

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Matheus Raphael Elero

**Aplicação de técnicas de *machine learning* para análise da satisfação dos
clientes de banda larga no Brasil**

Maringá
2023

Matheus Raphael Elero

Aplicação de técnicas de *machine learning* para análise da satisfação dos clientes de banda larga no Brasil

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Departamento de Engenharia de Produção, Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção.
Área de concentração: Engenharia de Produção

Orientador(a): Prof. Dr. Rafael H. Palma Lima
Coorientador(a): Prof. Dr. Bruno Samways dos Santos

Maringá
2023

Dados Internacionais de Catalogação-na-Publicação (CIP)
(Biblioteca Central - UEM, Maringá - PR, Brasil)

E39a

Elero, Matheus Raphael

Aplicação de técnicas de *machine learning* para análise da satisfação dos clientes de banda larga no Brasil / Matheus Raphael Elero. -- Maringá, PR, 2023.
132 f.: il. color., figs., tabs.

Orientador: Prof. Dr. Rafael Henrique Palma Lima.

Coorientador: Prof. Dr. Bruno Samways dos Santos.

Dissertação (Mestrado) - Universidade Estadual de Maringá, Centro de Tecnologia, Departamento de Engenharia de Produção, Programa de Pós-Graduação em Engenharia de Produção, 2023.

1. Machine learning. 2. Qualidade de serviços. 3. Telecomunicações. 4. Revisão sistemática. I. Lima, Rafael Henrique Palma, orient. II. Santos, Bruno Samways dos , coorient. III. Universidade Estadual de Maringá. Centro de Tecnologia. Departamento de Engenharia de Produção. Programa de Pós-Graduação em Engenharia de Produção. IV. Título.

CDD 23.ed. 658.5

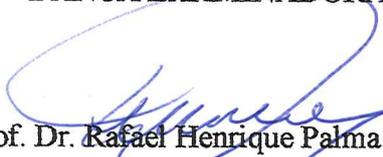
FOLHA DE APROVAÇÃO

MATHEUS RAPHAEL ELERO

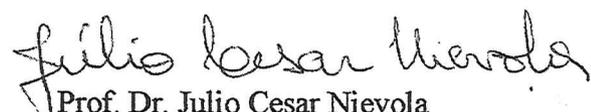
Aplicação de técnicas de machine learning para análise da satisfação dos clientes de banda larga no Brasil

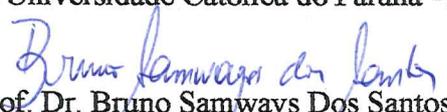
Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção pela Banca Examinadora composta pelos membros:

BANCA EXAMINADORA


Prof. Dr. Rafael Henrique Palma Lima
Presidente Orientador
Universidade Estadual de Maringá – PGP/UEM


Profa. Dra. Gislaine Camila Lapasini Leal
Membro examinadora interno
Universidade Estadual de Maringá – PGP/UEM


Prof. Dr. Julio Cesar Nievola
Membro examinador externo
Pontifícia Universidade Católica do Paraná - PUCPR


Prof. Dr. Bruno Samways Dos Santos
Universidade Tecnológica Federal do Paraná – UTFPR
Coorientador

Aprovada em: 17 de março de 2023.

Local da defesa: Sala de Projeção, Bloco 19, *campus* da Universidade Estadual de Maringá.

AGRADECIMENTO(S)

Primeiramente agradeço a minha noiva Bárbara, por todo apoio e companhia durante minha jornada no mestrado. Aos meus pais, Enivaldo e Regina, por toda educação e suporte em todos esses anos.

Agradeço a todos os colaboradores do PGP (Programa de Pós-Graduação em Engenharia de Produção), por oferecerem condições, conhecimento e suporte para os estudos e desenvolvimento do trabalho.

Por fim, agradeço aos professores Rafael Lima e Bruno Samways por todo o processo de orientação. O ensinamento fornecido por eles foi realizado com excelência, possibilitando que me desenvolvesse muito no âmbito científico e profissional.

Extraordinary claims require extraordinary evidence.

(CARL SAGAN)

Aplicação de técnicas de *machine learning* para análise da satisfação dos clientes de banda larga no Brasil

RESUMO

A prestação de serviços está contida em diversos setores da economia, tais como telecomunicações, transporte, saúde, entre outros. Considerando a importância e os desafios em mensurar e gerenciar a qualidade de serviços, muitas empresas têm adotado indicadores de satisfação dos clientes para quantificar a qualidade percebida. Os dados sobre satisfação dos clientes são armazenados em bases de dados, as quais podem ser analisadas para melhor entender os fatores de satisfação dos clientes. Nos últimos anos, a literatura científica tem visto a publicação de diversos trabalhos que utilizam técnicas de *machine learning* para analisar dados de satisfação de clientes no setor de serviços. No Brasil, diversos segmentos possuem pesquisas de satisfação (tais como energia, telecomunicações e transporte), porém há poucos trabalhos que exploram esses dados com aplicação de *machine learning*. Portanto, o objetivo deste trabalho é estudar a literatura sobre aplicação de ML na análise da qualidade de serviços e aplicar técnicas de ML em uma base de dados de satisfação de clientes de banda-larga no Brasil. Para isso, este trabalho foi subdividido em dois artigos. O primeiro relata os resultados de uma revisão sistemática da literatura sobre aplicação de técnicas de *machine learning* para análise da qualidade de serviços. Esta pesquisa resultou em análises de 106 publicações sobre o tema, onde foi possível extrair diversas informações da literatura, como por exemplo, foi identificado que o setor de hotelaria é o que mais possui publicações. Com estes resultados, foi possível identificar algumas lacunas da literatura que foram utilizadas para construção do segundo artigo. Assim, o segundo relatou a aplicação de técnicas de *machine learning* para explorar uma base de dados de satisfação de clientes de banda larga da ANATEL (Agência Nacional de Telecomunicações). Neste artigo foi apresentado que algumas técnicas como *Random Forest*, *Histogram Gradient Boosting* e *Gradient Boosting* apresentaram melhor desempenho para classificação. Também foi identificado que os clientes considerados neutros pelo *Net Promoter Score* possuem perfil incerto para classificação, e por fim foi identificado que alguns dos principais atributos para satisfação de clientes são velocidade de navegação, capacidade da prestadora em manter a conexão sem quedas, e cobrança.

Palavras-chave: *machine learning*, qualidade de serviços, telecomunicações, revisão sistemática.

Application of machine learning techniques to analyze broadband customer satisfaction in Brazil

ABSTRACT

The provision of services is contained in several sectors of the economy, such as telecommunications, transport, healthcare, among others. Considering the importance and challenges of measuring and managing service quality, many companies have adopted customer satisfaction indicators to quantify perceived quality. Customer satisfaction data is stored in databases, which can be analyzed to better understand customer satisfaction factors. In recent years, the scientific literature has seen the publication of several works that use machine learning techniques to analyze customer satisfaction data in the service sector. In Brazil, several segments have satisfaction surveys (such as energy, telecommunications and transport), but there are few works that explore these data with the application of machine learning. Therefore, the objective of this work is study the literature on the application of ML in the analysis of the quality of services and apply ML techniques in a database of satisfaction of broadband customers in Brazil. For this, this work was subdivided into two articles. The first article reports the results of a systematic review of the literature on the application of machine learning techniques to analyze the quality of services. This research resulted in analyzes of 106 papers on the subject, where it was possible to extract various information from the literature, for example, it was identified that the hospitality sector is the one that has the most number of publications. With these results, it was possible to identify some gaps in the literature that were used to build the second article. Thus, the second reported the application of machine learning techniques to explore an ANATEL (National Telecommunications Agency) broadband customer satisfaction database. In this article it was presented that some techniques such as Random Forest, Histogram Gradient Boosting and Gradient Boosting presented better performance for classification. It was also identified that customers considered neutral by the Net Promoter Score have an uncertain profile for classification, and finally it was identified that some of the main attributes for customer satisfaction are browsing speed, the provider's ability to maintain the connection without drops, and billing.

Keywords: *machine learning, service quality, telecommunications, systematic review*

LISTA DE FIGURAS

Figura 1 – Justificativas abordadas neste trabalho.	9
Figura 2 – Etapas de cada artigo.	14
Figura 3 – Estrutura da <i>string</i> de busca.	20
Figura 4 – Processo de Extração de Artigos.	21
Figura 5 – Fluxo de classificação dos Artigos.	22
Figura 6 – Quantidade de artigos incluídos na pesquisa publicados por ano.	24
Figura 7 – Quantidade de artigos por setores de serviço.	28
Figura 8 – Quantidade de artigos por países	29
Figura 9 – Quantidade de artigos por fonte de dados utilizados nas pesquisas.	30
Figura 10 – Tipo de dados por setores.	31
Figura 11 – Quantidade de artigos pela forma como foi medida a satisfação de clientes.	33
Figura 12 – Técnicas de <i>Machine Learning</i> mais utilizadas	34
Figura 13 – Descrição dos Modelos aplicados na pesquisa.	60
Figura 14 – Etapas da pesquisa.	61
Figura 15 - Fluxo do questionário para área de informações gerais.	65
Figura 16 – Fluxo do questionário para área de satisfação geral.	66
Figura 17 - Fluxo do questionário para satisfação específica Parte 1.	67
Figura 18 - Fluxo do questionário para satisfação específica Parte 2.	68
Figura 19 - Fluxo do questionário para informações demográficas.	69
Figura 20 – Diagrama de células vazias na base de dados.	70
Figura 21 – Diagrama de análise de clientes Neutros.	76
Figura 22 - Quantidade de respostas por ano.	77
Figura 23 – Quantidade de respostas por operadora.	77
Figura 24 – Quantidade de respostas por estado.	78
Figura 25 – Histograma da satisfação por ano.	79
Figura 26 – Satisfação média por operadora.	80
Figura 27 – <i>Box plot</i> da acurácia no Modelo 1.	81
Figura 28 – Gráfico <i>Beeswarm</i> com valores SHAP para predição de clientes Insatisfeitos no Modelo 1.	83
Figura 29 – Valores SHAP absolutos estratificados por classe.	83
Figura 30 – <i>Box plot</i> da acurácia no Modelo 2.	85
Figura 31 - Gráfico <i>Beeswarm</i> com valores SHAP para predição de clientes Insatisfeitos no	

Modelo 2.	87
Figura 32 – Valores SHAP absolutos estratificados por classe.	87
Figura 33- <i>Box plot</i> da acurácia no Modelo 3.	89
Figura 34 - Gráficos <i>Beeswarm</i> com valores SHAP para o Modelo 3.	90
Figura 35 – Valores médios absolutos de SHAP estratificados por classe no Modelo 3.	91
Figura 36 – Clientes neutros classificados com algoritmos treinados no Modelo 2	92
Figura 37 – Clientes neutros classificados com algoritmos treinados no Modelo 1.	93

LISTA DE TABELAS

Tabela 1 – Relação dos artigos apresentados neste trabalho.	13
Tabela 2 - Artigos mais citados no WoS.	25
Tabela 3 – Artigos mais citados no Scopus.	26
Tabela 4 – <i>Journals</i> com maior quantidade de artigos.	26
Tabela 5 - Dimensão média do tamanho das bases de dados	32
Tabela 6 – Contribuições para serviços no setor de hotelaria.	35
Tabela 7 - Contribuições para serviços no setor de educação.	39
Tabela 8 - Contribuições para serviços no setor de saúde.	42
Tabela 9 - Contribuições para serviços no setor de transporte.	44
Tabela 10 - Contribuições para serviços no setor de telecomunicações.	47
Tabela 11 – Principais lacunas para serem preenchidas com futuras pesquisas.	49
Tabela 12 – Descrição das etapas de pesquisa.	62
Tabela 13 - Formatos de questões do questionário.	63
Tabela 14 - Seções do questionário.	64
Tabela 15 – Etapas de preparação da base.	71
Tabela 16 – Formato de cada modelo.	72
Tabela 17 - Técnicas e campos de hiperparâmetros.	73
Tabela 18 - Resultados do <i>Grid Search</i> por modelo e técnica	74
Tabela 19 – Desempenho das Técnicas Modelo 1.	80
Tabela 20 – Atributos mais relevantes de acordo com RF, DT e GB resultantes no Modelo 1.	82
Tabela 21 – Desempenho das técnicas para o Modelo 2.	84
Tabela 22 – Atributos mais relevantes de acordo com RF, DT e GB resultantes no Modelo 2.	86
Tabela 23 – Resultados de Acurácia para o Modelo 3.	88
Tabela 24 - Atributos mais importantes para RF, DT e GB.	89
Tabela 25 – Síntese da ordem dos atributos mais relevantes obtidos pelas técnicas ML (RF, DT e GB) e SHAP.	96
Tabela 26 – Descrição das colunas da base de dados.	121

LISTA DE ABREVIATURAS E SIGLAS

AB	<i>Ada Boost</i>
ABRADEE	Associação Brasileira de Distribuidores de Energia Elétrica
ANATEL	Agência Nacional de Telecomunicações
API	<i>Application Programming Interface</i>
AUC	<i>Area Under the Curve</i>
DT	<i>Decision Tree</i>
GB	<i>Gradient Boosting</i>
HGB	<i>Histogram Gradient Boosting</i>
KNN	<i>K-Nearest Neighbors</i>
LR	<i>Logistic Regression</i>
ML	<i>Machine Learning</i>
NPS	<i>Net Promoter Score</i>
RF	Random Forest
RNA	Rede Neural Artificial
ROC	<i>Receiver Operating Characteristic</i>
RSL	Revisão Sistemática da Literatura
SAC	Secretaria Nacional de Aviação Civil
SHAP	<i>SHapley Additive exPlanations</i>
SVM	<i>Support vector machine</i>
WoS	<i>Web of Science</i>

SUMÁRIO

CAPÍTULO 1 – INTRODUÇÃO	7
1.1 CONTEXTUALIZAÇÃO.....	7
1.2 JUSTIFICATIVA	9
1.3 OBJETIVOS	12
1.4 MÉTODO.....	13
1.5 ESTRUTURA DO TRABALHO	15
CAPÍTULO 2 – ARTIGO 1: REVISÃO SISTEMÁTICA DA LITERATURA.....	16
RESUMO.....	16
2.1 INTRODUÇÃO.....	17
2.2 MÉTODO	19
2.2.2 Seleção de artigos	20
2.2.3 Classificação Preliminar	21
2.2.4 Coleta de Dados.....	23
2.3 RESULTADOS E DISCUSSÕES	24
2.4 CONTRIBUIÇÕES PARA SETOR DE SERVIÇOS	35
2.5 AGENDA DE PESQUISA	48
2.6 CONCLUSÕES	50
CAPÍTULO 3 – ARTIGO 2: QUALIDADE DO SERVIÇO DE BANDA-LARGA NO BRASIL	52
RESUMO.....	52
3.1 INTRODUÇÃO.....	53
3.2 REFERENCIAL TEÓRICO	55
3.2.1 ML Aplicado à Qualidade de Serviços.....	55
3.2.2 ML Aplicada à Qualidade De Serviços No Setor De Telecomunicações	57
3.3 MÉTODO	58
3.3.1 Etapas da Pesquisa.....	58
3.3.2 Base de Dados	63
3.3.3 Preparação da Base de Dados	69
3.3.4 Aplicação das Técnicas de ML.....	72
3.3.5 Análise dos Atributos mais relevantes.....	75
3.3.6 Análise dos Clientes Neutros.....	75
3.4 RESULTADOS	76

3.4.1 Análise Descritiva dos Dados.....	76
3.4.2 Modelo 1.....	80
3.4.3 Modelo 2.....	84
3.4.4 Modelo 3.....	88
3.4.5 Análise dos Neutros.....	91
3.5 DISCUSSÃO.....	94
3.6 CONCLUSÃO.....	97
CAPÍTULO 4 – CONCLUSÕES.....	99
REFERÊNCIAS.....	103
APÊNDICE A – COLUNAS DA BASE DE DADOS.....	122

INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

A prestação de serviços abrange operações de diferentes áreas, como transporte, comunicações, tecnologias, hotelaria, saúde, entre outros (ZHANG; MOREIRA; SOUSA, 2021). Cada uma delas possui suas particularidades, no entanto esses setores têm um objetivo em comum, que é gerenciar e atender as expectativas de seus clientes. Essa gestão como um todo envolve diversos aspectos como o planejamento efetivo, análise de falhas e qualidade do serviço (ALTUNTAS; KANSU, 2020).

Além de ter relevância em meios práticos, a qualidade de serviços também possui destaque na literatura científica. Carnerud (2018) realizou uma revisão sistemática sobre publicações de artigos em três periódicos (*The International Journal of Quality & Reliability Management*, *The TQM Journal* e *Total Quality Management & Business Excellence*). Segundo o autor, a qualidade de serviços e satisfação de clientes estão entre os seis principais temas de pesquisa em gestão da qualidade ao longo de 25 anos.

Como apresentam Berry, Parasuraman e Zeithaml (1994), aferir a qualidade de um serviço não é uma tarefa fácil, pois diferente de um produto físico, a qualidade precisa ser medida sobre a perspectiva do consumidor. Altuntas e Kansu (2020) argumentam que os desafios de analisar a qualidade de serviços são devidos aos diversos fatores que influenciam o resultado, e indicam que para aprimorar a qualidade do serviço é necessário diminuir as lacunas entre a expectativa

do cliente e o valor percebido, considerar um planejamento adequado, e reduzir as falhas operacionais. Apesar dos desafios, gerir a qualidade pode contribuir diretamente para alguns benefícios, como retenção de clientes (PRIHATNA *et al.*, 2021).

Portanto, muitas organizações utilizam indicadores de satisfação de clientes e qualidade percebida, o que pode ocasionar a geração de uma grande quantidade de dados. Por exemplo, no setor hoteleiro, Samara, Magnisalis e Peristeras (2020) relatam a existência de grandes bases de dados obtidas a partir de redes sociais, e de sites de viagem como *TripAdvisor*, as quais podem ser usados para analisar a satisfação dos turistas. Algumas organizações também possuem base de dados internos de clientes, como em hospitais com registros de pacientes (KUNZE *et al.*, 2020). Outra fonte de dados utilizada no setor de serviços é a pesquisa de satisfação, que pode ser desenvolvida tanto por órgãos nacionais, quanto internamente por organizações. Por exemplo, o artigo de Langan e Harris (2019) explorou uma pesquisa do Reino Unido com 1,8 milhões de respostas para analisar o nível de satisfação dos estudantes na região.

Com a disponibilidade desses dados, torna-se necessário extrair conhecimentos para gerenciamento e melhoria da qualidade de serviços. Com isso, muitos estudos têm abordado técnicas de *machine learning* (ML) e *data mining* para explorar esses dados. Sabendo-se que múltiplos atributos contribuem para a qualidade final do serviço, os algoritmos de ML permitem a identificação dos fatores de maior influência, criar sistemas preditivos para um indicador de satisfação, comunicar e sintetizar os dados.

A literatura apresenta publicações de pesquisas em vários setores. Por exemplo, no setor de saúde, Kunze *et al.* (2020) relataram a utilização de algoritmos supervisionados de ML para prever a satisfação de pacientes após cirurgia no joelho. No setor de hotelaria, Manuel J. Sánchez-franco, Cepeda-carrion e Roldán (2019), extraíram dados do site *TripAdvisor*, para aplicar técnicas não supervisionadas, o que permitiu identificar que fatores ligados ao desempenho dos funcionários, limpeza interna e entretenimento, são os que mais contribuem para satisfação final. No setor de educação, Thomas e Galambos (2004) aplicaram técnicas supervisionadas de ML em dados resultantes de um questionário de satisfação de uma universidade, e assim, identificaram que a relação com os colegas de classe, e o ambiente acadêmico, são variáveis determinantes para a satisfação de estudantes.

Além dos setores de saúde, hotelaria e educação, também existem artigos para empresas de transporte, como é o caso de Sezgen, Mason e Mayer (2019) que apresentaram o desenvolvimento de técnicas de *text mining*, para estudar a relação de preço e conforto das viagens para satisfação de passageiros. Outro artigo no setor de transporte é o publicado por Farazi, Murshed e Hadiuzzaman (2022), onde os autores aplicam técnicas supervisionadas e

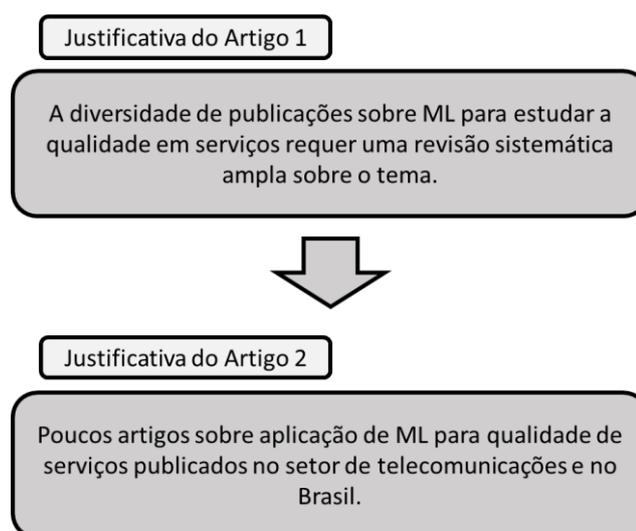
não supervisionadas para investigar a relação da heterogeneidade do público na qualidade percebida em viagens de trem. Também existem pesquisas de provedoras de serviços de telecomunicações, com destaque para os trabalhos de Tong *et al.* (2017) e Markoulidakis *et al.* (2020), que utilizam dados de clientes para construir modelos preditivos de *Net Promoter Score* (NPS).

