5481	0,2521
Preço	0,7239	-0,2852

Fonte: Elaboração própria (2023).

Observa-se que todas as polaridades são positivas, exceto o preço, o que está de acordo com o valor geral observado na Tabela 8. Além disso, todos as classificações apresentam um grau de subjetividade relevante, o que é natural em se tratando da extração de dados de redes sociais. Curiosamente, mesmo com o enfoque da Apple no *design* para a 15^a geração, esse aspecto é um dos menos positivos. Isso pode acontecer por imprecisões ligadas à implementação da ABSA (por exemplo, o uso da cor “black” como adjetivo leva à atribuição de uma polaridade -0,17), mas também por uma falta de alinhamento entre o valor percebido pelo cliente e o valor percebido pela empresa. Por outro lado, a bateria apresenta a polaridade mais positiva, mesmo não havendo mudanças de tempo de duração em relação à geração anterior. Analisando os principais elementos que aumentam a polaridade, percebe-se que o mais importante é a palavra “better”, que mostra uma melhoria relativa. Assim, mais uma vez é fundamental destacar a diferença entre especificações técnicas reais do produto e percepção do usuário.

5.2 Sistema de inferência *fuzzy*

Os valores de subjetividade e polaridade serão *inputs* para o FIS, além de uma nova variável baseada na Tabela 7: a importância para as necessidades do cliente (ICN). Essa última pode ser calculada para cada característica pela proporção de associações Aspecto-Adjetivo em comparação com o número total de associações Aspecto-Adjetivo. A Tabela 10, portanto, apresenta os valores de subjetividade, polaridade e importância para as necessidades do cliente para cada aspecto, todos convertidos para uma escala de 0 a 10. Esse processo é fundamental, pois todos os valores dos antecedentes e consequentes de qualquer FIS do modelo proposto serão apresentados nessa escala, para torná-los comparáveis.

Tabela 10 – Subjetividade, polaridade e importância para as necessidades do cliente por aspecto

Atributo	Subjetividade	Polaridade	Importância para as necessidades do cliente
Áudio & Conectividade	5,55	6,68	0,31
Bateria	5,33	7,04	0,85
Câmera	5,04	6,45	3,64
Desempenho	5,34	6,24	1,25
<i>Design</i>	4,91	5,89	3,03
<i>Display</i>	5,48	6,26	0,81
Preço	7,24	3,57	0,11

Fonte: Elaboração própria (2023).

O sistema produz como saída uma variável chamada Índice de Valor Percebido pelo Cliente (CPV). Para isso, ele precisa dos números *fuzzy* de entrada e da base de regras. Esta, por sua vez, depende muito da aplicação, já que as relações “se-então” devem capturar as percepções dos *stakeholders*. Portanto, sua construção será detalhada conforme a Tabela 11.

A base de regras para calcular o índice de CPV consiste em 27 regras, que devem refletir as percepções do cliente em relação à interação entre os antecedentes (polaridade, subjetividade e importância para as necessidades do cliente). O valor total resulta da combinação de 3 variáveis de entrada com 3 termos linguísticos para sua avaliação ($3^3 = 27$). Por exemplo, se a polaridade for negativa - ou seja, o cliente expressa um sentimento negativo em relação à característica -, a subjetividade for baixa e a importância para as necessidades do cliente for baixa, o consequente CPV seria “um pouco negativo”. Isso se justifica pois, apesar de ter um sentimento negativo com baixa subjetividade, a importância da característica é baixa, o que diminui a percepção de valor do aspecto.

A máquina de inferência processa os *inputs* da Tabela 10 e, considerando a base de regras, retorna o valor defuzzificado do índice de CPV para cada característica, como mostra a Tabela 12. Este resultado, que é uma entrada para a etapa seguinte, reflete como a percepção do cliente pode ser incluída no processo de tomada de decisão em gestão de modos de falhas.

Tabela 11 – Base de regras do sistema de inferência *fuzzy*

SE	Polaridade	E	Subjetividade	E	ICN	ENTÃO	CPV
1	Negativa	E	Baixa	E	Baixa	ENTÃO	Um pouco negativo
2	Neutra	E	Baixa	E	Baixa	ENTÃO	Neutro
3	Positiva	E	Baixa	E	Baixa	ENTÃO	Um pouco positivo
4	Negativa	E	Média	E	Baixa	ENTÃO	Um pouco negativo
5	Neutra	E	Média	E	Baixa	ENTÃO	Neutro
6	Positiva	E	Média	E	Baixa	ENTÃO	Um pouco positivo
7	Negativa	E	Alta	E	Baixa	ENTÃO	Um pouco negativo
8	Neutra	E	Alta	E	Baixa	ENTÃO	Neutro
9	Positiva	E	Alta	E	Baixa	ENTÃO	Um pouco positivo
10	Negativa	E	Baixa	E	Média	ENTÃO	Negativo
11	Neutra	E	Baixa	E	Média	ENTÃO	Neutro
12	Positiva	E	Baixa	E	Média	ENTÃO	Positivo
13	Negativa	E	Média	E	Média	ENTÃO	Um pouco negativo
14	Neutra	E	Média	E	Média	ENTÃO	Neutro
15	Positiva	E	Média	E	Média	ENTÃO	Um pouco positivo
16	Negativa	E	Alta	E	Média	ENTÃO	Um pouco negativo
17	Neutra	E	Alta	E	Média	ENTÃO	Neutro
18	Positiva	E	Alta	E	Média	ENTÃO	Um pouco positivo
19	Negativa	E	Baixa	E	Alta	ENTÃO	Negativo
20	Neutra	E	Baixa	E	Alta	ENTÃO	Neutro
21	Positiva	E	Baixa	E	Alta	ENTÃO	Positivo
22	Negativa	E	Média	E	Alta	ENTÃO	Negativo
23	Neutra	E	Média	E	Alta	ENTÃO	Neutro
24	Positiva	E	Média	E	Alta	ENTÃO	Positivo
25	Negativa	E	Alta	E	Alta	ENTÃO	Negativo
26	Neutra	E	Alta	E	Alta	ENTÃO	Neutro
27	Positiva	E	Alta	E	Alta	ENTÃO	Positivo