1.2 JUSTIFICATIVA

Apesar da variedade de exemplos na literatura que aplicam ML para qualidade de serviços, e a existência de bases de dados para estudo, existem algumas lacunas na literatura, como por exemplo, a baixa quantidade de publicações no Brasil. Dessa forma, esta dissertação relata estudos sobre a aplicabilidade de ML para qualidade de serviços, e foi organizada no modelo *multipaper* com o desenvolvimento de dois artigos. O primeiro teve o objetivo de realizar uma revisão sistemática sobre o tema, e outro sobre análise dos dados de satisfação de clientes da ANATEL (Agência Nacional de Telecomunicações) com aplicação de ML.

A Figura 1 ilustra as justificativas de cada artigo deste trabalho. Para o primeiro artigo foi explorado a diversidade de publicações sobre ML aplicado a qualidade de serviços. Com os resultados do Artigo 1, foi possível identificar algumas lacunas, as quais foram exploradas no Artigo 2. Dessa forma, cada justificativa é destinado a um artigo, sendo a segunda uma consequência dos resultados encontrados no primeiro trabalho. O detalhamento dos objetivos e métodos de cada artigo é apresentado nas Seções 1.3 e 1.4.

Figura 1 – Justificativas abordadas neste trabalho.



Fonte: Autoria Própria.

Devido à variedade de publicações existentes que aplicam ML, existem estudos que conduziram revisões sistemáticas da literatura para analisar o estado da arte, entender as lacunas e tendências. Por exemplo, Slob, Catal e Kassahum (2021) realizaram uma análise do estado da arte sobre artigos que aplicaram ML para gestão diária de fazendas. Já Dos Santos *et al.* (2019) apresentaram uma revisão sistemática sobre aplicação de ML no setor de saúde pública, e Buchlak *et al.* (2021) analisaram publicações sobre aplicação de ML para diagnósticos de doenças em neuroimagens.

O artigo de Vencovský (2020) analisou 14 artigos do Scopus, e apresentou alguns dados da literatura, como fonte de dados utilizados, principais abordagens, e conclusões sobre os principais problemas e desafios a serem sanados em pesquisas de *text mining* para qualidade de serviços. No entanto, não existe na literatura uma revisão sobre a aplicação de técnicas de ML no setor de serviços de forma ampla, exceto apenas uma específica sobre *text mining* (VENCOVSKÝ, 2020).

Considerando que o trabalho de Vencovský (2020) tem foco de aplicação de *text mining*, existem lacunas na produção científica para exploração da literatura sobre aplicação de ML em qualidade de serviços de maneira mais ampla. Ou seja, é importante identificar quais as principais fontes de dados são estudadas, os setores mais frequentes, as principais técnicas, e como são as contribuições que a aplicação de ML pode suprir para cada setor.

Considerando esta lacuna, o Artigo 1 realiza uma revisão sistemática sobre aplicação de ML para qualidade de serviços e satisfação de clientes, a qual é relatada no Capítulo 2. Com este levantamento, foi possível identificar situações que podem ser preenchidas pela comunidade científica.

Dentre os resultados do Artigo 1, destacam-se dois principais. Primeiro, apesar da importância econômica do setor de serviços no Brasil, poucos trabalhos aplicam ML para estudar a qualidade dos serviços prestados. Além disso, o setor de telecomunicações ainda é pouco explorado na literatura científica e o estudo do caso brasileiro pode auxiliar nas discussões sobre esse tema.

O levantamento de artigos realizados resultou em análises de 106 publicações. Dentro deste total de artigos, 26 são do setor de hotelaria, 20 de educação, 18 de transporte, 15 saúde e oito telecomunicações. Note que o setor de telecomunicações é apenas o quinto lugar entre os que mais tem publicações, o que indica possível falta de estudos para o setor. Além dele, outras áreas de prestação de serviços como, turismo, tecnologia da informação, alimentação e energia também apresentam carência de estudos sobre o tema.

Os resultados da revisão sistemática também demonstraram que o Brasil possui apenas duas

publicações sobre aplicação de ML para qualidade de serviços. O trabalho em questão foi desenvolvido por Sibert *et. al.* (2019), que aplicou ML para construção de um sistema preditivo da satisfação de clientes no setor de energia. E Lucini *et al.* (2020) apresentaram um estudo com aplicação de *text mining*, com a finalidade de analisar a satisfação de clientes em uma base de dados sobre transporte aéreo de 170 países e 400 empresas de aviação. Este é um aspecto que pode ser preenchido por pesquisadores que atuam no território brasileiro, pois existem disponibilidade de dados e setores relevantes para estudo.

Como apresentou Vieceli (2023) através de dados do IBGE (Instituto Brasileiro de Geografia e Estatísticas), o setor de serviços brasileiro apresentou recorde de crescimento em 2022, com alta de 8,3%. De acordo com os dados, o setor de serviços superou outros dois setores, como indústria e varejo. Portanto, o desenvolvimento de pesquisas para o setor pode ser relevante para uma das principais áreas econômicas do país.

No contexto brasileiro, vários setores possuem pesquisas de satisfação de clientes. Para o setor de energia, existe a pesquisa anual da ABRADDEE (Associação Brasileira de Distribuidores de Energia Elétrica), para telecomunicações a ANATEL (Agência Nacional de Telecomunicações) aplica um questionário de satisfação anual e disponibiliza os dados em seu site (ABRADDEE, 2020; ANATEL, 2022). Já para o setor de transporte brasileiros, existe a pesquisa desenvolvida pela SAC (Secretaria Nacional de Aviação Civil), que mensura o índice de satisfação de passageiros sobre aeroportos (SAC, 2022). Além disso, informações de satisfação de clientes para prestadoras de serviços brasileiras podem ser extraídas de sites como *TripAdvisor*, *Booking*, *Twitter*, entre outros.

A pesquisa de satisfação realizada pela ANATEL também é pouco explorada na literatura. O trabalho de Albuquerque e Eduardo (2018) é o único encontrado que apresenta a utilização dos dados do questionário da agência. No artigo, os autores apresentam análises de capacidade para serviços de telefonia móvel na região sul do Brasil. Na literatura brasileira também existe um trabalho de conclusão de curso desenvolvido por Bernardes (2020), que aplica ML e realiza análises estatísticas para a base de dados de telefonia móvel da ANATEL.

Outro estudo encontrado sobre satisfação de clientes no setor de telecomunicações brasileiro foi publicado por Mota *et al.* (2012), no qual os autores desenvolveram um questionário próprio com base em outros padrões internacionais. A escolha dos autores se deve ao fato de o trabalho ter sido realizado antes da ANATEL iniciar a aplicação da pesquisa, que começou apenas em 2015. O artigo de Sousa *et al.* (2020) também explora a qualidade dos serviços de telecomunicações no país, porém aplica *text mining* em dados de reclamação de clientes do site Reclame Aqui.

Apesar da baixa exploração dos dados da ANATEL pela comunidade científica brasileira, o setor de telecomunicações brasileiro possui impactos para economia local, como apresenta Schenedes (2022), o setor recebeu em média R\$ 36,9 bilhões de investimentos entre 2018 e 2022. E Este trabalho pode contribuir com os objetivos estratégicos apresentados pelo Governo do Brasil (2023) para ANATEL, como redução da quantidade de reclamações, pois a aplicação de ML para análise da satisfação e seus principais fatores podem contribuir com implicações práticas para as empresas planejarem ações de melhoria para satisfação.

1.3 OBJETIVOS

Considerando as lacunas encontradas na literatura sobre ML aplicada à qualidade de serviços, baixa quantidade de publicações no Brasil e no setor de telecomunicações, esta pesquisa tem como objetivo principal estudar a literatura sobre aplicação de ML na análise da qualidade de serviços e aplicar técnicas de ML em uma base de dados de satisfação de clientes de banda-larga no Brasil, com o intuito de identificar os principais fatores de satisfação nesse segmento de serviço. Para isso, os seguintes objetivos específicos foram elaborados:

- Obter um panorama geral da literatura sobre a aplicabilidade de ML para gestão da qualidade de serviços;
- Identificar lacunas e definir uma agenda de pesquisa sobre o tema;
- Aplicar algoritmos de ML em uma base de dados nacional no setor de telecomunicações;
- Obter implicações práticas resultantes de ML para melhoria da qualidade no setor estudado;

Para atingir os objetivos da pesquisa, foram propostos dois artigos com os seguintes objetivos e métodos apresentados na Tabela 1.

Tabela 1 – Relação dos artigos apresentados neste trabalho.

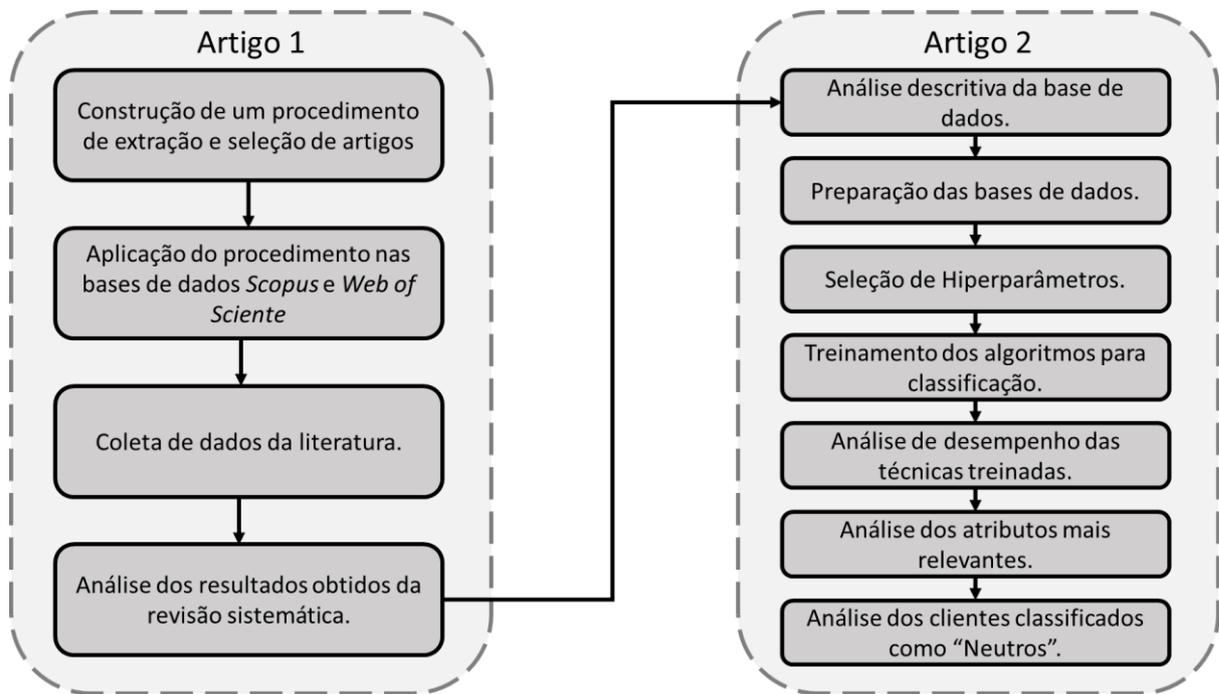
Artigo	Artigo 1	Artigo 2
Título	Análise da qualidade de serviços a partir de técnicas de ML e data mining: Uma Revisão Sistemática e agenda de pesquisa	Aplicação de técnicas de ML para analisar a qualidade de serviços de banda larga no Brasil
Objetivos	Realizar uma revisão sistemática para analisar o estado da arte sobre aplicações de ML para análise da qualidade de serviços.	Aplicar técnicas de ML para classificar a satisfação de clientes, e analisar os atributos mais relevantes para a satisfação.
Método	Revisão Sistemática da Literatura	Experimento
Abordagem	Combinada	Quantitativa

Fonte: Autoria própria.

1.4 MÉTODO

A Figura 2 apresenta as etapas de pesquisa para cada artigo. No primeiro artigo foi realizada uma revisão sistemática da literatura sobre aplicações de ML em qualidade de serviços. Para este método foi construído um procedimento para extração e seleção de artigos, utilização das bases de dados *Scopus* e *Web of Science*, leitura e análise das publicações selecionadas. Com os resultados do Artigo 1, foi identificado que a literatura brasileira possuía uma lacuna de publicações sobre o tema, e assim o Artigo 2 possuiu etapas para aplicação de ML em uma base de dados de satisfação de clientes de banda larga no Brasil, com seleção de hiperparâmetros dos algoritmos aplicados, treinamento para classificação, análises de desempenho e identificação dos atributos mais relevantes para satisfação.

Figura 2 – Etapas de cada artigo.



Fonte: Autoria própria.

Em relação às abordagens de cada método, Cauchick Miguel *et al.*, (2018) apresentam três tipos para pesquisas em Engenharia de Produção: a Quantitativa, Qualitativa e Combinada. Com relação à abordagem quantitativa, os autores subdividem alguns métodos mais apropriados como *survey*, modelagem/simulação, experimento e quase-experimento. Na abordagem Qualitativa, alguns meios de atender os objetivos das pesquisas são entrevistas, estudos de caso, pesquisa ação e a pesquisa a documentos. Por fim, a abordagem combinada aplica métodos quantitativos e qualitativos de forma combinada, com objetivo de compensar as vantagens e desvantagens de cada abordagem.

Com base nos conceitos apresentados pelos autores, as pesquisas realizadas nos artigos podem ser caracterizadas quanto a sua abordagem e seu método. A primeira possui abordagem Combinada, pois utiliza um método exploratório para investigar o estado da arte e obter estatísticas da literatura existente, e assim transformá-los em dados quantitativos. O segundo artigo aplicou algoritmos e métodos estatísticos para analisar o nível de satisfação do serviço de telecomunicações, portanto pode ser considerado como quantitativo com método experimental, pois será executada a manipulação e estudo de variáveis em prol de um objetivo.

1.5 ESTRUTURA DO TRABALHO

Assim, o projeto de dissertação está organizado em capítulos. No Capítulo 2 é apresentado o Artigo 1 com o título “Análise da qualidade de serviços a partir de técnicas de *machine learning* e *data mining*: Uma Revisão Sistemática e agenda de pesquisa”. O Capítulo 3 disponibiliza o Artigo 2 intitulado de “Aplicação de técnicas de ML para analisar a qualidade de serviços de banda-larga no Brasil”. E por fim o Capítulo 4 apresenta as principais conclusões obtidas pelos resultados dos dois artigos.

ARTIGO 1: REVISÃO SISTEMÁTICA DA LITERATURA

O primeiro artigo apresenta um estudo de revisão sistemática da literatura sobre aplicações de ML para qualidade de serviços. No momento da apresentação desta dissertação, este artigo foi submetido para o periódico *Journal of Quality & Reliability Management*, e estava em etapa de revisão do editor. Portanto, a versão final deste artigo pode ser diferente da apresentada nesta dissertação, conforme revisões e correções apontadas pela revisão do periódico.

Análise da qualidade de serviços a partir de técnicas de *machine learning* e data mining: Uma Revisão Sistemática e Agenda de Pesquisa

RESUMO

Proposta - Grande parte das necessidades básicas da sociedade são atendidas por serviços como saúde, educação, comunicação, transporte, entre outros. A qualidade desses serviços é crucial, o que tem levado as empresas a investirem na mensuração da qualidade dos serviços. A literatura acadêmica tem relatado o uso de técnicas de *machine learning* (ML) para

estudar os resultados dessas medidas. Portanto, este artigo tem como objetivo fornecer uma visão geral da aplicação de técnicas de ML para estudar a qualidade do serviço e a satisfação do cliente por meio de uma revisão sistemática da literatura (RSL).

Método - Esta RSL usou as bases de dados *Scopus* e *Web of Science* (WoS). Depois de selecionar e filtrar os artigos, seu conteúdo completo foi analisado para identificar as ferramentas de ML, segmentos de serviço e fontes de dados mais populares usados.

Resultados - A revisão sistemática foi capaz de identificar 106 artigos relevantes. Embora o primeiro artigo tenha sido publicado em 1995, o tema ganhou atenção significativa a partir de 2016. Foi identificado que hotelaria, educação, transporte e saúde são os serviços mais estudados devido ao acesso facilitado às bases de dados. Por fim, este artigo também discute outros aspectos dessas publicações, como as ferramentas de ML, tarefas de aprendizado usadas, tipos de bancos de dados analisados e uma visão geral do uso de ML no setor de serviços.

Originalidade/Valor - Esta pesquisa apresenta um panorama geral das publicações que estudaram ML para gestão da qualidade de serviços, e uma agenda de pesquisa com indicações de lacunas que podem ser preenchidas na literatura.

Palavras-chave: *Machine Learning*, *Data Mining*, Qualidade de Serviços, Revisão Sistemática.

2.1 INTRODUÇÃO

A prestação de serviços está contida em um contexto multidisciplinar, com atividades voltadas à educação, transporte, saúde, telecomunicações, energia, entre outros (ZHANG; MOREIRA; SOUSA, 2021). Todas essas áreas têm um papel fundamental para o bom andamento da sociedade, fazendo com que a gestão desses serviços seja essencial para construir uma operação melhor. Dessa forma, a Gestão da Qualidade para esse tipo de operação possui inúmeras vantagens para o consumidor e para empresa, como por exemplo, pode contribuir com uma melhor relação de confiança entre as partes, redução de custos e aumento de vendas. (BERRY; PARASURAMAN; ZEITHAML, 1994).

Além de benefícios e implicações práticas, a gestão da qualidade de serviços é uma das principais tendências de pesquisa na literatura científica. Carnerud (2018) realizou uma RSL de três *Journals* (*The International Journal of Quality & Reliability Management*, *The TQM Journal* e *Total Quality Management & Business Excellence*), e apresentou que a qualidade de

serviços e satisfação de clientes, pertence a um dos seis principais de temas de pesquisa em gestão da qualidade ao longo de 25 anos.

A operacionalização da gestão da qualidade no setor de serviços requer que empresas escolham uma métrica para mensurar o grau de satisfação dos clientes. Algumas abordagens podem utilizar um valor numérico que represente o nível da qualidade percebida (número de 0 a 10), outros adotam uma escala numérica (1- Muito Insatisfeito a 5 – Muito Satisfeito), ou podem classificar clientes conforme o NPS (*Net Promoter Score*) (DEJAEGER *et al.*, 2012; MARKOULIDAKIS *et al.*, 2020; TURKYILMAZ; TEMIZER; OZTEKIN, 2018).

É comum que para a construção e coleta de informações sobre a qualidade percebida, muitas organizações prestadoras de serviços construam bases de dados obtidas a partir de questionários, sistemas online de avaliação de serviços ou até mesmo de plataformas de terceiros, como é o caso do *TripAdvisor* no setor hoteleiro ou o uso de postagens no *Twitter* sobre a empresa prestadora de serviços. Em todos esses casos, os registros coletados vão além da satisfação final, podendo incluir percepções mais detalhadas, como em hotéis por exemplo, onde o cliente pode avaliar também a qualidade da localidade, restaurantes e atendimento. Já no caso de hospitais, existem registros de tempo de espera, caso clínico, entre outros (ALHAMAD; SINGH, 2021; KUNZE *et al.*, 2020).

Devido à grande quantidade de dados gerados, muitos pesquisadores têm aplicado técnicas de *machine learning* (ML) para realizar análises da qualidade de serviços (VENCOVSKÝ, 2020). Em alguns casos, as pesquisas abordam aplicação dos métodos para prever ou classificar o nível de satisfação de um determinado cliente, e assim comparar o desempenho das abordagens (GAO; YANG; QU, 2021). Em outros, a aplicação pode utilizar algoritmos que exploram quais atributos são os maiores determinantes da qualidade (DEJAEGER *et al.*, 2012;). Entretanto, também existe a síntese de texto com o objetivo de indicar agrupamentos positivos e negativos, assim como outras abordagens (VARGAS-CALDERON *et al.*, 2021).

Conforme a variedade de artigos publicados sobre ML, alguns estudos abordam RSL para explorar o estado da arte, e entender as lacunas e tendências de pesquisa. Dos Santos *et al.* (2019) apresentaram uma revisão sistemática sobre a aplicação de algoritmos de ML no setor de saúde pública. Já Slob, Catal e Kassahun (2021) aplicaram RSL para entender o uso dessas técnicas na gestão diárias de fazendas. Outra pesquisa desenvolvida por Buchlak *et al.* (2021), explora artigos sobre ML utilizados para diagnósticos em neuroimagem. No entanto, não existe na literatura uma revisão sobre a aplicação de técnicas de ML no setor de serviços, exceto apenas uma específica sobre *text mining* (VENCOVSKÝ, 2020). O artigo de Vencovský (2020) analisou 14 artigos do

Scopus, e apresentou alguns dados da literatura, como fonte de dados utilizados, principais abordagens, e conclusões sobre os principais problemas e desafios a serem sanados em pesquisas de *text mining* para qualidade de serviços.