Fonte: Elaboração própria (2023).

Nota-se que, apesar das discrepâncias nos valores iniciais, o valor percebido pelo cliente é próximo para todos os aspectos. Isso indica que, devido à subjetividade, à natureza não absoluta das classificações e ao tipo de produto analisado, opiniões e percepções de valores extremas de um produto ou de seus aspectos - tanto positivas como negativas - tendem a ser evitadas.

As superfícies nas Figuras 46 e 47 mostram como cada cenário possível de interação entre os antecedentes se reflete no valor do CPV. Elas proporcionam aos tomadores de decisão a

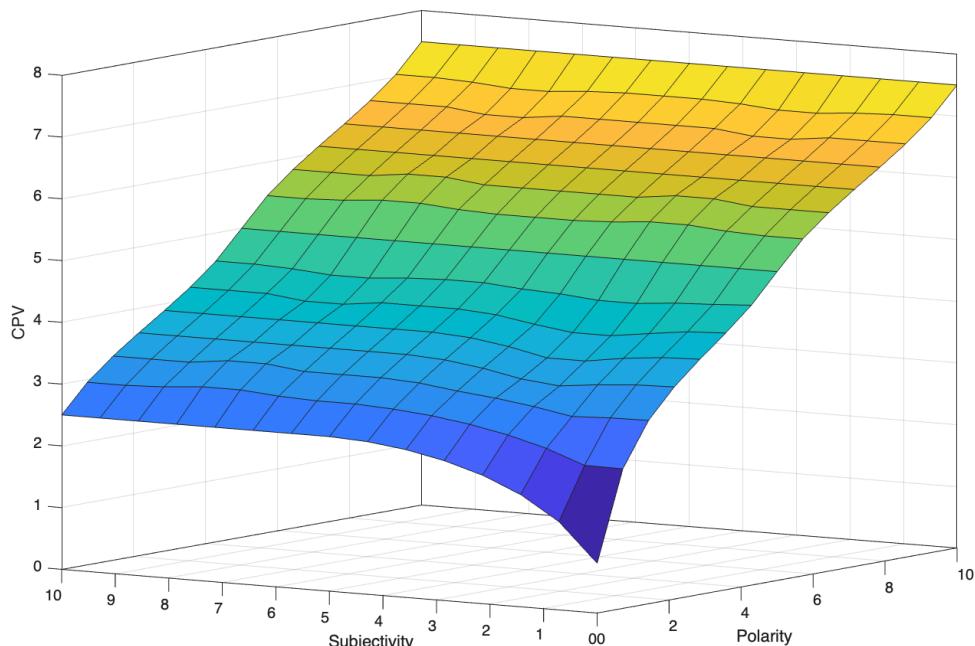
Tabela 12 – CPV por aspecto

Atributo	CPV
Áudio & Conectividade	5,91
Bateria	6,06
Câmera	5,81
Desempenho	5,72
<i>Design</i>	5,62
<i>Display</i>	5,73
Preço	4,11

Fonte: Elaboração própria (2023).

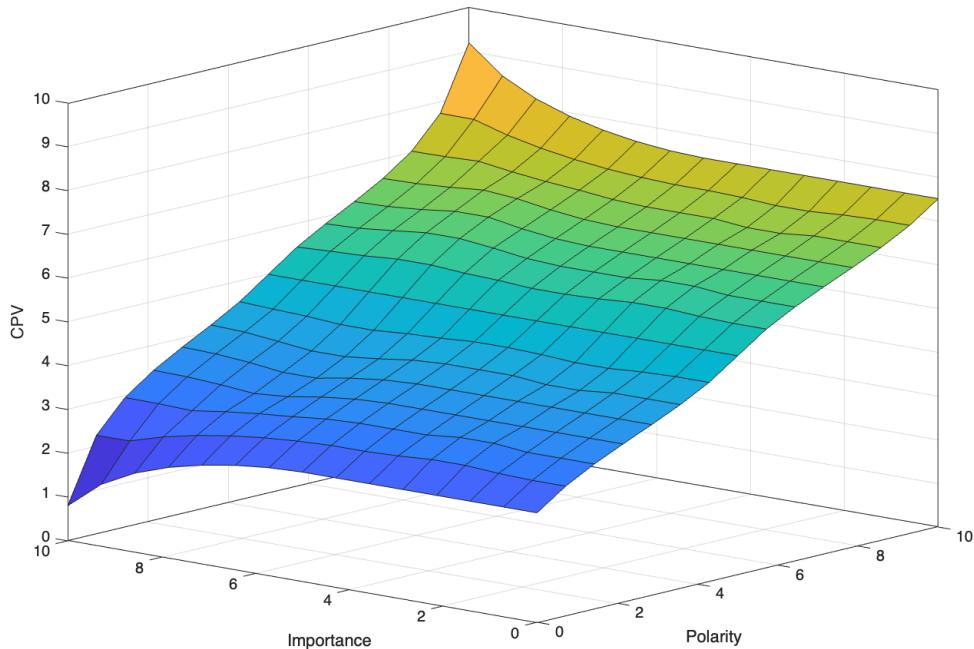
capacidade de simular o impacto da polaridade, subjetividade e importância para as necessidades do cliente na percepção de valor do cliente. Portanto, é possível visualizar como um ponto ótimo de CPV pode ser facilmente alcançado, por exemplo, melhorando a polaridade. Com essas informações, podem ser definidas diretrizes para planos de ação, auxiliando os gestores no processo de aprimoramento do valor.