Portanto, esse artigo tem como objetivo apresentar uma RSL sobre pesquisas que aplicam ML para análise da Qualidade de Serviços. Este trabalho se diferencia do de Vencovsky (2020) na abrangência das técnicas de ML e *Data Mining* e fonte de extração de artigos, já que o autor abordou apenas *Text Mining* e extraiu dados do *Scopus*. Para isso, foi desenvolvido um protocolo de pesquisa, classificação e análise bibliométrica de trabalhos extraídos do *Scopus* e *Web of Science* (WoS). Ao final do processo foram analisados 106 artigos sobre o tema, os quais foram lidos e analisados para extrair informações da literatura. Esse artigo está dividido em 4 seções, 2.2 descreve o método utilizado, 2.3 os resultados encontrados, 2.4 apresenta uma discussão sobre as contribuições por setor, e 2.5 as conclusões finais.

2.2 MÉTODO

Para atingir o objetivo principal da pesquisa, foi utilizado um método de revisão sistemática de artigos publicados sobre ML aplicada à Qualidade de Serviços. O processo desenvolvido foi inspirado no trabalho de Dos Santos *et al.* (2019), e pode ser dividido em 4 quatro grandes etapas sequenciais: construção da *string* de busca, seleção de artigos, classificação preliminar e análise.

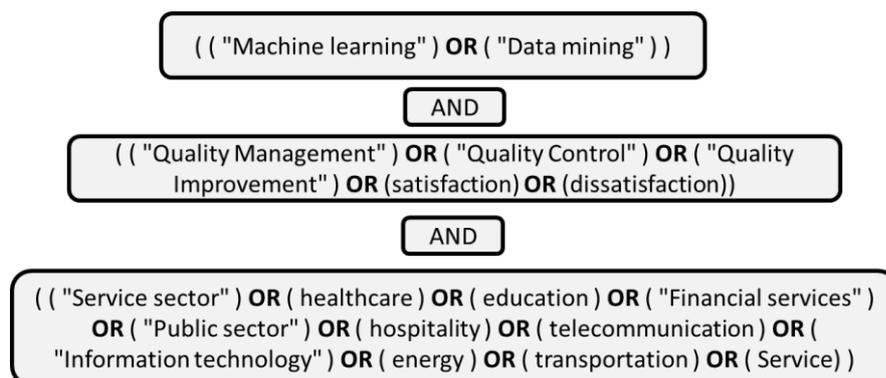
2.2.1 Construção da *string* de busca

Inicialmente foram realizadas buscas no sistema *Scopus* apenas com os termos “*Machine Learning*” e “*Quality of Service*”, em títulos, resumos ou *Keywords*. Os resultados iniciais apresentaram uma grande quantidade de artigos, porém muitos dispersos em relação ao objetivo da pesquisa. Com isso, foram realizadas novas pesquisas adicionando outras palavras e operadores na *string*, como “*customer satisfaction*”, “*Data Mining*” e outros.

Com a finalidade de limitar os trabalhos pesquisados conforme áreas de serviços, foi realizada uma busca na literatura para selecionar os principais setores a serem alocados na *string*. O trabalho de Zhang, Moreira e Sousa (2021), descreve uma revisão sistemática da literatura sobre Gestão da Qualidade Total aplicada no setor de serviços, que resultou em alguns dos setores mais frequentes, os quais foram utilizados como base para a construção da *string* de busca. Estas áreas são *healthcare* (saúde), educação, telecomunicações, hotelaria, público, financeiro, serviços gerais, alimentação, turismo, energia e tecnologia da informação.

Com isso, a *string* final foi desenvolvida com o propósito de encontrar pesquisas com palavras em Títulos, Resumos ou Palavras Chave, que estivessem relacionadas com “*Machine Learning*” ou “*Data Mining*”, Gestão da Qualidade ou Satisfação de Clientes, e os setores apresentados por Zhang, Moreira e Sousa (2021). A Figura 3 apresenta um esquema simples das palavras utilizadas na *string* de busca.

Figura 3 – Estrutura da *string* de busca.

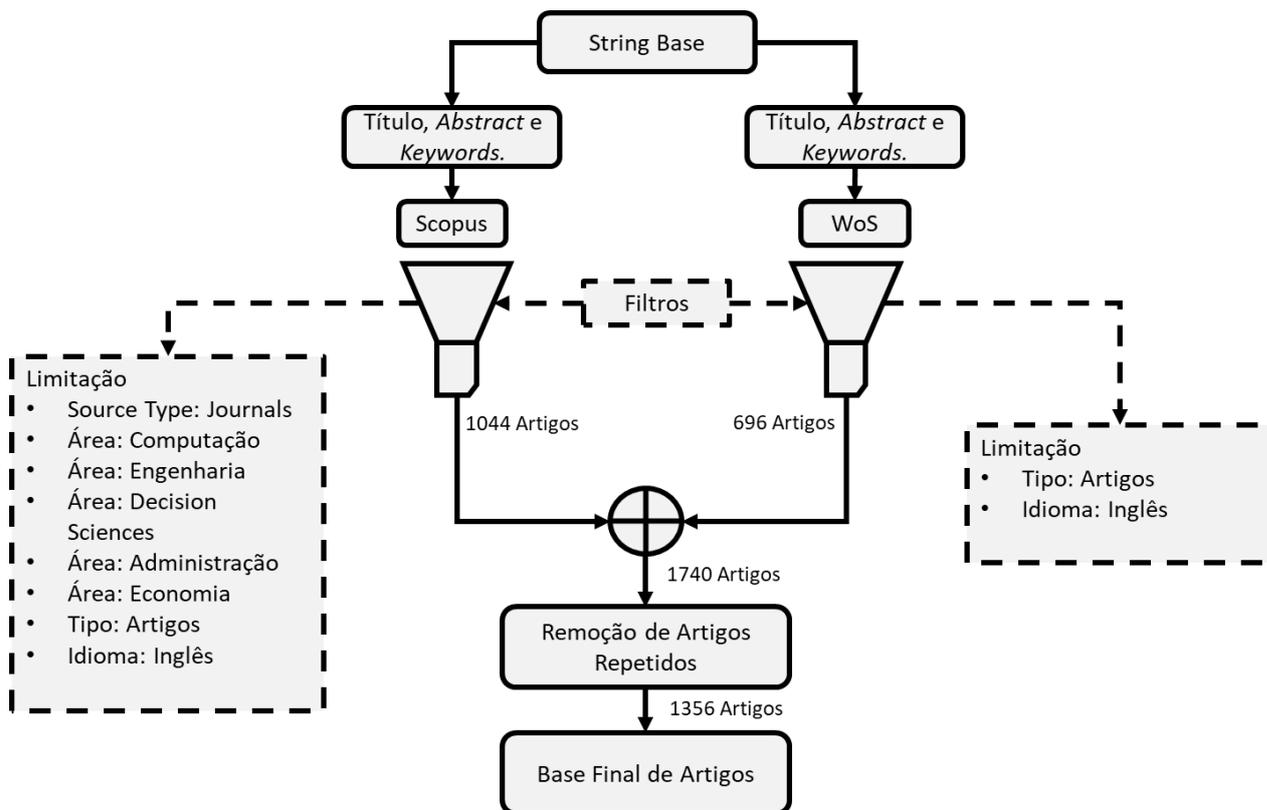


Fonte: Autoria própria.

2.2.2 Seleção de artigos

O objetivo dessa etapa foi extrair os artigos de duas fontes, *Scopus* e *WoS* com a utilização da *string* construída. Estas fontes também foram utilizadas em outros artigos de revisão sistemática, como Dos Santos *et al.* (2019) e Slob *et al.* (2021), onde apresentaram bons resultados de extração de publicações com estas bases, e, portanto, elas foram utilizadas nesta pesquisa. A Figura 4 mostra um fluxograma de como foi realizada essa busca para a obtenção do conjunto inicial de artigos. Esta extração pode ser separada em duas fases, com a filtragem inicial dos dados, e remoção de textos repetidos. O processo resultou em uma base com 1.356 artigos.

Figura 4 – Processo de Extração de Artigos.



Fonte: Autoria própria.

Primeiro, a *string* foi aplicada nos repositórios *Scopus* e *WoS*, para busca em título, *abstract* ou *keywords*. Em seguida, os dados foram filtrados através de opções disponíveis nos próprios sistemas, conforme indica a Figura 4. Os filtros foram selecionados para limitar apenas artigos em inglês, para artigos publicados em periódicos, e áreas correlatas a gestão de serviços. Essa parte resultou em uma base com 1740 artigos, que foram importados no *software* MENDELEY (2021) para a remoção de itens duplicados, resultando em 1368 textos. Por fim, esses dados foram organizados em uma planilha eletrônica, e uma checagem manual de duplicados foi realizada, onde foram encontrados mais 12 itens. Portanto, o conjunto final de artigos para a etapa de classificação foi de 1356 documentos.

2.2.3 Classificação Preliminar

A classificação preliminar de artigos teve como objetivo identificar quais trabalhos têm relação com os objetivos desta RSL, e assim separá-los para a etapa seguinte. Na primeira parte, os textos foram revisados apenas pelo Título, *Abstract* e palavras-chave, e para cada um foi estabelecido um critério de Inclusão e Exclusão:

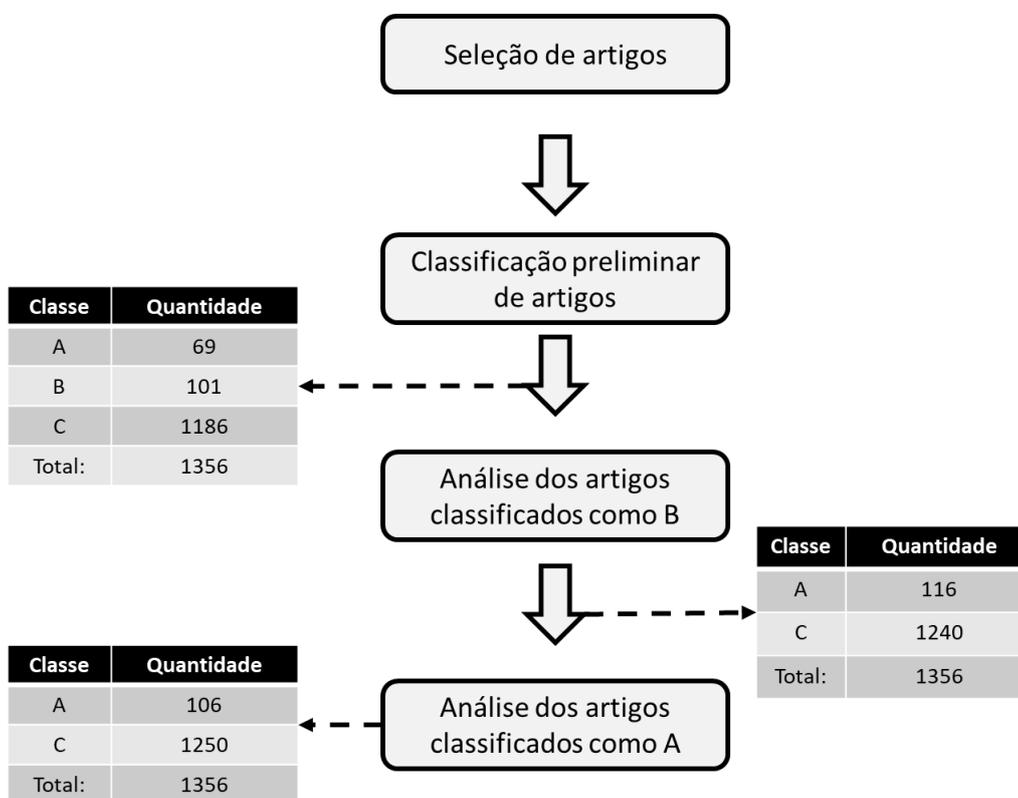
- **Inclusão:** Artigos que utilizaram técnicas de ML aplicada para análise de

qualidade de serviços;

- **Exclusão:** Artigos que não utilizaram técnicas de ML ou não abordaram qualidade de serviços.

A Figura 5 apresenta um fluxo resumido dessa etapa. Todo o processo foi inspirado no trabalho de Dos Santos *et al.* (2019). Artigos classificados como A, são textos que tinham alta possibilidade de atender aos critérios de inclusão. Documentos classificados com B são trabalhos duvidosos que precisaram de uma análise mais detalhada (etapa posterior) para identificar a inclusão, e C são pesquisas que certamente atendem aos critérios de exclusão.

Figura 5 – Fluxo de classificação dos Artigos.



Fonte: Autoria própria.

Na segunda parte, os artigos identificados como B foram lidos completamente para reclassificar como C ou A. Dos 101 trabalhos duvidosos, 47 foram reclassificados como A e 54 como C, resultando em um total de 116 A's e 1240 C's. Depois, 116 artigos foram incluídos para a próxima fase de análise. No entanto, essa fase resultou em algumas reclassificações, finalizando com 106 artigos atribuídos como A.

É importante destacar que outros dois critérios de exclusão foram utilizados no momento da leitura completa dos Artigos A. O primeiro é referente ao DOI do artigo, ou seja, caso o mesmo não tivesse DOI ele era excluído dos dados e automaticamente classificado como C. O segundo foram os casos onde não fosse possível ter acesso ao artigo.

2.2.4 Coleta de Dados

A coleta de dados tinha como objetivo extrair informações de cada artigo para análise. Com isso, todos os 106 artigos resultantes da etapa anterior. Todos os artigos foram lidos em sua íntegra com o objetivo de identificar as seguintes características:

- Tipo do aprendizado (Supervisionada, Não Supervisionada ou Ambas);
- Tipo da tarefa de ML utilizada (Classificação, Clusterização, Regressão ou Associação);
- Segmento do setor de serviços estudado (ex: hotelaria, saúde, etc.)
- País de filiação dos autores dos artigos;
- Técnicas de ML aplicadas;
- Como foi medida a satisfação de clientes ou qualidade de serviços (Classificação binária, valor numérico, categorias ordinais, *Net Promoter Score* (NPS) ou agrupamento);
- Fonte de dados utilizados;
- Tamanho dos dados processados;
- Nacionalidade dos dados;

Os tipos de métricas utilizadas foram classificadas conforme os exemplos:

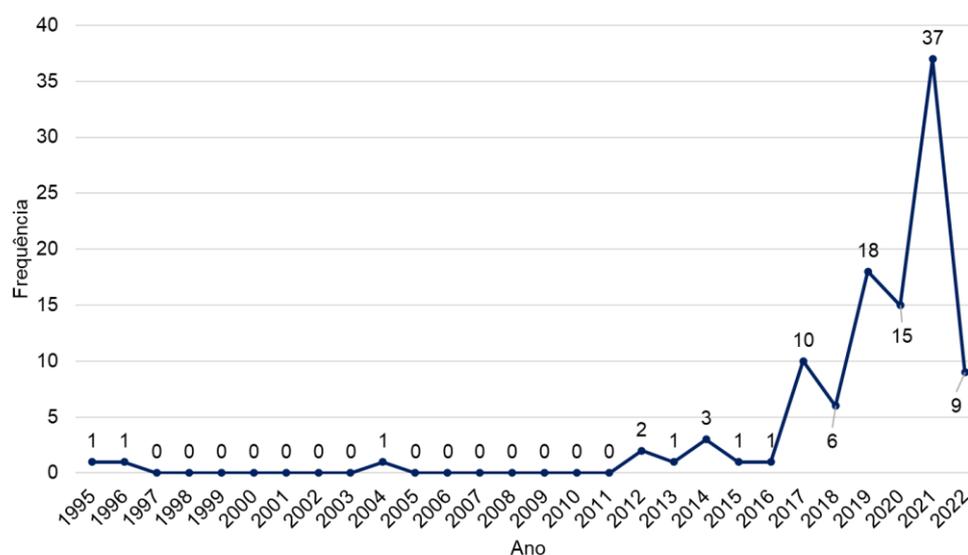
- **Classificação Binária:** Inclui casos onde os clientes foram classificados em dois grupos, como “Satisfeito” ou “Insatisfeito”;
- **Valor Numérico:** Consiste em uma métrica onde apenas um número foi utilizado para descrever o nível de satisfação;
- **Categorias Ordinais:** Em alguns casos, os pesquisadores usaram escala *Likert* em que cada número representa uma categoria ordinal, como por exemplo, “Muito Insatisfeito”, “Insatisfeito”, “Neutro”, “Satisfeito” e “Muito Satisfeito”;
- **NPS:** Casos onde os pesquisadores utilizaram escala de 0 a 10 e classificaram os clientes em três categorias, “promotores”, “neutros” e “detratores”;
- **Agrupamento:** Inclui casos onde ao invés de mensurar o nível de qualidade, os pesquisadores agruparam os clientes conforme suas semelhanças e buscaram descrever suas características e criar perfis;

2.3 RESULTADOS E DISCUSSÕES

A Figura 6 apresenta a quantidade de publicações entre os anos 1995 e 2022. É importante destacar que a RSL foi aplicada em junho de 2022, e, portanto, apenas nove artigos foram encontrados em 2022. Os primeiros artigos encontrados que utilizaram técnicas de ML para análise de qualidade de serviços foram publicados em 1995 e 1996 por Cox e Bell (1996) e Cox, Bell e Glover (1995). Ambos relatam a aplicação da técnica *Decision Tree* para classificação da satisfação de clientes no setor de telecomunicações.

A ocorrência de publicações sobre o assunto permaneceu baixa e o assunto começou a ganhar relevância acadêmica a partir de 2016, com a publicação de 10 trabalhos. Após isso, pode-se verificar um significativo aumento no número de publicações, sendo que somente em 2021 houveram 37 trabalhos sobre a aplicação de ML em organizações de serviços.

Figura 6 – Quantidade de artigos incluídos na pesquisa publicados por ano.



Fonte: Autoria própria.

Pode-se dizer que os resultados da Figura 5 são esperados pois a tecnologia para aplicação das técnicas evoluiu e se tornou mais acessível. Nos últimos anos houve um aumento na quantidade de bases de dados disponibilizadas publicamente, como em redes sociais e plataformas de serviços online. Samara *et al.* (2020) apresenta que no setor de Turismo existem

oportunidades para exploração de dados originários de sites como *Airbnb*, *Facebook* e *Google*

A relação de textos mais citados conforme o WoS é apresentado pela Tabela 2. O trabalho de Thomas e Galambos (2004) é o mais citado. Os autores pesquisaram técnicas de regressão e classificação para análise de satisfação de estudantes em uma universidade. O segundo mais citado é a pesquisa publicada por De Oña *et al.* (2012), que demonstra aplicação de *Decision Tree* para identificar atributos mais relevantes para satisfação no setor de transporte. Em terceiro está o artigo publicado por Lin (2013), que apresenta o desenvolvimento de um sistema de detecção para clientes insatisfeitos em serviços logísticos.

Tabela 2 - Artigos mais citados no WoS.

Referência	Título	Citações
Thomas e Galambos (2004)	<i>What satisfies students? Mining student-opinion data with regression and decision tree analysis</i>	115
De Oña <i>et al.</i> (2012)	<i>A classification tree approach to identify key factors of transit service quality</i>	114
Lin (2013)	<i>Analysis of service satisfaction in web auction logistics service using a combination of fruit fly optimization algorithm and general regression neural network</i>	108
Hew <i>et al.</i> (2020)	<i>What predicts student satisfaction with moocs: a gradient boosting trees supervised machine learning and sentiment analysis approach</i>	33
De Oña e De Oña (2015)	<i>Analysis of transit quality of service through segmentation and classification tree techniques</i>	32

Fonte: Autoria própria.

A Tabela 3 apresenta a relação dos artigos mais citados pelo Scopus. Em primeiro lugar está o artigo de Guo, Barnes e Jia (2017) com 414 citações. O trabalho apresenta um estudo no setor de hotelaria, com aplicação de técnicas supervisionadas e não-supervisionadas em dados do *TripAdvisor* para analisar a qualidade do serviço em diversos hotéis. Os outros dois artigos em sequência, Lin (2013) e De Oña *et al.* (2012) estão presentes entre os três primeiros no *ranking* dos mais citados, tanto pelo *Scopus*, quanto pelo WoS.

Tabela 3 – Artigos mais citados no Scopus.

Referência	Título	Citações
Guo, Barnes e Jia (2017)	Mining meaning from online ratings and reviews: tourist satisfaction analysis using latent dirichlet allocation	414
Lin (2013)	Analysis of service satisfaction in web auction logistics service using a combination of fruit fly optimization algorithm and general regression neural network	133
De Onã <i>et al.</i> (2012)	A classification tree approach to identify key factors of transit service quality	121
Hu <i>et al.</i> (2019)	What do hotel customers complain about? Text analysis using structural topic model	112
Chang, Ku e Chen (2019)	Social media analytics: extracting and visualizing hilton hotel ratings and reviews from tripadvisor	84

Fonte: Autoria própria.

Em relação aos periódicos dos artigos incluídos, percebe-se uma grande dispersão das publicações, como apresentado na Tabela 4. Os dois com maior frequência de artigos é o “*International Journal Of Contemporary Hospitality Management*” e “*Sustainability*” com quatro publicações, seguidos de outros com duas. As demais revistas não apresentadas pela Tabela 6 possuem apenas uma publicação. Esse resultado indica que as aplicações de ML em qualidade de serviços estão disseminadas em periódicos associados ao segmento de serviços, e não relacionados à área de ML, pois nesta lista existem *Journals* para gestão de hotéis, transporte, turismo e gestão de serviços no geral.

Tabela 4 – *Journals* com maior quantidade de artigos.