Figura 46 – CPV em função da subjetividade e da polaridade



Fonte: Elaboração própria (2023).

Figura 47 – CPV em função da importância para as necessidades dos cliente e da polaridade



Fonte: Elaboração própria (2023).

5.3 ELECTRE TRI e FMEA orientada ao cliente

O índice CPV foi, então, agregado aos tradicionais critérios severidade (S), ocorrência (O) e detecção (D) para compor uma FMEA orientada ao cliente, calculada por meio do método ELECTRE TRI. Entretanto, mesmo que o CPV esteja na mesma escala que os demais (0 a 10), a pouca variação dos valores obtidos no FIS faz com que ele seja pouco representativo do valor relativo que o cliente atribui a cada *feature*. Assim, foi realizada uma normalização dos valores utilizando o método min-max (SHALABI; SHAABAN; KASASBEH, 2006), conforme a Equação 12. Os resultados do CPV normalizados foram nomeados NCPV.

$$x'_i = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (12)$$

Os modos de falha (KADËNA *et al.*, 2022), os aspectos correspondentes (ABSA), as notas para S, O e D (KADËNA *et al.*, 2022) e o valor percebido pelo cliente (FIS e normalização min-max) podem ser observados na Tabela 13. Para a câmera, os valores apresentados são a média entre os obtidos em modos da falha da câmera frontal e traseira. Além disso, o aspecto “preço” não tem um modo de falha correspondente e, portanto, não será analisado nesta seção. A definição de cada modo de falha é apresentada na Tabela 14.

Com base nos dados da Tabela 13, é possível fixar os limites b_1 e b_2 , conforme parâmetros estabelecidos na Seção 4.3. A fim de ser capaz de separar as alternativas nas diferentes categorias e tornar a classificação útil para a tomada de decisão, os limites foram definidos como apresentado na Tabela 15.

Tabela 13 – Avaliação dos critérios de entrada para o ELECTRE TRI

MF	Modo de Falha	Atributo	Severidade	Ocorrência	Detecção	NCPV
MF ₁	<i>Touch-Screen</i>	<i>Display</i>	5,00	10,00	5,50	2,50
MF ₂	Bateria	Bateria	5,50	10,00	5,00	10,00
MF ₃	Revestimento do dispositivo	<i>Design</i>	6,50	5,00	4,50	0,00
MF ₄	Câmera frontal e traseira	Câmera	3,00	7,25	2,75	4,32
MF ₅	Microfone	Áudio & Conectividade	2,50	9,50	4,50	6,59
MF ₆	<i>Freeze</i>	Desempenho	5,50	9,00	7,50	2,27

Fonte: Elaboração própria (2023).

Tabela 14 – Descrição dos modos de falha

MF	Modo de Falha	Descrição	Efeitos
MF ₁	<i>Touch-Screen</i>	Não responsivo: não recebe as entradas dos usuários ou responde de maneira precisa.	Ações não são executáveis. Usuário insatisfeito.
MF ₂	Bateria	Drena rapidamente; o dispositivo não mantém a carga e não consegue carregar; superaquecimento.	Usuário insatisfeito; o dispositivo reinicia por conta própria; risco de explosão.
MF ₃	Revestimento do dispositivo	Facilmente danificado após queda.	Usuário insatisfeito; o dispositivo fica mais danificado com o tempo.
MF ₄	Câmera frontal e traseira	Não funciona propriamente.	Usuário insatisfeito e irritado.
MF ₅	Microfone	Ruído estático na saída de áudio; ruídos de fundo; interrupções no áudio; som distante; parada de funcionamento.	Usuário insatisfeito e irritado; ao longo do tempo, eles podem se tornar não funcionais.
MF ₆	<i>Freeze</i>	Mau funcionamento.	A função necessária torna-se inoperante; saída inadequada.

Fonte: Adaptado de Kadêna *et al.* (2022).

Aplicando o código detalhado na Seção 4.3, os índices de credibilidade e as relações de preferência podem ser obtidos e assumem os valores mostrados na Tabela 16.