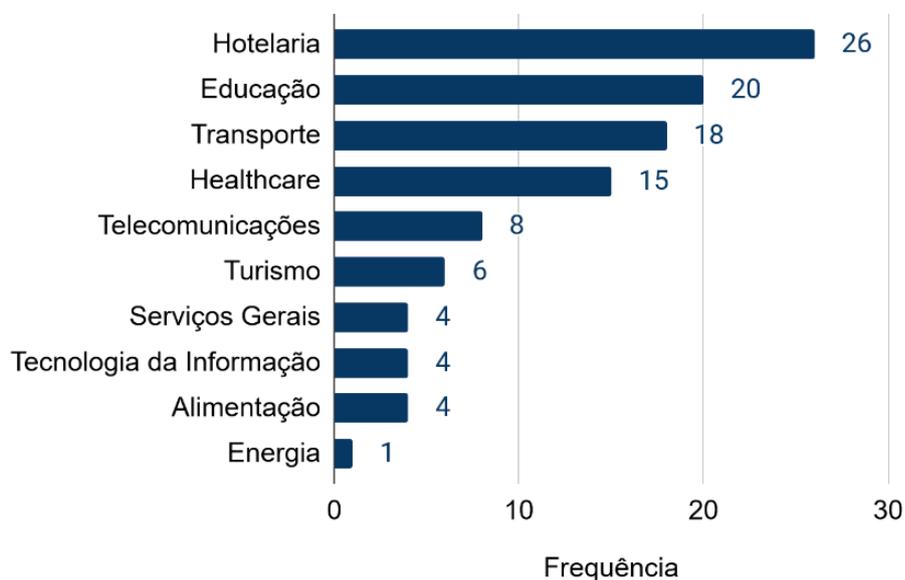
<i>Journals</i>	Quantidade de Artigos	Área
<i>International Journal of Contemporary Hospitality Management</i>	4	Hotelaria
<i>Sustainability</i>	4	Sustentabilidade
<i>Annals of Operations Research</i>	2	Pesquisa Operacional
<i>Expert Systems With Applications</i>	2	Multidisciplinar
<i>International Journal of Hospitality Management</i>	2	Hotelaria

<i>Journal of Air Transport Management</i>	2	Transporte
<i>Transportation Research Part D: Transport And Environment</i>	2	Transporte
<i>Journal of Quality Assurance In Hospitality & Tourism</i>	2	Hotelaria
<i>Ieee Access</i>	2	Multidisciplinar
<i>Plos One</i>	2	Multidisciplinar
<i>Healthcare</i>	2	Saúde
<i>Journal of Retailing And Consumer Services</i>	2	Gestão de Serviços
<i>Mobile Information Systems</i>	2	Telecomunicações
<i>Research In Transportation Business and Management</i>	2	Transporte
<i>Journal of Service Management</i>	2	Gestão de Serviços
<i>Tourism Management</i>	2	Turismo

Fonte: Autoria própria.

A Figura 7 mostra a distribuição de trabalhos por segmentos de serviços. O setor de hotelaria é o com a maior quantidade de artigos publicados, correspondendo a cerca de 24,5% do total, seguido por educação (18,8%), transporte, saúde (*healthcare*), telecomunicações, turismo, serviços gerais, alimentação, tecnologia da informação e energia. Os setores público e financeiro não apresentaram nenhum artigo publicado, o que indica uma lacuna da literatura, pois são áreas relevantes para a sociedade.

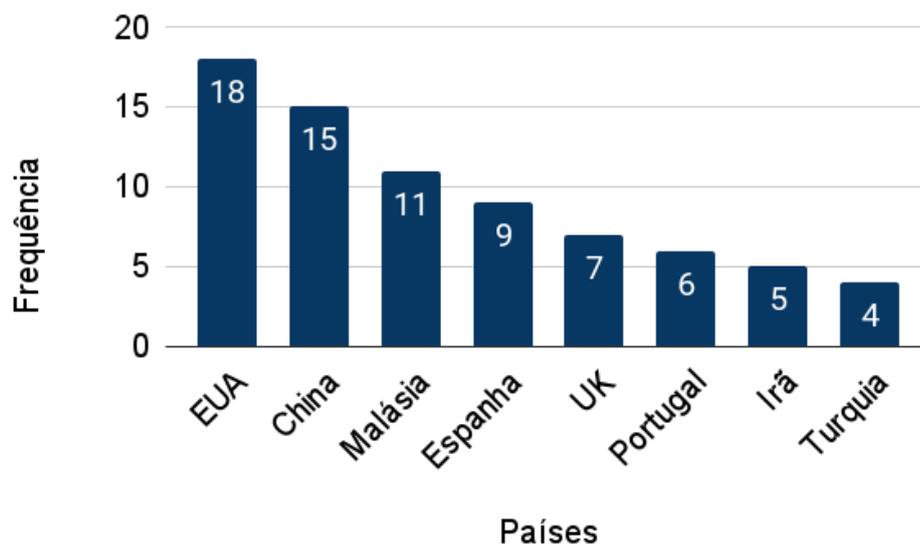
Figura 7 – Quantidade de artigos por setores de serviço.



Fonte: Autoria Própria.

Com uma análise da Figura 8 é possível observar que China e Estados Unidos concentram cerca de 31% dos países de filiação dos autores, se destacando em relação aos demais. Também é notável que outras regiões não se destacam muito em relação aos dois primeiros, como Espanha, Malásia, Reino Unido (UK) e Portugal. O levantamento mostrou que existem apenas dois artigos com autores brasileiros, indicando uma lacuna na produção científica do país para aplicação de ML para analisar qualidade de serviços.

Figura 8 – Quantidade de artigos por países

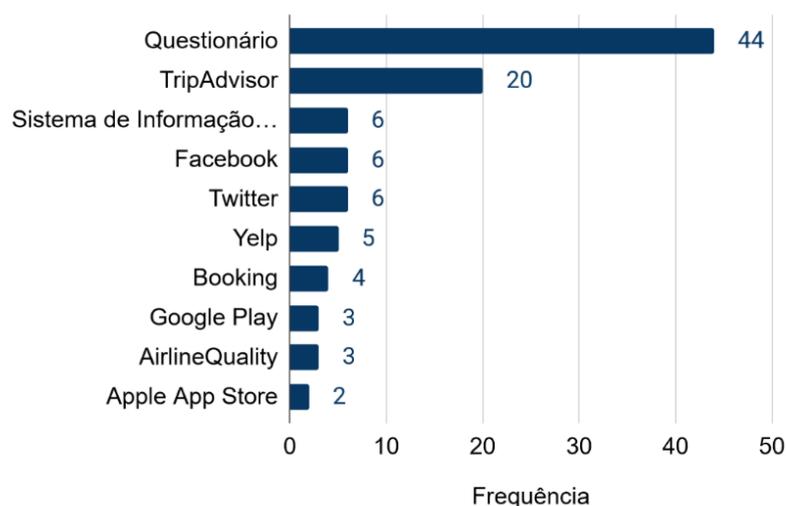


Fonte: Autoria Própria.

As nacionalidades das fontes de dados utilizadas para aplicação das pesquisas com ML também foram coletadas. Os resultados encontrados neste aspecto apresentaram alinhamento com o apresentado pela Figura 7. Os Estados Unidos também é o país que mais originou fonte de dados para os estudos, com 27 ocorrências, seguido da China com 10, Espanha com oito, Malásia com sete, e Turquia com quatro. Os resultados indicaram que apenas um artigo aplicou ML em uma base de dados brasileira, que é o caso de Siebert *et al.* (2020) com a exploração dos dados da ABRADDE (Associação Brasileira de Distribuidores de Energia Elétrica).

A Figura 9 ilustra as fontes de dados utilizadas nos artigos, questionários, sistemas de informação gerencial ou outras fontes de plataformas online. A fonte mais utilizada pelos pesquisadores são os questionários ou *surveys*, que são desenvolvidos pelos próprios autores, ou apenas utilizados os dados de uma pesquisa já realizada. Em seguida está presente o *TripAdvisor*, uma plataforma online para avaliação de hotéis, transporte, pontos turísticos e restaurantes. Este resultado demonstra que a disponibilidade de dados contribui para o desenvolvimento de pesquisas com ML, pois o caso de questionários é o formato mais convencional para analisar satisfação de clientes, e plataformas online possuem dados abertos para acesso.

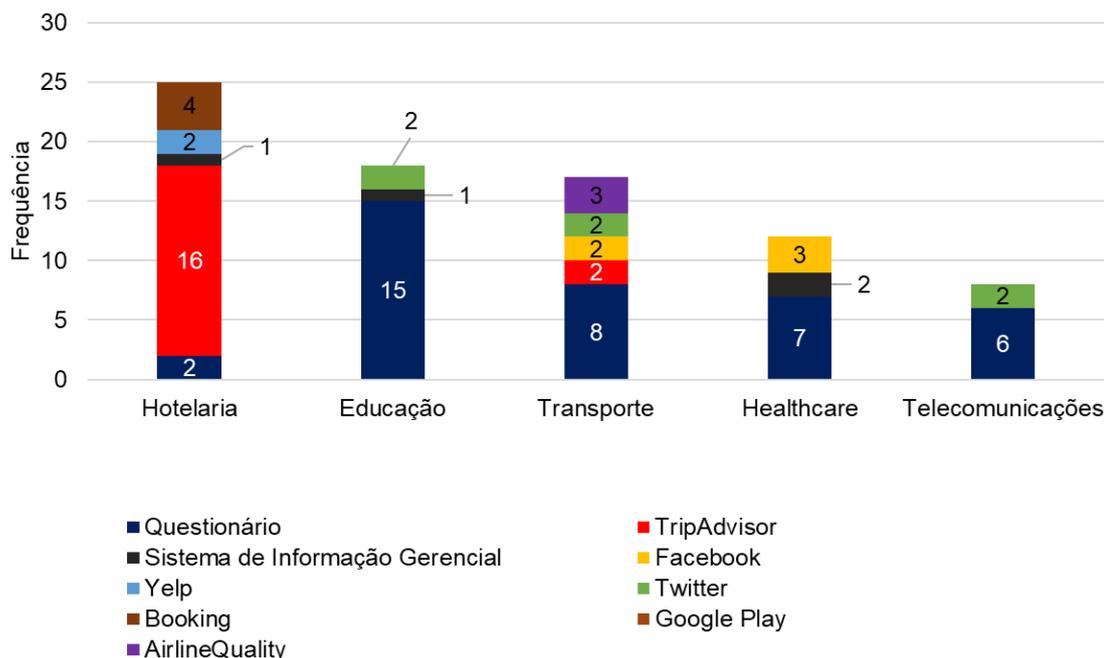
Figura 9 – Quantidade de artigos por fonte de dados utilizados nas pesquisas.



Fonte: Autoria própria.

A Figura 10 mostra a relação dos tipos de dados por setores. O setor de Hotelaria possui predominância na utilização de originários de plataformas online, com aproximadamente 74% dos artigos publicados nessa área extraíram informações destes sites. Todos esses artigos utilizaram do *Tripadvisor*, *Yelp* ou *Booking*, sites de avaliação destinado ao turismo e hotelaria, com o objetivo de classificar ou clusterizar satisfação de clientes. Portanto, este resultado indica que a disponibilidade destes dados possibilitou o desenvolvimento deste tipo de pesquisa para o setor. O mesmo pode-se dizer do setor de transporte, onde 52% dos artigos extraiu dados do *Facebook*, *Twitter*, *TripAdvisor* e *AirlineQuality*.

Figura 10 – Tipo de dados por setores.



Fonte: Autoria própria.

Como apresenta a Figura 10, o setor de educação possui predominância de artigos que utilizaram dados originários de questionários de satisfação. Para este setor, existem muitos casos onde os próprios autores aplicam um questionário dentro da própria instituição de ensino onde trabalharam, e depois utilizam dos dados gerados para aplicação de ML. As publicações de Thomas e Galambos (2004), Turkyilmaz, Temizer e Oztekin (2018) e Skrbinjek e Dermol (2019), são exemplos destes casos. No entanto, existem outros artigos que utilizaram dados de pesquisas de satisfação desenvolvidas por terceiros, como é o caso de Langan e Harris (2019), que aplicaram ML em dados de satisfação de estudantes do Reino Unido.

A Tabela 5 apresenta uma relação da dimensão média das bases de dados encontradas por fonte. Os resultados indicam que a *Yelp* é a fonte que apresentou maior tamanho médio com 1.033.047,40 instâncias por artigo encontrado. As duas fontes que apresentaram segundo e terceira maior dimensão média é o *Booking* e *TripAdvisor*. Por fim, os questionários ficaram apenas em quarto lugar no *ranking* de dimensão média. Este resultado mostra que plataformas online podem resultar em maiores quantidades de dados, neste caso o *Yelp*, *Booking* e *TripAdvisor* são sites destinados ao setor de hotelaria e turismo, e além de possibilitar a oportunidade de pesquisa com dados disponíveis online, também podem resultar em bases de dados com grande quantidade de instâncias.

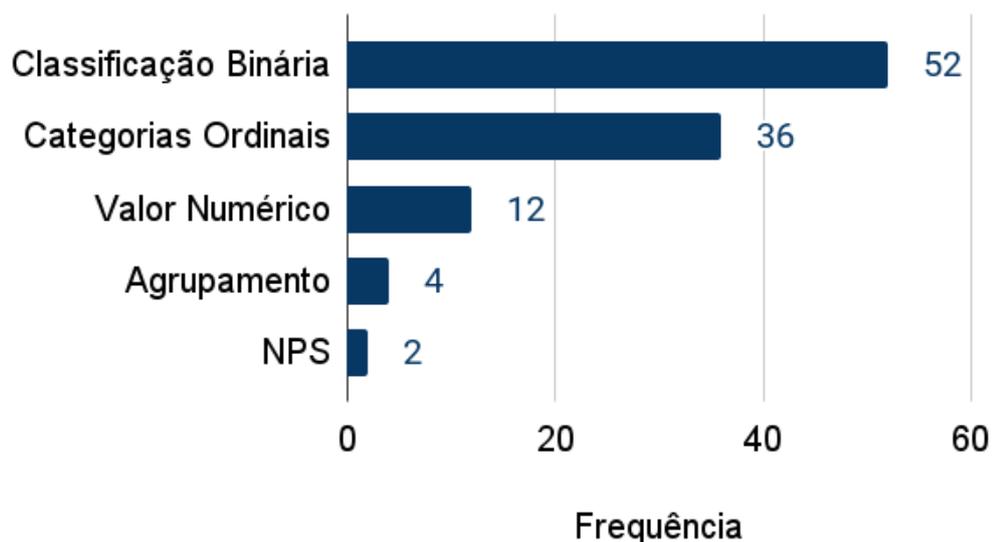
Tabela 5 - Dimensão média do tamanho das bases de dados

Fonte	Dimensão Média das bases de Dados
<i>Yelp</i>	1.033.047,40
<i>Booking</i>	158.899,75
<i>TripAdvisor</i>	122.115,15
Questionário	47.188,36
<i>AirlineQuality</i>	27.909,33

Fonte: Autoria própria.

A Figura 11 apresenta a frequência dos formatos de medição da satisfação de clientes na base estudada. Cada pesquisa utilizou uma variável de saída para definir a satisfação de clientes ou qualidade de serviços, dentre as opções mais comuns estão a classificação binária entre “Satisfeitos” e “Insatisfeitos”, categorias ordinais, valor numérico, agrupamento e NPS. Sendo assim, as duas primeiras são os maiores destaques nas pesquisas encontradas, muito provavelmente devido a sua simplicidade de aplicação e análise. Apenas dois artigos utilizaram NPS, que são os casos de Tong *et al.* (2017) e Markoulidakis *et al.* (2020).

Figura 11 – Quantidade de artigos pela forma como foi medida a satisfação de clientes.



Fonte: Autoria Própria.

Foram encontrados 86 trabalhos que utilizaram técnicas supervisionadas, 18 Não-Supervisionadas, e dois artigos aplicaram algoritmos dos dois tipos. A grande maioria são de aprendizado supervisionado, com tarefas de Classificação ou Regressão. Esses casos são aplicações comuns e objetivas, como atribuir se um cliente está satisfeito ou insatisfeito, classificar seu grau de satisfação com o serviço através de uma escala, ou prever um valor numérico para a qualidade percebida. Ainda para esse tipo, também existem pesquisas que utilizam de ML para explorar as variáveis mais relevantes para o nível da qualidade do serviço.

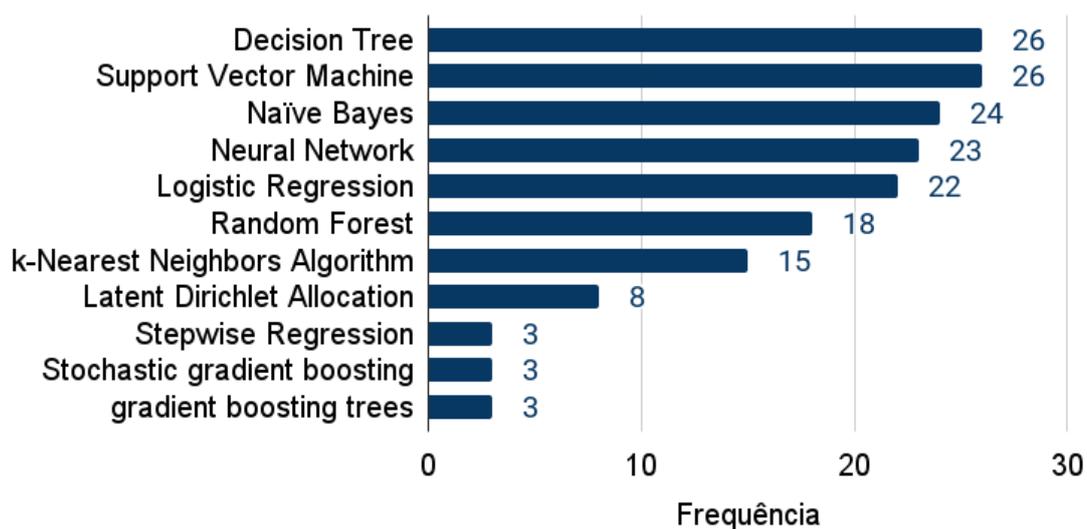
A maioria dos artigos que apresentam técnicas não-supervisionadas são referentes a estudos que aplicam métodos para análise de sentimentos e *Text Mining* para sintetizar a satisfação de serviços. Apesar de utilizarem tarefas de clusterização, esses casos atribuem a distinção entre satisfeitos e insatisfeitos com base em dados textuais, e utilizam a classificação binária como entrada ao método, e não saída. Ou seja, os autores utilizaram estratégia de classificação binária como objetivo final para analisar os clusters de clientes. Alguns exemplos são as pesquisas publicadas por Ali, Wang e Riaz (2020), e Borakati (2021) .

Em relação aos tipos de tarefas abordados nos artigos, 68 utilizaram classificação, 23 regressões e 16 clusterização. Existe uma predominância de artigos que aplicam técnicas para problemas de classificação ou regressão. A primeira é o tipo mais comum, com representação de 64% do total de pesquisas, sendo a maioria no conjunto total. Ngai, Xiu e Chau (2009)

apresentaram uma revisão sistemática da literatura sobre aplicação de ML para gestão de relacionamento de clientes. Na pesquisa as técnicas de classificação também são predominantes para prever comportamento e retenção de clientes.

Como apresentado pela Figura 12, as técnicas de *Machine Learning* mais frequentes foram *Decision Tree*, *SVM (Support Vector Machine)*, *Random Forest*, *Naïve Bayes*, *Logistic Regression*, *KNN (K-Nearest Neighbors)* e redes neurais. Além da tarefa de saída, a *Decision Tree* e *Random Forest* também possuem o recurso de identificar atributos mais importantes, o que pode ser um ponto relevante para a análise de Qualidade. Outra que vale destacar é a *LDA (Latent Dirichlet allocation)*, uma técnica de *Text Mining* não supervisionada aplicada nas pesquisas que utilizam dados textuais, e é a 8ª mais utilizada. Essa última foi a mais aplicada para o caso de agrupamento das informações e segregação binária, com o formato satisfeitos e insatisfeitos sendo utilizados como entrada.

Figura 12 – Técnicas de *Machine Learning* mais utilizadas



Fonte: Autoria Própria.

2.4 CONTRIBUIÇÕES PARA SETOR DE SERVIÇOS

A Tabela 6 apresenta a relação de artigos publicados no setor de hotelaria. Como é possível identificar, a maioria dos artigos publicados neste setor exploram dados extraídos de plataformas online como *TripAdvisor*, *Booking* e *Yelp*. Através de técnicas de ML, alguns artigos apresentam os fatores que mais influenciam na qualidade do serviço dos hotéis, como limpeza, serviço de quarto, localização e segurança. Além disso, alguns artigos apresentam que diferenças culturais de cada hóspede influenciam nesses fatores, o que é um ponto de atenção para a gestão de hotéis. Portanto, para gerir a qualidade de serviços hoteleiros, o processamento de dados extraídos de plataformas online pode ser um meio de baixo custo, e que pode trazer diversas informações importantes para tomada de decisões na operação.

Tabela 6 – Contribuições para serviços no setor de hotelaria.