Um resumo dos modos de falha em cada categoria pode ser observado na Tabela 17. Nota-se que os modos de falha mais críticos considerando os quatro critérios (S, O, D e CPV) são *touch-screen*, bateria, *freeze* e microfone, classificados como risco inaceitável de acordo com a abordagem pessimista. Esse resultado é de extrema relevância para os tomadores de decisão,

Tabela 15 – Definição dos limites das categorias

Limite	Ocorrência	Severidade	Detecção	NCPV
b_2	4,0	6,5	4,5	3,5
b_1	6,5	8,5	6,0	6,5

Fonte: Elaboração própria (2023).

Tabela 16 – Índices de credibilidade, relações de preferência e categorias

MF	$\sigma(a, b_2)$	$\sigma(a, b_1)$	$\sigma(b_2, a)$	$\sigma(b_1, a)$	Relação de preferência	Categoria (Pessimista)	Categoria (Otimista)
MF ₁	0	0	0	0	aRb_2 e aRb_1	CT ₁	CT ₃
MF ₂	1	0	0	0	aSb_2 e aRb_1	CT ₁	CT ₂
MF ₃	0	0	0	1	aRb_2 e b_1Sa	CT ₂	CT ₃
MF ₄	0	0	0	1	aRb_2 e b_1Sa	CT ₂	CT ₃
MF ₅	0	0	0	0	aRb_2 e aRb_1	CT ₁	CT ₃
MF ₆	0	0	0	0	aRb_2 e aRb_1	CT ₁	CT ₃

Fonte: Elaboração própria (2023).

pois permite a criação de políticas de gestão de modos de falha diferentes para cada categoria e, por consequência, priorização de prevenção, mitigação e redução de falhas da categoria CT₁. Nesse caso, é indicado à Apple dedicar atenção especial a problemas de bateria - cujo risco não é aceitável nem no procedimento otimista -, seguido de defeitos ligados ao *display*, ao microfone e ao desempenho do aparelho. As saídas do modelo representam, ainda, uma melhoria em relação ao modelo-base de Kadëna *et al.* (2022), pois os modos de falha são categorizados em vez de ordenados, o que torna a compreensão e a visualização mais fáceis e promove tomadas de decisão mais eficientes e focadas nos elementos mais críticos (LOLLI *et al.*, 2015).

Tabela 17 – Modos de falha por categoria

Categorias de risco	Procedimento pessimista	Procedimento otimista
CT ₁ Risco Inaceitável	MF ₁ - <i>Touch-Screen</i> , MF ₂ - Bateria, MF ₅ - Microfone, MF ₆ - <i>Freeze</i>	
CT ₂ Risco Tolerável	MF ₃ - Revestimento do dispositivo, MF ₄ - Câmera frontal e traseira	MF ₂ - Bateria
CT ₃ Risco Aceitável		MF ₁ - <i>Touch-Screen</i> , MF ₃ - Revestimento do dispositivo, MF ₄ - Câmera frontal e traseira, MF ₅ - Microfone, MF ₆ - <i>Freeze</i>

Fonte: Elaboração própria (2023).

Além disso, outro resultado importante está relacionado ao uso de um método não compensatório, que estabelece um nível mínimo de performance para cada fator de risco. Isso

significa que, se pelo menos um critério tiver um desempenho inaceitável, o modo de falha não será classificado como tolerável ou aceitável pelo procedimento pessimista. Para ser categorizado como tolerável nessa abordagem, cada fator de risco deve ter um nível pelo menos tolerável individualmente. Isso evita que resultados muito bons em um fator de risco omitam ameaças graves em outro e o modo de falha seja despriorizado indevidamente, por exemplo.

Por fim, é indispensável avaliar a introdução do CPV no modelo para permitir uma adequação da FMEA de acordo com a visão dos clientes. A Tabela 18 mostra as categorizações utilizando como entrada apenas os fatores de risco tradicionais S, O e D.

Tabela 18 – Modos de falha por categoria desconsiderando o CPV

Categorias de risco	Procedimento pessimista	Procedimento otimista
CT ₁ Risco Inaceitável	MF ₁ - <i>Touch-Screen</i> , MF ₂ - Bateria, MF ₅ - Microfone, MF ₆ - <i>Freeze</i>	
CT ₂ Risco Tolerável	MF ₃ - Revestimento do dispositivo, MF ₄ - Câmera frontal e traseira	MF ₁ - <i>Touch-Screen</i> , MF ₂ - Bateria, MF ₆ - <i>Freeze</i>
CT ₃ Risco Aceitável		MF ₃ - Revestimento do dispositivo, MF ₄ - Câmera frontal e traseira, MF ₅ - Microfone

Fonte: Elaboração própria (2023).

Observa-se que, no processo incluindo o CPV para esse exemplo, o modo de falha “bateria” fica isolado na categoria tolerável ao observar a perspectiva otimista. Isso reforça que, para os clientes, o valor percebido de problemas na bateria é maior que aquele relacionado ao *display* ou ao desempenho. Assim, o modelo consegue absorver a visão espontânea e orgânica expressa pelos clientes nas redes sociais e usá-la na análise de modos de falha. Como se trata de um método não compensatório, entretanto, os fatores de risco para os quais os modos de falha “*touch-screen*” e “*freeze*” são inaceitáveis continuam sendo levados em consideração no procedimento pessimista, não havendo sobreposição das informações já existentes no FMEA tradicional. Portanto, é possível englobar elementos relacionados à satisfação do cliente de forma equilibrada e pertinente, validando o modelo desenvolvido neste trabalho.

6 CONCLUSÃO

O presente Trabalho de Conclusão de Curso teve como objetivo o desenvolvimento de um modelo de análise de modos de falha utilizando uma abordagem não compensatória e incluindo a percepção de valor do cliente como fator de risco adicional.

Esse objetivo foi atingido por meio da elaboração de uma revisão bibliográfica (Capítulo 3) e de um modelo de tomada de decisão em duas etapas: o primeiro passo realizou a seleção e transcrição de vídeos do YouTube, aplicou uma ABSA nas frases extraídas e utilizou as saídas da ABSA em um FIS, gerando o índice de valor percebido pelo cliente (CPV) (Seções 4.1 e 4.2); o segundo, por sua vez, utilizou o CPV como nova entrada para a FMEA, que foi executada com o uso do método de tomada de decisão multicritério ELECTRE TRI (Seção 4.3).

A aplicação ilustrativa para o iPhone 15 demonstrou que a transcrição de vídeos por meio do modelo Whisper seguida da ABSA proporcionou resultados satisfatórios no contexto da indústria de *smartphones*, permitindo a identificação dos principais aspectos dos aparelhos, bem como a percepção média dos usuários a respeito de cada um.

Da ABSA, os atributos “Câmera” e “*Design*” foram os mais citados pelos clientes, evidenciando, por um lado, a importância das câmeras para os usuários e, por outro, os efeitos do recente enfoque da Apple em elementos de *design*. Assim, há uma consonância entre os aspectos em evidência nas mídias sociais e a estratégia competitiva da marca. A maior polaridade, entretanto, não foi atribuída a nenhum dos dois, mas à bateria, puxada por adjetivos como “better” e “best”. Assim, há uma percepção positiva do aspecto no mercado, ainda que não acompanhada de uma melhoria nas especificações técnicas com relação à geração anterior. Isso evidenciou a importância da consideração da visão do cliente, para além de elementos técnicos objetivos do produto.

Já os resultados da FMEA orientada ao cliente utilizando não compensação mostraram que os maiores riscos estão ligados a modos de falha do *touch-screen*, da bateria, do microfone e de *freeze*, quando o aparelho celular “trava”. Nesse sentido, ao comparar os resultados considerando ou não o CPV, percebe-se que o alto valor dado pelo cliente à bateria tem uma influência relevante na categorização dos modos de falha. Em relação aos impactos gerenciais, a abordagem proposta evidenciou o potencial de capturar as percepções dos clientes nas redes sociais e utilizar essas informações para orientar melhorias nas políticas de gestão de modos de falha. Além disso, o uso de abordagem não compensatória permitiu levar em consideração cada fator de risco individualmente para a categorização de um modo de falha.

Esse modelo permitiu contemplar a oportunidade de pesquisa identificada por Zanon (2022) e trazer contribuições relacionadas às lacunas de pesquisa mapeadas durante a revisão bibliográfica. Entre as contribuições, pode-se mencionar:

- O uso de vídeos do YouTube como fonte de dados para percepção dos clientes. Embora o X, antigo Twitter, tenha se popularizado como fonte de dados para análise de sentimentos, assim como seções de comentários de redes sociais e aplicativos, o conteúdo em vídeo disponível no YouTube ainda foi pouco explorado pela literatura com esse fim. Além disso, por se tratar de um modelo novo, poucos trabalhos usaram o Whisper para reconhecimento automático de fala. Sobretudo, nenhum trabalho nesse sentido foi encontrado no contexto de *smartphones*;
- É o primeiro trabalho a usar dados de redes sociais para propor um índice de percepção de valor pelo cliente a ser utilizado como fator de risco da FMEA orientada ao cliente. Nesse sentido, é também o primeiro trabalho a combinar as técnicas de ASR, ABSA, FIS e ELECTRE TRI para gerar a categorização de modos de falha. De modo mais amplo, é o único estudo, até o momento, a usar *inputs* espontâneos e orgânicos dos clientes para a FMEA orientada ao cliente;
- O modelo pode ser replicado para outros *smartphones* e também para outros produtos.

O trabalho também apresentou algumas limitações e desafios. Entre eles, é importante mencionar que a seleção e *download* de vídeos do YouTube para uso no estudo foi feita de forma manual, o que é um empecilho ao uso do modelo para grandes volumes de dados. Além disso, um desafio inerente ao uso de conteúdo transscrito dessa natureza é a presença de um grande número de frases sem informações significativas para os objetivos do trabalho, dado que os *reviews* não têm limitação de escopo e formato. Eles costumam apresentar momentos de interação com o espectador, descontração, *storytelling*, entre outros, o que dificulta a mineração de relações aspecto-adjetivo relevantes.