Referência	Fonte de Dados	Tamanho da Base de Dados	Contribuições para Satisfação de Serviços
Guo, Barnes e Jia (2017)	<i>TripAdvisor</i>	39.287	O artigo apresenta alguns aspectos importantes para a qualidade do serviço e satisfação dos hóspedes, como eficiência do processo de check-in, infraestrutura e experiência da hospedagem.
Antonio <i>et al.</i> (2018)	<i>TripAdvisor e Booking</i>	23.322	O trabalho focou no desenvolvimento e aplicação de ML para processamento de <i>Text Mining</i> e predição com dados de diferentes idiomas.
Moro <i>et al.</i> (2018)	<i>TripAdvisor</i>	967	Para a satisfação dos clientes foi identificado que o número de quartos e o preço mínimo foram os principais atributos para satisfação.
Sánchez-franco, Navarro-garcía e Rondán-cataluña (2019)	<i>Yelp</i>	47.172	Através de ML os autores identificaram que atributos relacionados ao desempenho dos funcionários, atributos físicos como decoração e limpeza são fatores relevantes para a qualidade do serviço de hotelaria.
Lee, Lee e Koh (2019)	<i>TripAdvisor</i>	200.844	Explorou o conceito de <i>Multi-Sensory Marketing</i> , e como alguns atributos podem impactar na qualidade percebida de um hotel, e assim sugeriram práticas como recepção com comida, presença de música ambiente, e incensos para agradar ainda mais os hóspedes.

Sánchez-franco, Cepeda-Carrion e Roland (2019)	<i>Yelp</i>	41.413	Concluíram que a qualidade do serviço está diretamente relacionada com desempenho dos funcionários, limpeza interna, entretenimento familiar, entre outros.
Chang, Ku e Chen (2019)	<i>TripAdvisor</i>	634.277	O estudo concluiu que diferentes tipos de hóspedes podem ter percepções diferentes para a qualidade e satisfação, como por exemplo o caso de hospedagem de pessoas a lazer ou a trabalho.
Hu <i>et al.</i> (2019)	<i>TripAdvisor</i>	27.864	Realizaram um estudo no setor de hotelaria em 2019 e concluíram que os fatores que mais contribuem para a satisfação são transporte, decoração, internet e alimentação.
Brochado, Rita e Moro (2019)	<i>Booking</i>	1.195	Os resultados indicaram que os atributos mais relevantes para a qualidade do serviço variam conforme a cultura e país de origem de cada hóspede. Outro aspecto relevante encontrado é a segurança e localização do hotel.
Ahani <i>et al.</i> (2019)	<i>TripAdvisor</i>	9.128	O artigo apresenta importância relativa de atributos em diferentes clusters, como limpeza do quarto, qualidade do sono, processo de check-in, localização e preço.
Moro (2020)	<i>TripAdvisor</i>	28957	Foi apresentado que as diferenças culturais dos hóspedes influenciam na percepção da qualidade do serviço. Dessa forma os autores sugerem que os funcionários sejam treinados para lidar com diferentes tipos de hóspedes, e assim poder sugerir roteiros de turismo, restaurantes, e serviços do hotel.
Moro <i>et al.</i> (2020)	<i>TripAdvisor</i>	83.688	A partir de aplicações de ML os autores levantaram pesos para os atributos mais relevantes para a satisfação em hotéis. No estudo foi identificado que a sazonalidade não tem um impacto relevante para satisfação, já a experiência com a plataforma online de avaliação, e aspectos como infraestrutura, limpeza, valor, localização e serviço dos colaboradores, tem um impacto maior.
Ahmed e Rodriguez-diaz (2020)	<i>TripAdvisor</i>	5.278	Os autores focaram no desempenho das técnicas de ML. Para este caso, foi argumentado que a regressão múltipla pode ser adequada para análise de sentimentos nas avaliações.

Sutherland e Kiatkawsin (2020)	<i>Airbnb</i>	1.086.800	Os resultados apresentados pelos autores indicam que alguns atributos como localização, qualidade do prédio, acomodação e os anfitriões.
Thu (2020)	<i>TripAdvisor</i>	100.000	Os autores apresentaram que 72,7% dos hóspedes estão satisfeitos com os hotéis no Vietnã, sendo seis critérios que contribuem para a qualidade do serviço, como localização, serviço de quarto, funcionários, refeição e valor.
Tsao <i>et al.</i> (2020)	<i>TripAdvisor</i>	123.793	O artigo argumenta que a análise de textos em redes sociais com ML pode substituir questionários de satisfação. No caso, o foco do texto é apresentar uma sistemática que demonstrou bom desempenho para o objetivo.
Vargas-Calderon <i>et al.</i> (2021)	<i>Booking</i>	606.924	Primeiro foi realizada uma discussão sobre a utilização de ML para analisar dados não estruturados de redes sociais a favor de identificar tópicos relevantes para tomada de decisão. Outros aspectos é que diferenças culturais mudam a perspectiva de qualidade em um serviço hoteleiro, onde é realizado um comparativo entre hóspedes colombianos e espanhóis.
Alhamad e Singh (2021)	<i>Booking</i>	150	Os autores buscaram prever os fatores chave para a satisfação de um hóspede, que foram concluídos como sendo: infraestrutura; conforto; limpeza; funcionários; localização; preço e internet.
Nilashi <i>et al.</i> (2021)	<i>TripAdvisor</i>	1.685	Autores focaram em uma aplicação do método, que consistiu em técnicas de Text Mining, clusterização e classificação.
Xia e Zhang 2021	Questionário	301	Apresenta o uso de redes neurais para estudar o impacto das avaliações online de um hotel na percepção de consumidores. E assim foi apresentado que as análises online também são fundamentais para a qualidade percebida da marca.
Bagherzadeh <i>et al.</i> (2021)	<i>TripAdvisor</i>	1.131.862	Desenvolveram um comparativo de técnicas de ML e <i>Text Mining</i> para Qualidade de Serviços em posts do <i>TripAdvisor</i> , resultando em uma vantagem de métodos “ <i>dictionary-based</i> ” em relação a algoritmos de ML.

Mishra e Panda (2021)	<i>Google Reviews</i>	2.818	Realizaram a exploração híbrida com texto e ML supervisionada, onde concluíram que a qualidade da comida, quartos, segurança e treinamento adequado dos funcionários, são aspectos relevantes para clientes de hotéis sofisticados na Índia
Li et al. (2021)	<i>Bestshan website</i>	4.000	De acordo com os autores, muitos clientes ao avaliarem o serviço apenas deixam comentários escritos e esquecem de atribuir uma Nota ao serviço. Assim, os autores aplicaram e exploraram o uso de alguns modelos de ML para prever o nível de satisfação.
Nilashi et al. (2022)	Questionário e TripAdvisor	1.538	Foi concluído que durante a pandemia, outros aspectos precisam ser considerados para aumentar a qualidade, como distanciamento social, higiene e segurança, e além disso a preocupação com a qualidade geral do serviço pelos clientes aumentou na pandemia.
Oliveira et al. (2022)	<i>TripAdvisor</i>	8.596	Os autores processaram análises de três países diferentes, França, Inglaterra e Portugal. Os resultados indicaram que hóspedes de diferentes países podem ter visões distintas sobre os atributos da qualidade, por exemplo, a satisfação com os funcionários é alta para hóspedes britânicos, porém para portugueses é baixa.
Tanrisevdi, Ozturk e Ozturk (2022)	Sistema de Informação Gerencial	2.851	Os autores aplicaram técnicas de ML em comentários escritos à mão por clientes de hotéis, e argumentam que essa fonte de dados pode trazer maior confiabilidade para análise, pois os clientes escrevem sua percepção sem a influência de outros comentários como o caso de plataformas online. Portanto, o artigo tem como principal contribuição a elaboração de um sistema para analisar comentários de avaliação fora de redes sociais.

Fonte: Autoria própria.

A Tabela 7 apresenta as contribuições dos artigos para gestão da qualidade em serviços de educação. A maioria das publicações realizam processamento de dados extraídos de questionários, que muitas vezes são aplicados nas próprias instituições de ensino dos pesquisadores. Alguns estudos realiza análise da satisfação, e assim levantam quais atributos

são mais relevantes para a qualidade percebida, como didática e apresentação dos professores, atividades extraclasse, ambiente acadêmico e infraestrutura. Outros estudos possuíram foco no desenvolvimento de sistemas preditivos para a satisfação de estudantes.

Tabela 7 - Contribuições para serviços no setor de educação.

Referência	Fonte de Dados	Tamanho da Base de Dados	Contribuições para Satisfação de Serviços
Thomas e Galambos (2004)	Questionário	1.698	Os autores aplicaram <i>Decision Tree</i> em dados de uma universidade para explorar os fatores mais determinantes na satisfação dos alunos. Com isso, foi concluído que atributos como experiência acadêmica, relação com colegas de classe, e o senso de pertencimento, são relevantes para a satisfação dos estudantes.
Dejaeger <i>et al.</i> (2012)	Questionário	9.499	Os autores fizeram o uso de data mining para identificar as variáveis determinantes para a satisfação de estudantes em duas instituições de ensino, e apresentaram que os desempenhos dos instrutores, facilidade no aprendizado e eficiência do ensino estão entre os fatores mais relevantes
Zhang <i>et al.</i> (2017)	Questionário	5.346	Demonstraram que com o uso de Regressão Logística, foi identificado conexões potenciais entre gênero, idade e conteúdo oferecido com a qualidade percebida no ensino dos professores.
Wang, Wang e Hu (2017)	Questionário	157	Apresentam o desenvolvimento de um algoritmo híbrido com <i>Particle Swarm Optimization</i> e <i>Extreme Learning Machine</i> , e assim realizaram análises e aplicações, concluindo o bom desempenho para analisar o ensino de inglês na China.
Turkyilmaz, Temizer e Oztekin (2018)	Questionário	454	O estudo concluiu que a satisfação dos alunos está diretamente ligada pela qualidade do ensino percebida pelos estudantes, a contribuição do ambiente para os objetivos acadêmicos, e a excelência administrativa da instituição.

Langan e Harris (2019)	Questionário	1.841.711	Os autores concluíram que os principais fatores que influenciam a satisfação percebida de estudantes no Reino Unido são o estímulo e ritmo do curso, assim como a didática dos professores dos cursos.
Skrbinjek e Dermol (2019)	Sistema de Informação Gerencial	49	Através da aplicação de <i>Decision Tree</i> os autores identificaram que a diminuição de trabalhos e atividades dentro de sala de aula, e o aumento de tarefas <i>online</i> podem contribuir para otimizar a satisfação dos estudantes. Além disso, também foi identificado uma forte relação entre o desempenho do estudante com a satisfação.
Cunningham-nelson, Bak-tashmotlagh e Boles (2019)	Questionário	Não apresentado	Utilizaram LDA, e apresentou como principal contribuição um processo automatizado para visualizar comentários de alunos.
Hew <i>et al.</i> (2020)	<i>Class Central</i>	6.396	Os autores apresentaram que a avaliação, instrutor e conteúdo tem influência sobre a satisfação de estudantes em cursos online.
Grljevic, Bosnjak e Kovacevic (2020)	<i>Oceni Profesora</i>	3.863	O artigo foca no desempenho das técnicas de ML. Utiliza classificadores como KNN e SVM, concluindo que os algoritmos possuem bons resultados, porém ambos tiveram dificuldades para classificar os sentimentos negativos
Kaur <i>et al.</i> (2021)	Questionário	4.386	Estudo é focado no desempenho das técnicas para prever o nível de satisfação dos estudantes.
Gronberg <i>et al.</i> (2021)	Questionário	742	Apresentaram uma ferramenta denominada “Palaute” para analisar feedbacks escritos de estudantes. Os autores utilizaram LDA no processo de análise, e argumentaram que o software desenvolvido pode contribuir para análise de informações complexas, e levantar fatores que aumentem a satisfação dos alunos, como por exemplo, cursos oferecidos pela instituição, e tempo para concluir as disciplinas.
Borakati (2021)	Questionário	1.067	Utilizou LDA para um curso <i>online</i> , que resultou em tópicos relevantes para a satisfação como acessibilidade da ferramenta online, didática do conteúdo, e interação com os alunos.

Ho, Cheong e Weldon (2021)	Questionário	425	Foco no comparativo de algoritmos de regressão, sendo o <i>Elastic Net</i> o que apresentou a maior acurácia.
Chamorro-atalaya <i>et al.</i> (2021)	Questionário	581	A pesquisa possui foco no desempenho das técnicas de classificação para uma escala de 4 níveis. Foi concluído que o algoritmo Ensemble <i>Bagged Trees</i> possui o melhor desempenho.
Rabaiei, Al-najjar e Ahmad (2021)	Questionário	646	Foi concluído que <i>XGBoost</i> e <i>Decision Tree</i> tiveram melhores resultados para prever o valor numérico da satisfação. Esta pesquisa focou no desempenho das técnicas.
Aydin, Ozturk e Cicek (2021)	<i>Twitter</i>	4.652	Extraíram dados do <i>Twitter</i> sobre um serviço de educação à distância, e com o uso de classificadores, levantou um comparativo de desempenho entre as técnicas, indicando que a Regressão Logística possuiu a melhor performance.
Pérez Rave, Jaramillo Álvarez e González Echavarría (2021)	Questionário	Não apresentado	O artigo tem foco no desempenho das técnicas supervisionadas de ML, que resultaram em uma precisão de 72,2%, apresentando que o estudo tem grande potencial para construir um processo robusto de análise de satisfação para educação.
Imran, Hina e Baig (2022)	<i>Twitter</i>	17.003	Os resultados apresentados pelos autores permitiram identificar que os alunos se adaptaram bem com o formato de ensino online na pandemia, e os principais problemas para o serviço são a falta de recursos e problemas de saúde.
Li (2022)	Questionário	3.371	O artigo tem como foco o desempenho da técnica <i>Decision Tree</i> para classificar a satisfação dos estudantes com a performance dos professores

Fonte: Autoria própria.

A Tabela 8 apresenta a relação de artigos publicados no setor de saúde. As publicações neste setor apresentaram variações de aplicação, pois existem artigos que aplicam ML para analisar a satisfação de um procedimento específico, de hospitais e clínicas, ou de serviços de saúde públicos. Algumas contribuições de destaque são os fatores que mais contribuem para a satisfação, sendo alguns deles o histórico de pacientes, infraestrutura e time de enfermeiros,

comunicação do médico e tempo para atendimento.

Tabela 8 - Contribuições para serviços no setor de saúde.

Referência	Fonte de Dados	Tamanho da Base de Dados	Contribuições para Satisfação de Serviços
James, Villacis Calderon e Cook (2017)	<i>Rate MD e CheckBook</i>	3.712	Com técnicas de <i>Text Mining</i> e ML, os autores apresentaram dois principais fatores para a qualidade de atendimento médico. O primeiro deles é relacionado a processos administrativos, como sistemas de atendimento e pagamento. Outro aspecto é o relacionamento interpessoal, com habilidades do médico e empatia.
Menendez <i>et al.</i> (2019)	Questionário e Sistema de Informação Gerencial	186	Utilizaram regressão logística após um processamento de comentários de pacientes, resultando na conclusão de que a infraestrutura hospitalar, falta de habilidades técnicas dos profissionais, e gestão do tempo, são os fatores predominantes para insatisfação de pacientes.
Kunze <i>et al.</i> (2020)	Questionário	430	Os autores realizaram um estudo para prever a insatisfação do paciente após um procedimento cirúrgico no joelho. A partir do Random Forest foi identificado que alguns atributos como idade, alergia a medicamentos, comorbidades e pré-operatório são mais relevantes para o paciente não ficar satisfeito após a cirurgia.
Kowalski, Esteve e Mikhaylov (2020)	<i>National Health Service website</i>	9.148	São apresentados alguns atributos relevantes para a satisfação de pacientes, como a disponibilidade da agenda, gestão entre outros
Ceyhan, Orhan e Karras (2020)	Sistema de Informação Gerencial	1.000	O artigo tem como foco desenvolver um sistema que classifica comentários positivos e negativos.
Altuntas, Dereli e Erdoğan (2021b)	Questionário	385	Os autores apresentaram que fatores como condições físicas gerais do hospital, acessibilidade, atuação ética dos profissionais e confiança são os principais fatores para qualidade do serviço.

Liu, Ning, Kumara e Reich (2021)	Questionário	26.397	Utilizaram diferentes técnicas de ML como <i>Decision Tree</i> , <i>XGBoost</i> , entre outros. Com isso concluíram que os fatores mais importantes para a satisfação de pacientes são tratamento adequado dos enfermeiros, comunicação e relação com os familiares
Simsekler <i>et al.</i> (2021)	Questionário	411	Concluíram que a idade do paciente, tempo de atendimento e conhecimento dos médicos são os principais fatores para satisfação.
Rahim <i>et al.</i> (2021a)	<i>Facebook</i>	1.200	Os autores argumentaram que dados provenientes do <i>Facebook</i> são gratuitos, e podem gerar informações importantes para tomada de decisão. Por exemplo, no estudo realizado os autores identificaram que confiabilidade, responsividade e empatia são os tópicos de melhoria para os hospitais públicos na Malásia.
Rahim <i>et al.</i> (2021b)	<i>Facebook</i>	1.793	O artigo tem foco no desempenho das técnicas de ML para classificar a satisfação. Os autores apresentaram que esta aplicação pode contribuir para um sistema automatizado para identificar pacientes insatisfeitos com base em textos do <i>Facebook</i> .
Rahim <i>et al.</i> (2021c)	<i>Facebook</i>	1.174	Os autores sugerem a criação de páginas no Facebook para os hospitais públicos, para gerar dados organizados e monitorar as reclamações. Os resultados do artigo mostraram visualizações de dados a partir dos textos do Facebook, e permitiram identificar tópicos de melhoria para o serviço.
Okuda, Yasuda e Tsumoto (2021)	Questionário	3.711	Aplicaram <i>Ward's clustering method</i> para clusterizar dados de uma pesquisa de satisfação para hospitais, e assim apresentou como conclusão que a infraestrutura do hospital, a disponibilidade de certos tratamentos cirúrgicos e disposição da organização em melhorar a qualidade do tratamento, são fatores que influenciam na satisfação dos pacientes
Zobair <i>et al.</i> (2021)	Questionário	492	Os autores realizaram estudo com foco em um sistema preditivo de satisfação em telemedicina, e identificaram que a expectativa do paciente com o serviço, compromisso com horários e humor dos pacientes são atributos importantes para previsão.

Ahani <i>et al.</i> (2021)	<i>Treatment Abroad</i>	2.179	O artigo apresenta um processamento de dados textuais de avaliação de tratamento médico no exterior. Alguns aspectos mencionados para satisfação dos pacientes são o preço, tratamento médico, limpeza e o profissional.
Xu, Wu e Chen (2022)	<i>Good Doctor</i>	7.010	Os autores sugerem que um sistema de avaliação online pode prover aos médicos e pacientes um melhor processo de atendimento. Com isso, os atributos mais relevantes para satisfação do serviço de um médico é o diploma, método de tratamento e quantidade de pacientes atendidos.

Fonte: Autoria própria.

A Tabela 9 apresenta a relação de artigos publicados no setor de transporte. O setor apresenta diversidade de operações abordadas nas publicações, como transporte aviário, público, Uber e serviços logísticos. Para viagens de avião, alguns autores utilizaram técnicas de ML e processamento de texto de plataformas online para analisar a qualidade do serviço, e assim apresentam alguns atributos relevantes como processo de *check-in*, conforto dos assentos e preço. Para o caso de transporte público como metrô e ônibus, alguns atributos de destaques são a acessibilidade, pontualidade e conforto. Para serviços logísticos, os autores focaram em desenvolver um sistema de detecção de clientes satisfeitos e insatisfeitos, como forma de auxiliar lojas e operadores a monitorar o nível percebido pelos seus clientes.

Tabela 9 - Contribuições para serviços no setor de transporte.

Referência	Fonte de Dados	Tamanho da Base de Dados	Contribuições para Satisfação de Serviços
De Oña <i>et al.</i> (2012)	Questionário	858	Os resultados apresentados pelo artigo indicam que a velocidade da viagem, pontualidade, proximidade da parada de ônibus, segurança e tarifa são os principais atributos para qualidade do serviço.
Lin (2013)	Questionário	350	O artigo tem o foco de apresentar um sistema de detecção de nível de satisfação e qualidade para serviços logísticos.
De Oña e De Oña (2015)	Questionário	3.664	Utilizam <i>Decision Tree</i> para levantar os atributos mais relevantes, que foram resultados em pontualidade e comunicação das informações dos transportes.