Já em relação ao ELECTRE TRI, houve uma limitação ligada à quantidade de dados disponíveis para as entradas do problema: por um lado, o CPV foi extraído a partir do conteúdo de 50 vídeos do YouTube, podendo esse número ser maior; por outro, as demais entradas - S, O e D -, assim como os modos de falha, foram definidos com base em apenas dois pequenos conjuntos de dados (KADËNA *et al.*, 2022). Além disso, os limiares *p*, *q* e *v* foram definidos a partir da literatura (ARANTES *et al.*, 2022). Por fim, as entradas tradicionais da FMEA foram adaptadas de uma análise disponível na literatura para outra geração de iPhone e, embora seja possível correlacionar os modos de falha e fatores de risco, os resultados devem ser aproveitados com cautela. Com base nessas observações, algumas oportunidades de pesquisa futuras são sugeridas a seguir:

- Desenvolvimento de um modelo computacional capaz de analisar vídeos do YouTube, selecionando-os de acordo com critérios mais granulares que aqueles oferecidos pela plataforma e de maneira automática. Isso permitiria um aumento do volume de dados em estudos análogos no futuro;

-
- Desenvolvimento de um modelo computacional para filtrar da base de dados frases sem relevância para o estudo, de maneira automatizada e antes da realização da ABSA, a fim de melhorar o desempenho desta última;
 - Geração de avaliações de severidade, ocorrência e detecção específicas do produto analisado, o que pode ser feito com a ajuda de especialistas e de técnicas de atingimento de consenso;
 - Realização de testes para diferentes valores p , q e v , limiares de entrada do ELECTRE TRI, a fim de entender o impacto das variações nos resultados e estabelecer os valores mais apropriados para o problema de forma individualizada;
 - Definição e aplicação de outras técnicas de tomada de decisão multicritério além do ELECTRE TRI, a fim de comparar resultados e estabelecer o método mais apropriado para lidar com as variáveis de entrada inherentemente subjetivas do problema proposto;
 - Aplicação do modelo a outros *smartphones*, para efeito comparativo;
 - Aplicação do modelo de tomada de decisão em produtos de outra natureza, para testar seu desempenho e validade.

REFERÊNCIAS

- AKRAM, W.; KUMAR, R. A study on positive and negative effects of social media on society. **International journal of computer sciences and engineering**, v. 5, n. 10, p. 351–354, 2017.
- ALMEIDA, A. T. de *et al.* **Multicriteria and Multiobjective Models for Risk, Reliability and Maintenance Decision Analysis**. [S.l.: s.n.]: Springer International Publishing Switzerland, 2015. v. 231.
- APPLE. **iPhone 15**. [S.l.], 2023. Disponível em: <https://www.apple.com/br/iphone-15/>. Acesso em: 30 nov. 2023.
- ARAL, S.; DELLAROCAS, C.; GODES, D. Introduction to the Special Issue - Social Media and Business Transformation: A Framework for Research. **Inf. Syst. Res.**, v. 24, p. 3–13, 2013.
- ARANTES, R. F. M. *et al.* A fuzzy multicriteria group decision approach for classification of failure modes in a hospital's operating room. **Expert Systems with Applications**, v. 207, p. 117990, 2022. ISSN 0957-4174.
- BALAHUR, A.; JACQUET, G. Sentiment analysis meets social media – Challenges and solutions of the field in view of the current information sharing context. **Information Processing Management**, v. 51, 07 2015.
- BALAZS, J. A.; VELÁSQUEZ, J. D. Opinion Mining and Information Fusion: A survey. **Information Fusion**, v. 27, p. 95–110, 2016. ISSN 1566-2535.
- BENEKE, J. *et al.* The influence of perceived product quality, relative price and risk on customer value and willingness to buy: A study of private label merchandise. **Journal of Product and Brand Management**, v. 22, 05 2013.
- BERTRAND, J.; FRANSOO, J. Modelling and simulation. *In: _____*. [S.l.: s.n.], 2009. p. 265 – 306. ISBN 0-415-99055-6.
- BUSSE, B.; DUMRUKCIC, N.; KLEIBER, I. Book. **Language and linguistics in a complex world**. [S.l.: s.n.], 2023. 81 - 82 p.
- CARPINETTI, L. C. R.; ZANON, L. G. Sistemas de Apoio à Decisão: vídeo aula 5 - Introdução à teoria fuzzy - Parte I. **Youtube**, 2022. Disponível em: <https://www.youtube.com/watch?v=epx6cMFsbKs>. Acesso em: 01 nov. 2023.
- CARPINETTI, L. C. R.; ZANON, L. G. Sistemas de Apoio à Decisão: vídeo aula 5 - Introdução à teoria fuzzy - Parte II. **Youtube**, 2022. Disponível em: <https://www.youtube.com/watch?v=RYwg-hygIDA>. Acesso em: 01 nov. 2023.
- CERTA, A. *et al.* ELECTRE TRI-Based Approach to the Failure Modes Classification on the Basis of Risk Parameters. **Comput. Ind. Eng.**, Pergamon Press, Inc., USA, v. 108, n. C, p. 100–110, jun 2017. ISSN 0360-8352.
- CHAE, B. K. Insights from hashtag #supplychain and Twitter Analytics: Considering Twitter and Twitter data for supply chain practice and research. **International Journal of Production Economics**, v. 165, p. 247–259, 2015. ISSN 0925-5273.