De Oña e De Oña (2017)	Questionário	858	O artigo tem um foco em comparar o desempenho de redes neurais e <i>Decision Tree</i> para classificar a acurácia.
Bogicevic et al. (2017)	<i>AirlineQuality</i>	901	Os resultados apresentados pelos autores indicaram aspectos ligados ao serviço, funcionários, conforto e entretenimento como os mais frequentes em avaliações de satisfação.
Díez-mesa, De Oña e De Oña (2018)	Questionário	3.365	Os autores apresentaram uma discussão sobre os aspectos mais relevantes para a qualidade do serviço, como infraestrutura interna, acessibilidade, segurança, conforto e pontualidade.
Sezgen, Mason e Mayer (2019)	<i>TripAdvisor</i>	5.120	Os autores processaram dados do <i>TripAdvisor</i> , e apresentaram que alguns atributos como preço baixo podem contribuir com aumento da satisfação, já o desconforto da viagem para insatisfação.
Liu, Li e Li, (2019)	<i>Dazhong-Dianping Shanghai Station Website</i>	25.989	Autores exploraram comentários de avaliação do transporte na China, e apresentaram algumas descobertas como a satisfação dos clientes com as rotas desenhadas, limpeza do ambiente e as tarifas, no entanto apresentam insatisfação com o horário de pico, motoristas e ar-condicionado.
Othman, Hussin e Mahmood (2019)	<i>Facebook e Twitter</i>	500	Coletaram comentários escritos de redes sociais sobre serviços de transporte, concluindo que técnicas de ML e <i>Text Mining</i> tem relevância prática para gestão dessas organizações.
Hong e Park (2019)	Questionário	411	Demonstram o processamento com ML de 411 passageiros de países diversos, concluindo com algumas sugestões para as organizações do ramo, como melhorar o conforto dos assentos para longas viagens
Pirra e Pensa (2019)	Questionário	1.432	Apresentaram que alguns aspectos de qualidade como segurança e custo são essenciais para a satisfação.
Ali, Wang e Riaz (2020)	<i>Facebook</i>	3.853	Desenvolveram a pesquisa com a coleta de comentários no Facebook para viagens da Uber, demonstrando que os clientes em sua maioria reclamam sobre os aspectos voltados ao motorista ou o trajeto

Lucini <i>et al.</i> (2020)	<i>AirlineQuality</i>	55.775	Os autores argumentam que os atributos para a satisfação sofrem alterações com o tempo, como por exemplo, existe uma redução de preocupações com bebidas e comidas, e um aumento para consideração para processo de <i>check-in</i> e bagagens.
Gao, Yang e Qu, (2021b)	Questionário	107488	Os autores apresentam que algumas características do voo e passageiro, assim como atributos <i>wifi</i> , <i>check-in online</i> e bagagem de mão são os atributos mais importantes para a qualidade do serviço.
Osorio-arjona <i>et al.</i> (2021)	<i>Twitter</i>	27603	Os autores apresentaram que uma quantidade considerável de <i>twetts</i> com comentários negativos sobre o metro de Madrid ocorre em dias úteis, em locais do centro da cidade ou em linhas circulares. Além disso, os principais problemas citados pelos usuários são pontualidade e conforto.
Ram, Galztur e Rechavi, (2021)	TAQ&A	Não Apresentado	A partir da análise de dados realizada, identificou-se que para a satisfação do serviço alguns termos mais frequentes como preço, ticket e acessibilidade.
Pineda-jaramillo, Pineda-jaramillo (2021)	<i>TripAdvisor</i>	1235	Os autores apresentaram que alguns aspectos como sistema em horários de pico, porte do ticket e segurança influenciam para a insatisfação com o serviço.
Chatterjee <i>et al.</i> (2022)	<i>AirlineQuality</i>	27052	A principal contribuição do artigo é que ele mensura os atributos do SERVQUAL através de dados extraídos de plataformas online.

Fonte: Autoria própria.

A Tabela 10 apresenta a relação de artigos publicados no setor de telecomunicações. A maioria dos artigos processou dados de questionários com ML para analisar a qualidade do serviço. Dessa forma, algumas descobertas apresentadas mostram relação da qualidade da rede, conexões, atendimento ao cliente e manutenções como principais fatores de satisfação.

Tabela 10 - Contribuições para serviços no setor de telecomunicações.

Referência	Fonte de Dados	Tamanho da Base de Dados	Contribuições para Satisfação de Serviços
Cox, Bell e Glover (1995)	Questionário	749	Com uma análise aprofundada de <i>Decision Tree</i> , alguns tópicos como satisfação com a agilidade do reparo técnico e comunicação, são fatores importantes para aumentar a satisfação dos clientes.
Cox e Bell (1996)	Questionário	800	Evolução do artigo de Cox, Bell e Glover (1996). Neste caso, os autores também apresentaram aplicação de <i>Decision Tree</i> para satisfação de clientes em serviços de telefonia.
Hosseini e Bideh (2014)	Questionário	617	Os autores identificaram alguns atributos relevantes para qualidade do serviço em telecomunicações, como qualidade da rede e conexão, suporte ao cliente, serviços agregados e preço.
Tong <i>et al.</i> (2017)	Questionário	44.610	Apresentaram a aplicação de técnicas como <i>XBoost</i> e <i>Decision Tree</i> aplicados em informações de consumidores, como consumo de dados, tempo de ligações, entre outros, para desenvolver um sistema preditivo de satisfação de clientes.
Susanti, Djatna e Kusuma (2017)	Twitter	5.210	Demonstra coleta de comentários do <i>Twitter</i> , e assim aplica técnicas diferentes para classificação da satisfação. De acordo com os autores, a que apresentou melhor resultado foi a <i>Multinomial Naive Bayes Tree</i> .
Li e Weiwei <i>et al.</i> (2018)	Questionário	108	Foi realizado um experimento com usuários de streaming de vídeos, com aplicação de ML nos dados para explorar a qualidade da experiência de usuários. A pesquisa apresentou um resultado sobre a relação entre as métricas da qualidade com a incidência de falhas no processo de transmissão de vídeos.

Burhanuddin <i>et al.</i> (2018)	Twitter	Não apresentado	Os autores extraíram dados do <i>Twitter</i> para analisar a performance dos serviços de comunicação móvel. Para isso foi usado <i>Naive Bayes</i> com <i>Text Mining</i> e linguagem R, resultando em representações visuais dos dados, sendo possível apresentar direcionamentos práticos para organizações do ramo.
Markoulidakis <i>et al.</i> (2020)	Questionário	450	A pesquisa resultou em alguns atributos de melhoria como conta de pagamento, conexão para voz, conexão para dados e tarifas.

Fonte: Autoria própria.

2.5 AGENDA DE PESQUISA

Este artigo teve como objetivo analisar a literatura científica sobre aplicações de ML para analisar qualidade de serviços. Tais algoritmos podem contribuir com análises complexas de grandes quantidades de dados, e assim gerar informações, sistemas automatizados e visualizações para analisar a satisfação de clientes e qualidade dos serviços. Portanto, os resultados apresentados neste artigo demonstram que o assunto apresentou um crescimento expressivo de publicações a partir de 2016, com abrangência em diversos setores, técnicas e objetivos de pesquisa. No entanto, os dados também demonstram lacunas e tendências para futuras pesquisas.

A Tabela 11 apresenta as principais lacunas identificadas, e que podem ser preenchidas com futuras pesquisas. Cada uma delas possui algumas implicações práticas para a gestão da qualidade em serviços, e foram extraídas com base na análise dos dados da bibliografia. Dessa forma, três principais lacunas foram extraídas como a existência de poucas ou nenhuma publicação em alguns setores (1), disponibilidade de base de dados pouco exploradas (2), e países com baixo número de publicações (3).

Tabela 11 – Principais lacunas para serem preenchidas com futuras pesquisas.

Lacunas	Implicações Práticas
1) Setores de Serviços pouco explorados.	Desenvolvimento de pesquisas em setores pouco explorados na literatura podem contribuir com ideias e recursos de como ML pode ser aplicada para analisar qualidade de serviços.
2) Fonte de dados pouco explorada.	A exploração de diferentes fontes de dados pode contribuir com a extração de novas informações para auxílio na tomada de decisões gerenciais, assim como com o de outros sistemas automatizados
3) Países com baixas publicações.	O desenvolvimento de pesquisa em países pouco explorados pode contribuir com o desenvolvimento dos setores de serviços nos países.

Fonte: Autoria própria.

De 106 artigos publicados sobre aplicação de aproximadamente 60% estão concentrados em três setores de serviços, hotelaria, educação e transporte. Em seguida a estes três primeiros, o setor de saúde também possui uma quantidade expressiva de publicações (15). No entanto, outros setores como telecomunicações, turismo, alimentação e serviços gerais apresentaram uma baixa quantidade de artigos em consideração aos primeiros. Além disso, para os setores público e financeiro, não foram encontrados artigos publicados. Portanto, explorar pesquisas que apliquem técnicas de ML para analisar a qualidade de serviços podem fornecer recursos práticos para empresas dos setores carentes de artigos, e assim contribuir com métodos de aplicação, informações de apoio e direcionamento de base de dados disponíveis.

Como foi possível identificar, a aplicação de questionários possui predominância de aplicação em pesquisas (41,5%). Questionários são meios simples de obter dados, pois podem ser personalizados conforme os objetivos da pesquisa, além de que a aplicação pode ser realizada em universidades e locais próprios de trabalho. Este fato é identificado pela predominância do uso de questionários no setor de educação, pois os pesquisadores aplicam nas próprias universidades. No entanto, alguns setores podem explorar outros dados que podem contribuir para levantamento de novas informações e recursos para análise da qualidade de serviços. Da mesma forma que o setor de hotelaria utiliza dados de plataformas online, os demais setores podem extrair informações de redes sociais, sites de reclamação, aplicativos e outros para analisar a qualidade dos serviços.

Por fim, foi identificado que alguns países possuem poucas publicações em comparação com EUA, China, Espanha, Portugal, Malásia e Reino Unido. O desenvolvimento de pesquisas no setor pode contribuir com o crescimento do setor de serviços no país de aplicação e filiação dos autores. Por exemplo, o Brasil apresenta crescimento do setor de serviços, no entanto o país apresentou apenas duas publicações para aplicação de técnicas de ML para analisar a qualidade de serviços (GOVERNO DO BRASIL, 2022).

2.6 CONCLUSÕES

As primeiras pesquisas encontradas que abordam técnicas de ML para analisar a Qualidade de Serviços são de 1995 e 1996. Desde então, a quantidade de publicações por ano se manteve zerada até o ano de 2004, quando Thomas e Galambos (2004) publicaram um texto que hoje possui o maior número de citações pelo WoS. O padrão baixo se repete de 2004 até 2016, quando o número de trabalhos aumenta consideravelmente até 2021. Isso representa um alto interesse da comunidade científica em explorar o uso de ML para analisar a Qualidade de Serviços.

Apesar do aumento, entender com clareza as causas que motivaram esse crescimento de publicações no período pode ser uma oportunidade de pesquisa. Alguns fatores são claros, como evolução tecnológica e acessibilidade para os dados, no entanto existe uma oscilação no ano de 2020, e um aumento repentino para 2021. Assim, é interessante estudar o comportamento ao longo dos próximos anos, ou explorar outras variáveis que podem ocasionar o comportamento.

Como foi possível identificar, trabalhos relacionados ao objetivo desta pesquisa estão dispersos quase que uniformemente em *journals* de diferentes áreas de estudo, não se limitando apenas a periódicos específicos de ML. Ou seja, isso indica que diversos setores podem usufruir da aplicação dessas técnicas, e assim contribuir com o enriquecimento da bibliografia para diferentes tipos de estudo.

Apesar da distribuição em diferentes *journals*, as publicações se concentram mais em 3 setores de serviços, hotelaria, educação, *healthcare*. Considerando o caso dos hotéis, a acessibilidade dos dados pode contribuir com a quantidade de trabalhos, pois nesse caso a extração de informações de *sites* como *TripAdvisor* e *Booking* possibilitam a facilidade de exploração de dados para pesquisa. No entanto, alguns setores apresentaram falta de trabalhos, como é o caso do Financeiro e Público. Já outros não tiveram resultados expressivos como os 4 primeiros, mas tiveram ao menos 1 publicação, como são os casos de Telecomunicações, Serviços Gerais, Energia, Transporte e Turismo.

Os resultados da revisão bibliográfica mostraram que a maioria dos artigos publicados usaram base de dados com texto, e assim aplicaram técnicas de *Text Mining* e ML para processar as informações. Apesar de menor, a utilização de questionários possui um valor ainda expressivo de publicações (41.5%). Dessa forma, considerar pesquisas que aplicam ML nesses dois tipos de dados são sugestões de pesquisas futuras, pois assim como texto, podem trazer contribuições para a Qualidade de Serviços.

Por exemplo, no setor hoteleiro, a maioria dos artigos extraíram dados de plataformas online, e com ML e *Text Mining* algumas conclusões apresentadas pelos autores podem direcionar ações para aumentar a qualidade de um hotel, como por exemplo, investir em treinamento da equipe, cuidados com infraestrutura interna, entre outros. Já para educação, a maior parte dos artigos utiliza questionários como fonte de dados, com utilização de técnicas como *Decision Tree*, KNN e SVM, resultando em conclusões de desempenho das técnicas, assim como de atributos mais relevantes para a qualidade percebida do ensino.

Portanto, os resultados apresentados neste artigo fornecem à comunidade científica uma análise bibliográfica sobre aplicações de ML para gestão da qualidade de serviços, que possibilita aos pesquisadores identificar diretrizes para o desenvolvimento de novas pesquisas. No entanto, este trabalho apresentou algumas limitações, pois foi utilizado apenas duas plataformas para extração de artigos (Scopus e WoS), e a *string* de busca foi estratificada de forma empírica e estratificada em setores, o que pode ter deixado alguns artigos fora do levantamento. Dessa forma, é sugerido para pesquisas futuras realizar inserção de mais palavras na string, como "*Service Management*" e "*Quality of Service*", e aplicar outras bases de dados, como "PubMed", "*Science Direct*" e "*IEEE Xplore*".

ARTIGO 2: QUALIDADE DO SERVIÇO DE BANDA-LARGA NO BRASIL

O Artigo 2 relata a aplicação de técnicas de ML para análise da satisfação de clientes de banda-larga no Brasil, através de uma base de dados de satisfação da ANATEL. No momento da apresentação desta dissertação, este artigo teve seus resultados publicados nos anais do ENEGEP 2022, e estava sendo preparado para submissão no periódico *Journal of Service Management*. Portanto, a versão final deste artigo pode mudar conforme as revisões apontadas no processo de submissão.

Aplicação de técnicas de *machine learning* para análise da satisfação de clientes de banda-larga no Brasil.

RESUMO

Proposta – A disponibilidade de dados sobre satisfação de em diferentes fontes proporciona oportunidades de pesquisa para aplicação de ML. No entanto, em um levantamento realizado, foi identificado que o setor de telecomunicações brasileiro carece de pesquisas sobre o tema. Além disso, existem dados disponíveis pela Agência Nacional de Telecomunicações (ANATEL) que foram pouco explorados pela literatura. Portanto, este artigo tem o objetivo de explorar dados de satisfação de clientes de banda-larga no Brasil com aplicação de ML.

Método – Com base na escala do Net Promoter Score (NPS), foram construídos três modelos com estratégias distintas para conversão da nota dada pelo respondente em classes de satisfação. Com estes modelos, técnicas de ML foram treinadas e analisadas para classificação dos clientes conforme a satisfação. Por fim, foi realizada análise de atributos mais relevantes com método SHAP e outras técnicas de ML.

Resultados – Foi identificado que algumas técnicas como *Histogram Gradient Boosting* e *Random Forest* apresentaram melhores desempenhos para classificação. Também foi apresentada uma discussão sobre a classificação dos clientes neutros, que indicam perfil incerto para classificação. E por fim, alguns atributos como velocidade de navegação, capacidade de manter a conexão sem quedas e cobrança, foram identificados como um dos principais atributos para satisfação.

Originalidade/Valor – Não existe na literatura um estudo que explorou os dados da ANATEL para satisfação de clientes de banda-larga no Brasil com ML. Portanto, esta pesquisa preenche uma lacuna, e pode contribuir com o desenvolvimento de pesquisas para o setor de serviços brasileiro.

Palavras-chave: *Machine Learning*, Satisfação de Clientes, Qualidade de Serviços, NPS, SHAP.

3.1 INTRODUÇÃO

A literatura científica apresenta diversas aplicações de *Machine Learning* (ML) para auxiliar a gestão da qualidade em serviços. As publicações sugerem várias formas de como esses algoritmos podem contribuir para aprimorar a gestão em prestadoras de serviços, como desenvolvimento de sistemas preditivos de clientes com base na satisfação, análises e identificação de atributos mais relevantes para satisfação (ABIMANYU; POERNOMO, 2019; SIEBERT *et al.*, 2019; KOWALSKI; ESTEVE; MIKHAYLOV, 2020).

Essa diversidade de aplicações advém de características do próprio setor de serviços, o qual pode ser subdividido como transporte, comunicações, hotelaria, saúde, entre outras (ZHANG; MOREIRA; SOUSA, 2021). Cada um desses setores possui particularidades em sua forma de gestão, operações e produtos finais. No entanto, todas as empresas prestadoras de serviço possuem como objetivo comum atender as expectativas do consumidor, através de um planejamento efetivo, análise de falhas e qualidade (ALTUNTAS; DERELI; ERDOĞAN, 2021).

Diferente de um produto físico, onde é possível a mensurar grandezas concretas que atendam as expectativas dos clientes, mensurar a qualidade de serviços é uma tarefa mais desafiadora devido à sua intangibilidade (BERRY; PARASURAMAN; ZEITHAML, 1994). Para superar este desafio, autores como Altuntas e Kansu (2020) argumentaram que para gerir a qualidade de serviços é necessário aproximar a expectativa do cliente com o valor percebido, realizar um planejamento efetivo e reduzir falhas operacionais. Com isso, essa gestão pode trazer inúmeros benefícios para organização, como por exemplo, a retenção de clientes (PRIHATNA *et al.*, 2021).

Devido a necessidade de gerir a qualidade do serviço, muitas organizações utilizam indicadores de satisfação de clientes e qualidade percebida, o que pode ocasionar a geração de uma grande quantidade de dados. Na literatura existem exemplos de bases de dados extraídas de redes sociais e plataformas online, sistemas de gestão interna que empresas geram sobre seus clientes, e pesquisas de satisfação que podem ser aplicadas tanto internamente por organizações, quanto por órgãos nacionais (KUNZE, *et al.*, 2020; LANGAN; HARRIS, 2019; SAMARA; MAGNISALIS; PERISTERAS, 2020). Portanto, a disponibilidade destes conjuntos de dados faz com que seja necessária sua exploração para extração de conhecimento. E dessa forma, muitos estudos aplicam ML com a finalidade de explorar esses dados e gerar conhecimento para aplicação na gestão de serviços.

O setor de telecomunicações engloba prestadoras de serviços com atuações em telefonia fixa, telefonia móvel, banda larga e TV por Assinatura (ANATEL, 2022). A literatura acadêmica sobre o setor de telecomunicações abrange artigos aplicados a qualidade de transmissão em *streaming* de vídeos, retenção de clientes, análise de atributos mais relevantes, construção de sistemas automatizados para classificação e predição da satisfação de clientes, entre outros (HOSSEINI; ZIAEI BIDEH, 2014; LI *et al.*, 2018; TONG, Lili *et al.*, 2017).

Apesar da quantidade de publicações sobre o tema na literatura científica internacional, dentro do território brasileiro não são encontradas muitas publicações sobre aplicação de ML para estudar a qualidade no setor de serviços. Algumas aplicações podem ser encontradas nos trabalhos de Sibert *et al.* (2019) apresentaram um estudo sobre utilização de algoritmos para um sistema preditivo de satisfação de clientes no setor de energia. Já Lucini *et al.* (2020) exploraram e analisaram dados do setor de transporte aéreo em diversos países, e assim levantaram informações sobre o nível de satisfação de clientes com técnicas de ML.

Apesar da baixa quantidade de publicações nacionais, o país dispõe de bases de dados e fontes que podem ser exploradas em pesquisas científicas. A Agência Nacional de Telecomunicações (ANATEL) realiza uma pesquisa de âmbito nacional todo ano, que visa

levantar informações sobre o índice de satisfação de clientes para serviços de telefonia móvel e banda larga (ANATEL, 2022). A base de dados resultante dessa pesquisa é disponibilizada ao público, porém poucos trabalhos científicos realizaram estudos com base nesses dados. O trabalho Albuquerque e Eduardo (2018) utiliza dados do questionário referentes à satisfação de telefonia móvel. Outra publicação disponível é um trabalho de conclusão de curso desenvolvido por Bernardes (2020), que também explorou dados de satisfação para telefonia móvel, com análises estatísticas e aplicação de técnicas de regressão, para traçar os perfis do consumidor e extrair atributos mais relevantes para satisfação.

Considerando os desafios e relevância da qualidade de serviços, bem como os benefícios que técnicas de ML podem proporcionar para o conceito, e a falta de publicações no Brasil e a disponibilidade de dados da ANATEL, esta pesquisa teve como objetivo analisar a satisfação anual sobre prestadoras de serviço de banda larga aplicada pela ANATEL. Para isso foram aplicadas técnicas de ML para classificar os clientes que responderam à pesquisa, e por fim, foram explorados os atributos mais relevantes para o resultado, utilizando métodos de inteligência artificial explicável como SHAP (*Shapley Additive Explanations*) e algoritmos *Random Forest* (RF), *Decision Tree* (DT) e *Gradient Boosting* (GB).

Portanto, o restante deste artigo está subdividido em três seções. A Seção 3.2 (Referencial Teórico) são apresentadas algumas referências sobre aplicação de ML em diversos setores de serviços. A Seção 3.3 (Método) descreve todo o processo da pesquisa, desde a natureza e extração dos dados a como as técnicas foram aplicadas e analisadas. A seção 3.4 de Resultados apresenta os desempenhos das técnicas de classificação e os atributos mais relevantes. Na Seção 3.5 (Discussão) é realizada uma síntese final dos resultados. E por fim a Seção 3.6 (Conclusão) demonstra as conclusões obtidas por meio dos dados e objetivos da pesquisa, assim como sugestões para pesquisas futuras.

3.2 REFERENCIAL TEÓRICO

3.2.1 ML Aplicado à Qualidade de Serviços

A literatura dispõe de uma vasta quantidade de publicações que relatam aplicações de ML para qualidade de serviços. Com base em um levantamento bibliográfico sobre artigos que aplicam ML para qualidade de serviços realizado nas bases de dados *Scopus* e *Web of Science*, no período de 1995 até 2020, a quantidade de artigos sobre o tema cresceu consideravelmente, principalmente depois de 2016, que continuou aumentando até 2021, o último ano do levantamento. Dentro deste conjunto, existem relatos de estudos nos setores de serviços como

hotelaria, educação, saúde, telecomunicações, transporte, turismo, alimentação, serviços gerais e energia.

Os artigos encontrados mostraram que os cinco setores mais estudados são de Hotelaria, Educação, Transporte, Saúde e Telecomunicações. No setor de hotelaria, existem publicações que relatam a aplicação de técnicas não-supervisionadas em dados extraídos de sites como *TripAdvisor*, *Booking*, *Yelp* e *Google Reviews*. Alguns destes artigos aplicam tais métodos para identificar fatores e atributos que levam a satisfação ou insatisfação com o serviço. Com esse tipo de análise, alguns artigos podem levantar conceitos práticos para gestão de hotéis e modelos visuais de análise (AHANI *et al.*, 2019; KWON; LEE; BOWEN, 2022; OLIVEIRA *et al.*, 2022; SÁNCHEZ-FRANCO; CEPEDA-CARRION; ROLDÁN, 2019; SUTHERLAND; KIATKAWSIN, 2020; VARGAS-CALDERÓN *et al.*, 2021).

O setor de hotelaria também possui pesquisas com aplicação de ML supervisionadas. Em alguns deles, as técnicas também são aplicadas para explorar a importância de atributos, e contribuir para análise da satisfação em hotéis. Algumas dessas publicações também realizam extração de dados de fontes *online*, mas também existem pesquisas que aplicaram questionários para clientes de hotéis. Grande parte dos trabalhos estuda a aplicação de algoritmos de ML para classificar o nível de satisfação dos clientes (ALHAMAD; SINGH, 2021; CHANG; KU; CHEN, 2019; MORO, *et al.*, 2020; NILASHI *et al.*, 2022; SÁNCHEZ-FRANCO; NAVARRO-GARCÍA; RONDÁN-CATALUÑA, 2019). Outras pesquisas utilizaram as técnicas para realizar a regressão e obter o índice de satisfação (ANTONIO *et al.*, 2018; LEE; LEE; KOH, 2019; MORO *et al.*, 2018).

Dentro do setor de educação também existem publicações que utilizam ML para gestão da qualidade do serviço. Assim como nos demais setores, as pesquisas desenvolvidas para o setor de educação são variadas, e possuem exemplos com técnicas não supervisionadas e supervisionadas. Para o primeiro tipo, alguns exemplos desenvolveram estudos para explorar fatores relevantes para a satisfação de alunos, principalmente aplicando as técnicas para processar dados em formato de texto (BORAKATI, 2021; CUNNINGHAM-NELSON, S; BAKTASHMOTLAGH; BOLES, 2019; GRONBERG *et al.*, 2021).

Os exemplos de técnicas supervisionadas no setor de educação são mais variados. Alguns estudos analisaram o desempenho de técnicas para prever o nível de satisfação de alunos, tanto com classificação como com regressão (GRLJEVIĆ; BOSNJAK; KOVACEVIC, 2022; HO; CHEONG; WELDON, 2021; PÉREZ RAVE; JARAMILLO ÁLVAREZ; GONZÁLEZ ECHAVARRÍA, 2021). Outros estudos tiveram como objetivo analisar a satisfação de alunos, e assim levantar os fatores mais relevantes para a satisfação através das

técnicas supervisionadas (IMRAN; HINA; BAIG, 2022; TURKYILMAZ; TEMIZER; OZTEKIN, 2018).

O setor de transporte é outro de destaque dentro das publicações de ML para qualidade em serviços. Duas publicações relatam a aplicação de técnicas supervisionadas para comparar o desempenho de diversos algoritmos de regressão (DE OÑA, *et al.*, 2017; LIN, 2013). Outros artigos que também utilizaram ML supervisionadas, focaram em análise de atributos relevantes e extração de informações relevantes em dados do setor de transporte (BOGICEVIC *et al.*, 2017; DE OÑA, R.; DE OÑA, 2015; GAO; YANG; QU, 2021). Por fim, o setor de transporte também possui publicações que relatam aplicação de técnicas não supervisionadas, que foram aplicadas em sua maioria em dados extraídos de redes sociais e aplicativos, como *Twitter*, *Facebook* e *TripAdvisor*. Nestes estudos, são relatadas análises dos atributos mais relevantes para satisfação (ALI, S; WANG; RIAZ, 2020; OSORIO-ARJONA *et al.*, 2021; SEZGEN; MASON; MAYER, 2019).

Além dos setores de hotelaria, educação e transporte, outros também possuem aplicações diversas de ML para qualidade de serviços. O setor de turismo apresenta publicações em que os autores extraíram dados de redes sociais como *TripAdvisor* e *Facebook* (ABIMANYU D POERNOMO, 2019; FARHADLOO; PATTERSON; ROLLAND, 2016; SANGKAEW; ZHU, 2022). O setor de saúde possui estudos com desenvolvimento e extração de dados por meio de questionários (ALTUNTAS; DERELI; ERDOĞAN, 2021; LIU; KUMARA; REICH, 2021). Outros setores como de tecnologia da informação, energia, alimentação e serviços gerais também possuem publicações, mas os exemplos são mais escassos (BAIER *et al.*, 2021; SIBERT *et al.*, 2019a; LUO; XU, 2021; MIRANDA-VALENCIA, 2021).

3.2.2 ML Aplicada à Qualidade De Serviços No Setor De Telecomunicações

O setor de telecomunicações apresenta diversas publicações sobre o tema. Cox, Bell e Glover (1995) e Cox e Bell (1996) foram as primeiras publicações encontradas que aplicam ML para qualidade de serviços. Os autores apresentaram a utilização de *Decision Tree* (DT) para classificar a satisfação de clientes de telefonia móvel através de um questionário de qualidade percebida. Além disso, os autores também demonstraram como o DT pode ser utilizado para extrair os atributos mais relevantes para a satisfação.

Outros autores como Tong *et al.* (2017) e Markoulidakis *et al.* (2020) utilizaram dados de questionários e adotaram o NPS (*Net Promoter Score*) como variável de saída para aplicação

de ML. O primeiro apresenta a aplicação de técnicas como *XBoost* e DT aplicados em informações de consumidores, como consumo de dados, tempo de ligações, entre outros. Os autores argumentam que a construção de um modelo preditivo adequado pode contribuir com a economia de recursos das empresas destinados à elaboração de pesquisas de satisfação. No entanto, os resultados apresentados no artigo são limitados, e, portanto, são sugeridos caminhos para novas pesquisas. Já o segundo artigo, apresenta um bom desempenho de técnicas como Redes Neurais e *Random Forest* (RF), para analisar e classificar NPS.

Os autores Hosseini e Ziaei Bideh (2014) exploraram dados do setor de telefonia móvel no Irã. A pesquisa teve foco na obtenção da importância de atributos utilizando Redes Neurais Artificiais e outras técnicas. Com isso, os autores demonstraram que alguns atributos como serviços de valor agregado, suporte ao consumidor, preço dos planos, sistema de pagamento e qualidade da rede são alguns dos atributos mais relevantes.

O setor de telecomunicações também apresenta relatos de publicações que utilizaram dados extraídos de redes sociais. Susanti, Djatna e Kusuma (2017) e Burhanuddin *et al.* (2018) coletaram informações do *Twitter* para analisar satisfação de clientes em telecomunicações. O primeiro tem foco em serviços de pacotes de dados, e aplica técnica supervisionada como *Nayve Bayes Tree* para classificar o nível de satisfação. O segundo é aplicado a serviços de telefonia móvel e também utiliza ML supervisionada, mas o foco do trabalho é a análise e visualização de dados, com proposta prática para os serviços.

3.3 MÉTODO

3.3.1 Etapas da Pesquisa

O objetivo principal desta pesquisa é aplicar técnicas de ML supervisionadas para analisar a qualidade de serviços de banda larga no Brasil. Para atingi-lo, primeiro foram extraídos dados de uma pesquisa de satisfação da ANATEL, que é aplicada anualmente em todos os estados do Brasil (disponível em: <https://github.com/mrelero/dados-pesquisa-matheus-elero-UEM>). Um dos atributos da base diz respeito ao grau de satisfação geral do cliente (identificada por “J1”) usando uma escala entre 0 e 10, o qual foi utilizado para determinar a classe de satisfação de cada respondente.

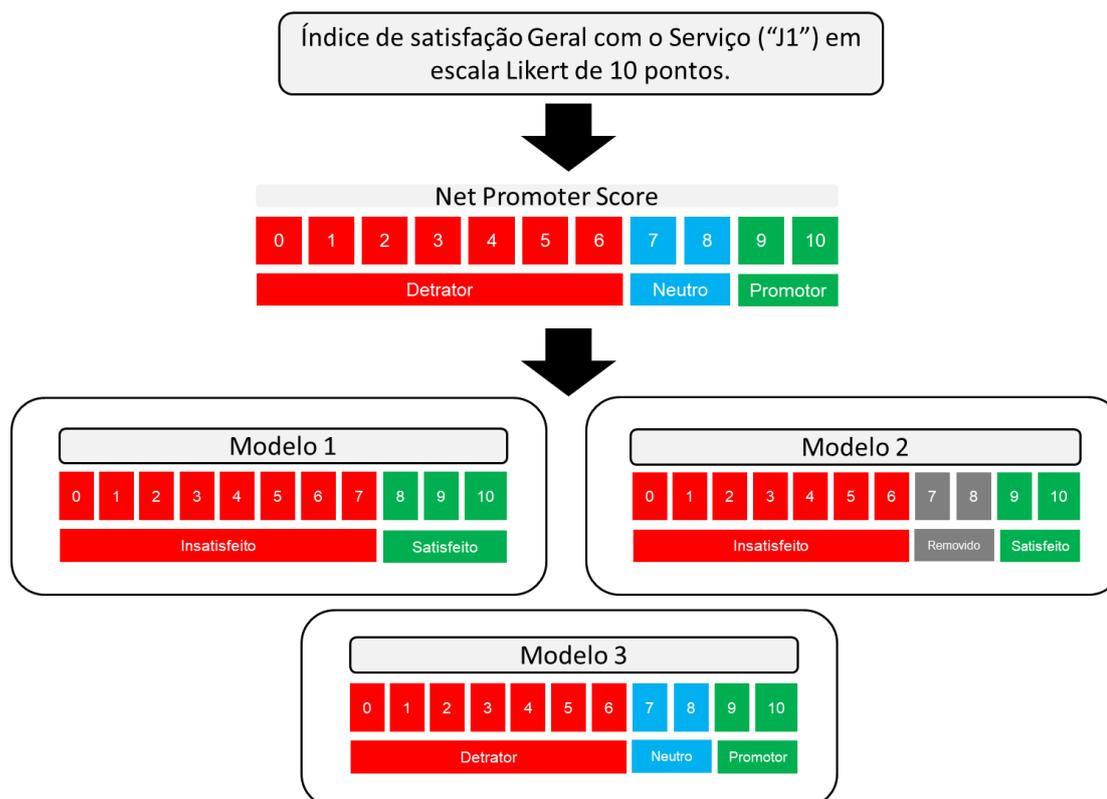
O NPS é um indicador utilizado por empresas prestadoras de serviço para aferir o nível de lealdade de um cliente. Através de uma escala de 0 a 10, os clientes são perguntados “De 0

a 10, qual a possibilidade de você recomendar uma determinada empresa para outra pessoa?”. Os clientes são classificados conforme sua pontuação respondida, sendo que se o índice respondido for acima ou igual que nove eles são chamados de “Promotores”, igual a sete ou oito são atribuídos como “Neutros”, menor ou igual que seis eles são classificados como “Detratores” (REICHHELD, 2003). Como o índice de satisfação geral do serviço é uma também escala *likert* de 10 pontos, o NPS foi utilizado como referência para construir três modelos.

Apesar de amplamente utilizado, na literatura existem publicações que apresentam análises críticas sobre a aplicação do NPS. O trabalho de Kristensen e Eskildsen (2011a) apresentaram uma análise comparativa com NPS e outras métricas através de dados simulados, e assim indicaram que o agrupamento em promotor, neutro e detratador possui variações e pode ser impreciso para o resultado final do indicador. Outro trabalho dos mesmos autores, também indicaram baixa precisão no indicador, e alertam que a aplicação da medida pode levar a decisões erradas durante o processo gerencial (KRISTENSEN; ESKILDSEN, 2011b).

A Figura 13 apresenta um descritivo sobre os três modelos que foram utilizados para a pesquisa. Com base na escala do NPS, cada modelo foi obtido ao utilizar estratégias distintas para conversão da nota dada pelo respondente em classes de satisfação. O Modelo 1 é uma base de dados para classificação binária, em que clientes que responderam acima ou igual que 8 são satisfeitos, e 7 ou inferior são insatisfeitos. O Modelo 2 representa apenas as classes Detratador e Promotor do NPS, sem os Neutros, ou seja, foram removidos todos os clientes que atribuíram nota 7 e 8, deixando apenas os dois extremos. Por fim, o Modelo 3 considera as três classes do NPS simultaneamente.

Figura 13 – Descrição dos Modelos aplicados na pesquisa.



Fonte: Autoria própria.

O Modelo 1 tem como limiar de distinção entre satisfeitos e insatisfeitos o meio da escala que é considerada neutra, ou seja, clientes que atribuíram nota 8 pertencem ao grupo de satisfeitos, e 7 aos insatisfeitos. Como os clientes atribuídos como neutro pelo NPS representam uma região de indefinição, o Modelo 1 teve como objetivo analisar a aplicação de ML considerando uma parcela dos neutros como satisfeitos e outra e insatisfeitos. Os resultados foram importantes para identificar o impacto no desempenho das técnicas, e quais os atributos mais relevantes para a classificação.

Já o Modelo 2 desconsidera os clientes neutros, e, portanto, teve como objetivo analisar quais impactos ocorrem no desempenho das técnicas sem estas instâncias. Dessa forma, este modelo é relevante para responder duas questões sobre o NPS:

- **Q1:** O NPS consegue diferenciar os satisfeitos dos insatisfeitos ?
- **Q2:** Os neutros são mais satisfeitos ou insatisfeitos ?

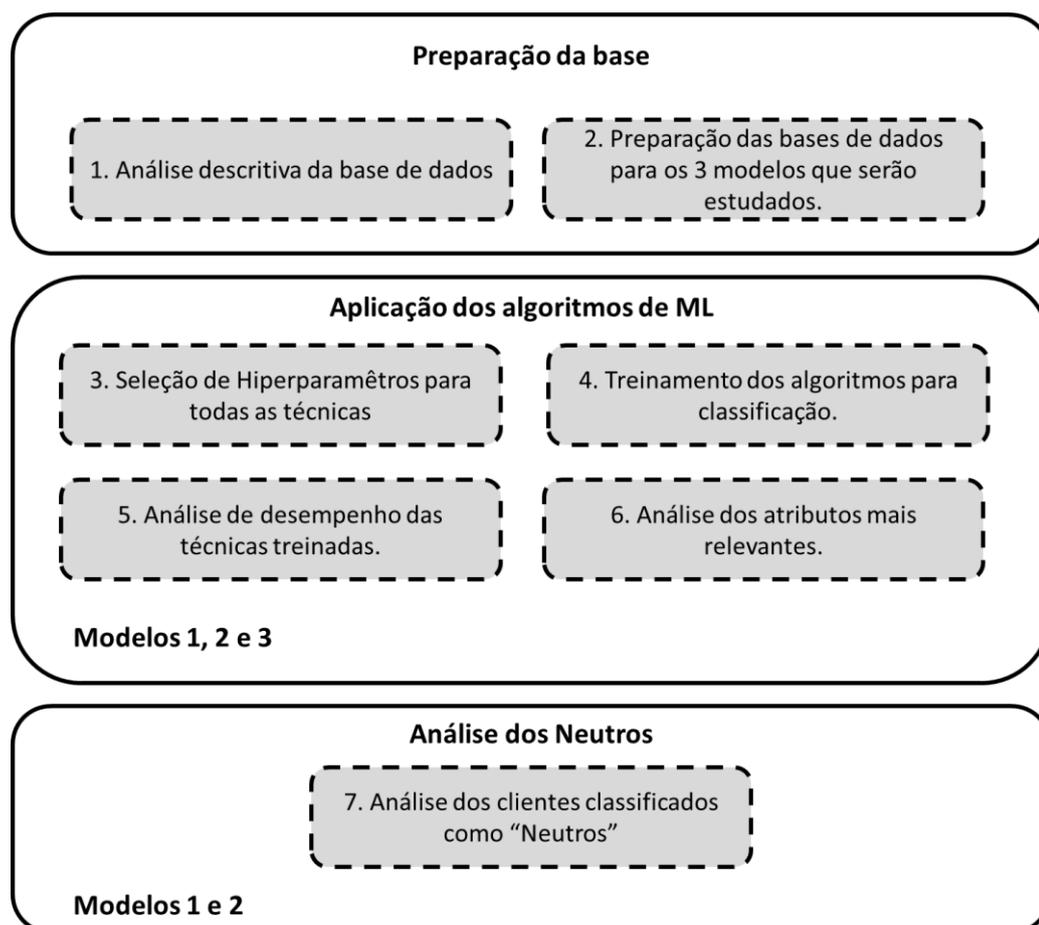
Portanto, este modelo é relevante para comparar os dados resultantes do Modelo 1, e também analisar como as técnicas de ML classificam estes dados incertos conforme seus critérios de treinamento.

O Modelo 3 possui natureza de dados para aplicação de técnicas de ML para

classificação múltipla. Dessa forma, este modelo teve como objetivo realizar aplicação de ML utilizando os critérios de subdivisão do NPS de forma integral. O Modelo 3 teve a finalidade de extrair o desempenho das técnicas para classificar os dados em promotores, neutros ou detratores. Como os modelos 1 e 2 exploram a inserção ou não dos neutros na base, este modelo é relevante pois utiliza todas as classes, e utiliza as categorias do NPS sem manipulações.

A Figura 14 apresenta um fluxo resumido da pesquisa. De acordo com o objetivo geral de analisar a qualidade de serviços de banda larga no Brasil, com a aplicação de técnicas de ML em dados da ANATEL. Existem três macro etapas da pesquisa, Preparação da base, onde os dados foram analisados e trabalhados para a fase seguinte, Aplicação dos algoritmos de ML, onde as técnicas foram treinadas e analisadas em todos os modelos. Por fim, foi realizada uma análise dos clientes neutros utilizando os algoritmos treinados nos modelos 1 e 2.

Figura 14 – Etapas da pesquisa.



Fonte: Autoria própria.

A Tabela 12 apresenta um descritivo de cada etapa da metodologia. Em resumo, todos os modelos têm aplicação de ML para classificação e análise de atributos, diferenciando apenas

na característica e composição da saída. Vale destacar que o Modelo 1 e Modelo 2 possuem uma etapa adicional, que consiste na aplicação dos algoritmos treinados nestes modelos para classificar os clientes categorizados como neutros pelo NPS.

Tabela 12 – Descrição das etapas de pesquisa.

Etapas	Descrição	Recursos	Descrição
1	Análise descritiva da base de dados	Glossário da Pesquisa, Python com Bibliotecas Pandas, <i>Matplotlib</i> , <i>Mis-signo</i> , <i>Numpy</i> .	Download da base de dados, construção de um Fluxograma geral da pesquisa, análise descritiva dos dados
2	Preparação das bases de dados para os 3 modelos que serão estudados.	Python com bibliotecas Pandas, <i>Numpy</i> e <i>scikit-learn</i> .	Remoção de células vazias, seleção de um recorte da base de dados, construção dos três modelos, preparação das bases de treinamento e teste
3	Seleção de Hiperparâmetros para todas as técnicas.	Python com bibliotecas <i>scikit-learn</i> e pandas.	Construção do espaço de busca com os hiperparâmetros e aplicação do <i>Grid Search</i> .
4	Treinamento dos algoritmos para classificação.	Python com bibliotecas <i>scikit-learn</i> e pandas.	Treinamento dos algoritmos utilizando os parâmetros encontrados no <i>Grid Search</i> , com <i>houldout</i> 50% da base para treinamento.
5	Análise de desempenho das técnicas treinadas.	Python com bibliotecas <i>scikit-learn</i> e pandas.	Análise do desempenho das técnicas treinadas através das métricas acurácias, precisão, <i>recall</i> e pontuação F1.
6	Análise dos atributos mais relevantes	Python com bibliotecas <i>scikit-learn</i> , pandas, SHAP e <i>matplotlib</i> .	Análise dos atributos mais relevantes para classificação da satisfação, conforme técnicas RF, DT, GB e método SHAP.
7	Análise dos clientes classificados como Neutros	Python com bibliotecas <i>scikit-learn</i> , pandas e <i>matplotlib</i> .	Foi utilizado as técnicas treinadas no Modelo 1 e Modelo 2 para classificar os clientes classificados como Neutro pelo NPS.