- DING, X.; LIU, B.; YU, P. A holistic lexicon-based approach to opinion mining. *In: . [S.l.: s.n.], 2008.* p. 231–240.
- DYER, J. S. *et al.* Multiple criteria decision making, multiattribute utility theory: The next ten years. **Management Science**, INFORMS, v. 38, n. 5, p. 645–654, 1992. ISSN 00251909, 15265501.
- EVANS, G. Measuring and managing customer value. **Work Study**, v. 51, p. 134–139, 06 2002.
- FIGUEIRA, J.; GRECO, S.; EHRGOTT, M. **Multiple Criteria Decision Analysis: State of the Art Surveys.** [S.l.: s.n.]: Springer, 2016. ISBN 978-1-4939-3093-7.
- GALO, N.; CALACHE, L.; CARPINETTI, L. A group decision approach for supplier categorization based on hesitant fuzzy and ELECTRE TRI. **International Journal of Production Economics**, v. 202, 05 2018.
- GALO, N. R. **Proposta de modelo de decisão para avaliação de fornecedores baseado no ELECTRE TRI para categorização e na teoria dos conjuntos fuzzy para a modelagem da incerteza e hesitação de múltiplos tomadores de decisão.** 2018. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, 2018.
- GERAMIAN, A. *et al.* Fuzzy inference system application for failure analyzing in automobile industry. **International Journal of Quality Reliability Management**, v. 34, p. 1493–1507, 10 2017.
- GRAF, A.; MAAS, P. Customer value from a customer perspective: a comprehensive review. **Journal für Betriebswirtschaft**, v. 58, p. 1–20, 2008.
- GUTIERREZ, K.; VILA, M.-A.; MARTIN-BAUTISTA, M. Building a fuzzy sentiment dimension for multidimensional analysis in social networks. **Applied Soft Computing**, v. 108, 2021.
- HOANG, M.; BIHORAC, O. A.; ROUCES, J. Aspect-based sentiment analysis using BERT. *In: HARTMANN, M.; PLANK, B. (ed.). Proceedings of the 22nd Nordic Conference on Computational Linguistics.* Turku, Finland: Linköping University Electronic Press, 2019. p. 187–196.
- KADĒNA, E. *et al.* FMEA in Smartphones: A Fuzzy Approach. **Mathematics**, v. 10, p. 513, 02 2022.
- KAMBLE, S.; GUNASEKARAN, A. Big data-driven supply chain performance measurement system: a review and framework for implementation. **International Journal of Production Research**, v. 58, 06 2019.
- KHAN, S. A. *et al.* Supplier sustainability performance evaluation and selection: A framework and methodology. **Journal of Cleaner Production**, v. 205, p. 964–979, 2018. ISSN 0959-6526.
- KOOMSAP, P.; CHAROENCHOKDIOK, T. Improving risk assessment for customer-oriented FMEA. **Total Quality Management & Business Excellence**, Routledge, v. 29, n. 13-14, p. 1563–1579, 2018.
- LIMA JUNIOR, F. R.; CARPINETTI, L. C. R. Quantitative models for supply chain performance evaluation: a literature review. **Computers Industrial Engineering**, Elsevier, 2017.

- LIN, K.-P. *et al.* Green suppliers performance evaluation in belt and road using fuzzy weighted average with social media information. **Sustainability**, v. 10, n. 1, 2018. ISSN 2071-1050.
- LIU, B. Sentiment analysis and opinion mining. **Synthesis Lectures on Human Language Technologies**, Morgan & Claypool Publishers {LLC}, v. 5, n. 1, p. 1–167, maio 2012.
- LOLLI, F. *et al.* Flowsort-GDSS - A novel group multi-criteria decision support system for sorting problems with application to FMEA. **Expert Systems with Applications**, v. 42, p. 6342–6349, 05 2015.
- MADZÍK, P.; SHAHIN, A. Customer categorization using a three-dimensional loyalty matrix analogous to FMEA. **International Journal of Quality Reliability Management**, v. 38, p. 1833–1857, 08 2021.
- MARNEFFE, M.-C.; MANNING, C. Stanford typed dependencies manual. 01 2008.
- MICALE, R.; LA FATA, C.; LA SCALIA, G. A combined interval-valued ELECTRE TRI and TOPSIS approach for solving the storage location assignment problem. **Computers Industrial Engineering**, v. 135, p. 199–210, 2019. ISSN 0360-8352.
- NOH, Y.; PARK, S.; PARK, S.-B. Aspect-based sentiment analysis using aspect map. **Applied Sciences (Switzerland)**, v. 9, n. 16, 2019. Cited by: 11; All Open Access, Gold Open Access.
- PANDITA, H.; GONDHI, N. K. A literature survey of sentiment analysis based on E-commerce reviews. **2021 5th International Conference on Computing Methodologies and Communication (ICCMC)**, p. 1767–1772, 2021.
- PAYNE, A.; HOLT, S. Diagnosing customer value: Integrating the value process and relationship marketing. **British Journal of Management**, v. 12, n. 2, p. 159–182, 2001.
- PENG, H. *et al.* Knowing what, how and why: A near complete solution for aspect-based sentiment analysis. **Proceedings of the AAAI Conference on Artificial Intelligence**, v. 34, p. 8600–8607, 04 2020.
- POURJAVAD, E.; SHAHIN, A. The application of mamdani fuzzy inference system in evaluating green supply chain management performance. **International Journal of Fuzzy Systems**, v. 20, p. 901–912, 2018.
- PRAHALAD, C.; RAMASWAMY, V. Co-opting customer competence. **Harvard Business Review**, v. 78, 01 2000.
- RADFORD, A. *et al.* Robust speech recognition via large-scale weak supervision. 12 2022.
- RAMEZANIAN, R. Estimation of the profiles in posteriori ELECTRE TRI: A mathematical programming model. **Computers Industrial Engineering**, v. 128, p. 47–59, 2019. ISSN 0360-8352.
- ROY, B. Decision-aid and decision-making. **European Journal of Operational Research**, v. 45, n. 2, p. 324–331, 1990. ISSN 0377-2217. OR for Engineers Expert Systems and Decision-Aid.
- ROY, B.; SŁOWIŃSKI, R. Questions guiding the choice of a multicriteria decision aiding method. **EURO Journal on Decision Processes**, v. 1, 06 2013.
- SHAH, D. *et al.* The path to customer centricity. **JOURNAL OF SERVICE RESEARCH**, v. 9, n. 2, p. 113–124, NOV 2006. ISSN 1094-6705.

- SHAHIN, A. Integration of FMEA and the Kano model. An exploratory examination. **International Journal of Quality & Reliability Management**, Emerald Group Publishing Limited, v. 21, n. 7, p. 731–746, 2004.
- SHALABI, L. A.; SHAABAN, Z.; KASASBEH, B. Data mining: A preprocessing engine. **Journal of Computer Science**, Science Publications, v. 2, n. 9, p. 735–739, Sep 2006.
- SIVAKUMAR, M.; UYYALA, S. R. Aspect-based sentiment analysis of mobile phone reviews using LSTM and fuzzy logic. **International Journal of Data Science and Analytics**, v. 12, 10 2021.
- SOKOLOVA, K.; KEFI, H. Instagram and YouTube bloggers promote it, why should I buy? How credibility and parasocial interaction influence purchase intentions. **Journal of Retailing and Consumer Services**, v. 53, p. 101742, 2020. ISSN 0969-6989.
- SONG, H.; CADEAUX, J.; YU, K. The effects of service supply on perceived value proposition under different levels of customer involvement. **Industrial Marketing Management**, v. 54, p. 116–128, 2016. ISSN 0019-8501.
- SONGAILIENE, E.; WINKLHOFER, H.; MCKECHNIE, S. A conceptualisation of supplier-perceived value. **European Journal of Marketing - EUR J MARK**, v. 45, p. 383–418, 04 2011.
- STINE, R. Sentiment analysis. **Annual Review of Statistics and Its Application**, v. 6, p. 1–22, 2018.
- SUBHA, K.; BHARATHI, N. Big data-driven support system for Youtube channel improvement. **Journal of Theoretical and Applied Information Technology**, v. 101, n. 18, p. 7308 – 7316, 2023. Cited by: 0.
- SUN, D. *et al.* Re-stream: Real-time and energy-efficient resource scheduling in big data stream computing environments. **Information Sciences**, v. 319, 03 2015.
- SWEENEY, J. C.; SOUTAR, G. N. Consumer perceived value: The development of a multiple item scale. **Journal of Retailing**, v. 77, n. 2, p. 203–220, 2001. ISSN 0022-4359.
- TAN, K.; SHEN, X. **Integrating Kano's model in the planning matrix of quality function deployment**. 2000.
- TEAM COUNTERPOINT. **Mobile Devices Monitor - 2023**. [S.I.], 2023. Disponível em: <https://www.counterpointresearch.com/insights/us-smartphone-market-share/>. Acesso em: 24 nov. 2023.
- TRIGOS, F.; VAZQUEZ, A. R.; CÁRDENAS-BARRÓN, L. E. A simulation-based heuristic that promotes business profit while increasing the perceived quality of service industries. **International Journal of Production Economics**, v. 211, p. 60–70, 2019. ISSN 0925-5273.
- WE ARE SOCIAL. **Digital 2023 October Global Statshot Report**. [S.I.], 2023. Disponível em: <https://datareportal.com/reports/digital-2023-october-global-statshot>. Acesso em: 15 nov. 2023.
- ZADEH, L.; KLIR, G.; YUAN, B. **Fuzzy Sets, Fuzzy Logic, and Fuzzy Systems: Selected Papers**. [S.I.: s.n.]: World Scientific, 1996. ISBN 9789810224219.

ZANON, L. *et al.* A decision making model based on fuzzy inference to predict the impact of scor® indicators on customer perceived value. **International Journal of Production Economics**, v. 223, p. 107520, 05 2020.

ZANON, L. G. **Customer centric supplier evaluation: a multicriteria decision making model proposition combining aspect-based sentiment analysis and fuzzy inference.** 2022. Tese (Doutorado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2022.

ZANON, L. G. *et al.* Exploring the relations between supply chain performance and organizational culture: A fuzzy grey group decision model. **International Journal of Production Economics**, v. 233, 2021. ISSN 0925-5273.

ZEITHAML, V. A. *et al.* Three decades of customer value research: Paradigmatic roots and future research avenues. **Journal of Service Research**, v. 23, n. 4, p. 409–432, 2020.