Fonte: Autoria própria.

3.3.2 Base de Dados

A base de dados para desenvolvimento deste trabalho foi extraída de uma pesquisa de satisfação de clientes da ANATEL (disponível em: <https://github.com/mrelero/dados-pesquisa-matheus-elero-UEM>), aplicada anualmente entre os anos de 2015 a 2020, para usuários de serviços de banda larga (ANATEL, 2020). Para leitura de informações detalhadas da composição da base de dados, a ANATEL disponibiliza um glossário com descrição, tipo dos campos e fluxo de pesquisa (ANATEL, 2022).

De acordo com o manual de pesquisa publicado pela ANATEL (2018), a agência sorteia os clientes que participarão da pesquisa a partir de bases enviadas pelas provedoras. Em seguida, essa relação é enviada para uma empresa terceirizada, que realiza uma nova randomização dos dados e aplica o questionário por meio de entrevistas por telefone. A base de clientes recebida pela pesquisadora possui até 40 vezes o número de amostras calculadas pela agência.

Os resultados extraídos entre os anos de 2015 a 2020 apresentam 147.777 respostas, que representam cada linha da base de dados, e 63 colunas que são equivalentes às perguntas da pesquisa. O questionário foi aplicado em todos os estados brasileiros e 16 operadoras, como Oi, Net, Vivo, Sky, GVT, Claro, Tim, Algar, *Big Brasil*, *Brisanet*, *Hughes*, Sercomtel, Cabo Telecom, Unifone, Copel e *Multiplay*.

A Tabela 13 apresenta quais os tipos de pergunta e resposta que existem no questionário da ANATEL. As 63 colunas da base de dados possuem quatro tipos de dados, sendo que para as variáveis “livre” e “seleção”, existe uma mistura de texto e números. Para respostas binárias, o valor assume duas opções “1” ou “2”, onde “1” é “sim” e “2” é “não”. Por fim, a escala *Likert* é um número inteiro entre 0 e 10, e representa o nível de satisfação de um determinado atributo.

Tabela 13 - Formatos de questões do questionário.

Tipo	Descrição
Livre	Campo livre para preenchimento, como quantidade de pessoas na família e renda mensal familiar.
Seleção	Seleção em lista suspensa de opções, como estado, operadora, área de trabalho do entrevistado, sexo, pessoa física ou jurídica, e faixas de idade.
Sim ou Não	Respostas para perguntas objetivas sobre a execução de uma determinada ação pelo cliente. Por exemplo, se o consumidor solicitou reparos na instalação da internet.

Escala *Likert* de 10 pontos Nível de satisfação de 0 a 10 sobre um determinado atributo do serviço.

Fonte: Autoria própria.

Conforme mostra a Tabela 14, o questionário de pesquisa é dividido em quatro partes. Para algumas etapas, o fluxo de informação é direto, ou seja, o respondente segue as perguntas de forma sequencial e responde a todas. Entretanto para outras partes, com a área de satisfação específica, o cliente só responde algumas perguntas condicionadas às respostas de outras questões. Com exceção de perguntas demográficas e de perfil, como estado, operadora e ano, cada item do questionário é nomeado com um código, que também nomeia a respectiva coluna da base de dados.

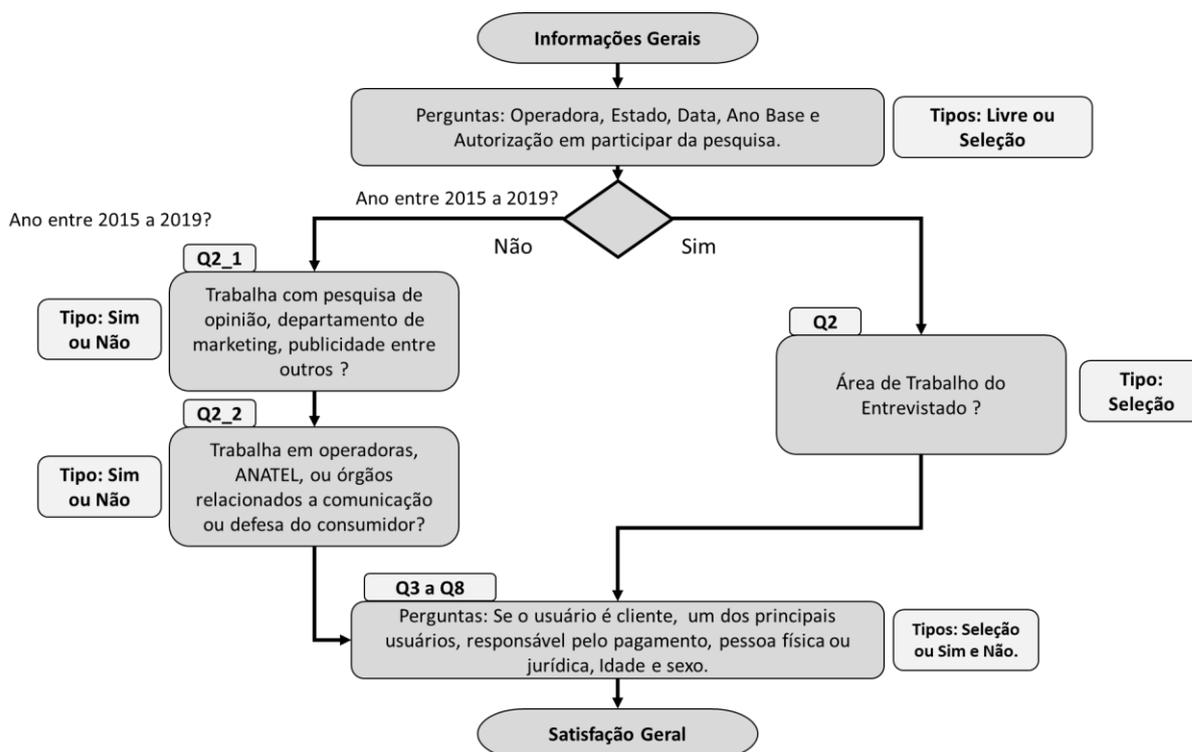
Tabela 14 - Seções do questionário.

Parte	Perguntas
Informações Gerais	Identificação, tipo, operadora, estado, data, ano, área de trabalho, tipo do usuário, pessoa física ou jurídica, idade e sexo.
Perguntas de Satisfação Geral	Nível de satisfação com serviços no geral, comunicação dos planos, comprometimento, cobrança, capacidade de manter conexão sem quedas, velocidade de navegação e informações da conta.
Perguntas de Satisfação Específica	Perguntas de sim ou não caso o cliente já tenha entrado em contato pelos canais de atendimento, já tenha realizado contato para falar de problemas, solicitado alteração no plano, cancelamento, instalação e reparos. Para cada uma dessas perguntas, em caso de responder sim, o cliente deve indicar o nível de satisfação de como a prestadora de serviço se saiu com as ações. Subdividida em Partes 1 e 2.
Informações Demográficas	Existência de concorrência na região, quantidade de pessoas na família, renda mensal familiar, autorização de uso dos dados e município.

Fonte: Autoria própria.

O fluxo da primeira parte do questionário é apresentado pela Figura 15. Nota-se que essa parte possui perguntas sequenciais, e todas devem ser respondidas. No entanto, a pesquisa realizada pela ANATEL mudou o formato da pergunta sobre a área de atuação em 2020, e, portanto, a pergunta com código Q2 só possui dados para respostas entre os anos 2015 e 2019, e para 2020 as respostas estão alocadas nas colunas Q2_1 e Q2_2. A mudança realizada pela ANATEL consistiu em alterar o tipo de resposta de seleção para binário sim ou não.

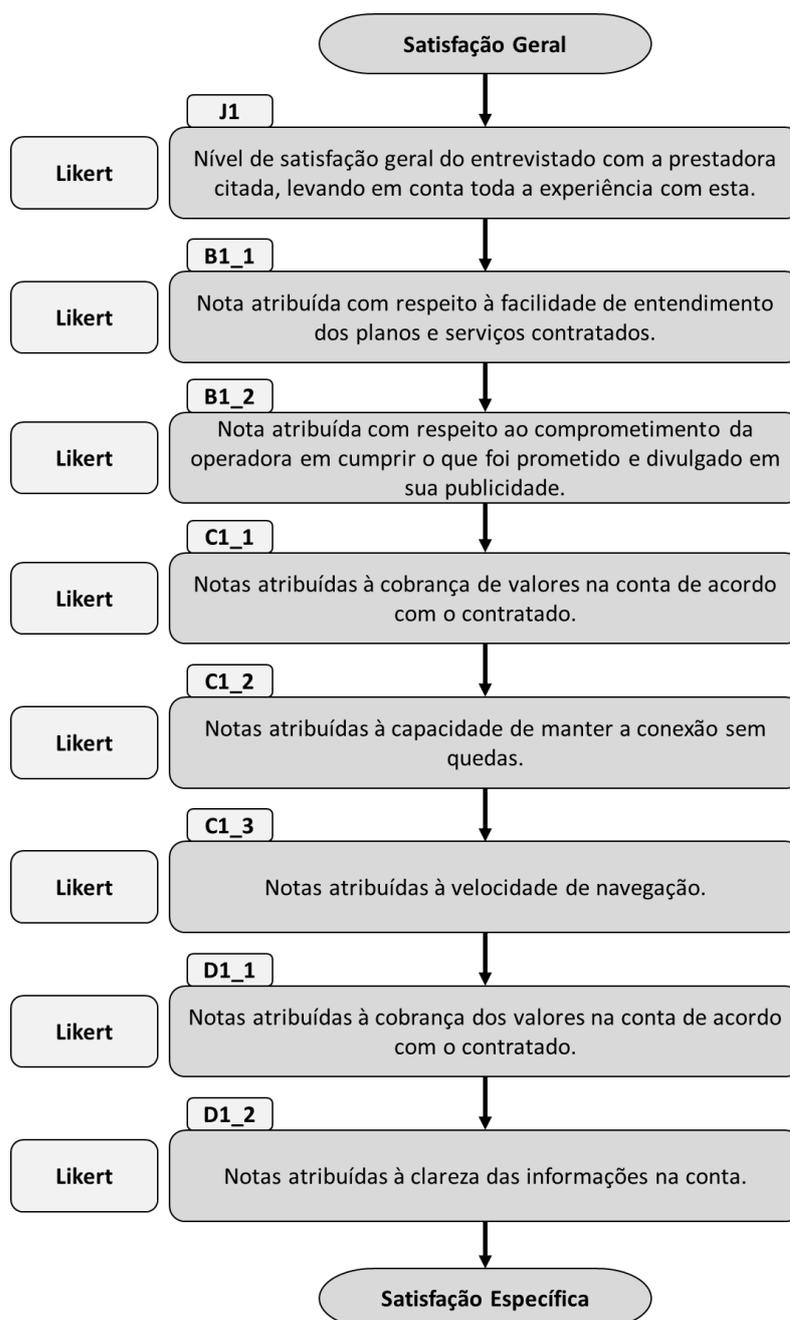
Figura 15 - Fluxo do questionário para área de informações gerais.



Fonte: Autoria própria.

A Figura 16 mostra o fluxo de pesquisa para itens de satisfação geral. Após preencher as informações gerais, o cliente que responde o questionário vai para a segunda etapa, a qual avalia alguns aspectos da qualidade do serviço, atribuindo uma nota de 0 a 10, ou caso não saiba responder é alocado 97, 99, 999 ou 9999 no resultado da pergunta. Nesta etapa, o respondente avalia todos os atributos de forma sequencial, ou seja, nenhuma pergunta de satisfação geral fica em branco.

Figura 16 – Fluxo do questionário para área de satisfação geral.

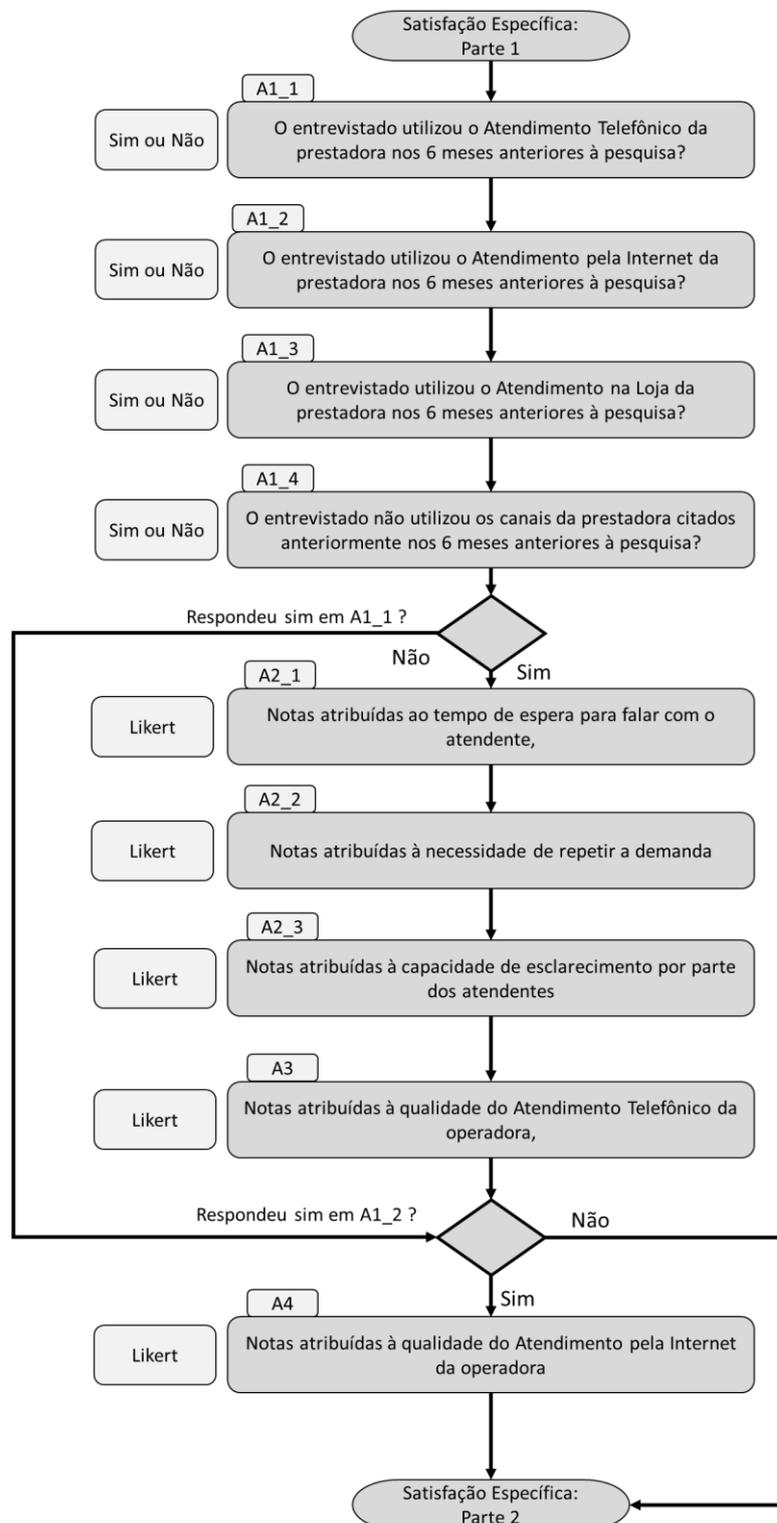


Fonte: Autoria própria.

A etapa de satisfação específica é a mais longa, e para facilitar seu entendimento, ela foi dividida em duas partes. A primeira é mostrada pela Figura 17, e basicamente explora se o cliente utilizou algum canal de atendimento nos seis meses anteriores à participação na pesquisa. Em caso de afirmação para o serviço telefônico ou pela internet, o respondente deve avaliar alguns atributos do ocorrido. Essas respostas geram uma particularidade nas colunas na base de dados. Em caso de uma resposta “sim”, as perguntas A_1, A_2, A_3 e A_4 assumem

valores 1, 2 e 3 respectivamente, e em caso de negativa a célula fica vazia. Caso o respondente não saiba fornecer esta informação, é atribuído valor 97 na célula.

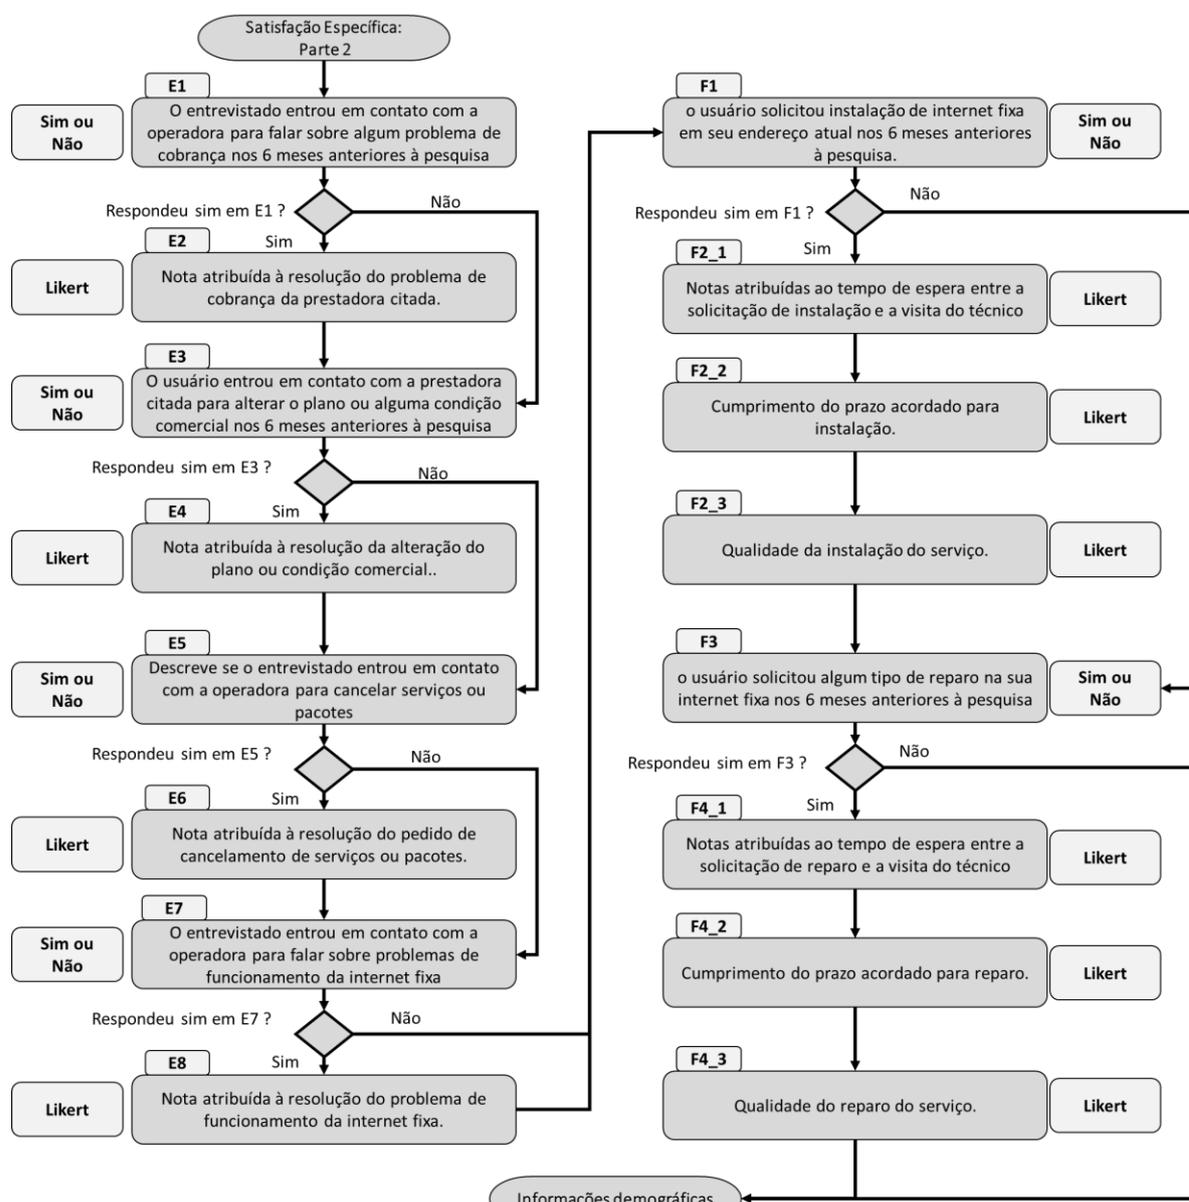
Figura 17 - Fluxo do questionário para satisfação específica Parte 1.



Fonte: Autoria própria.

A parte 2 da etapa de satisfação específica é descrita pela Figura 18. O fluxo segue um padrão para todas as perguntas. Nesta etapa o cliente é questionado se solicitou alguma demanda da prestadora, como por exemplo, solicitado algum reparo ou atendimento financeiro, caso a resposta seja “sim”, o cliente avalia como a empresa desempenhou a sua solicitação. Algumas perguntas como “suporte à instalação” e “reparos” possuem alguns atributos mais detalhados para análise do cliente. Essa parte é importante para entender a composição da base de dados, pois caso um respondente coloque uma negativa em uma pergunta, a célula de avaliação ficará vazia.

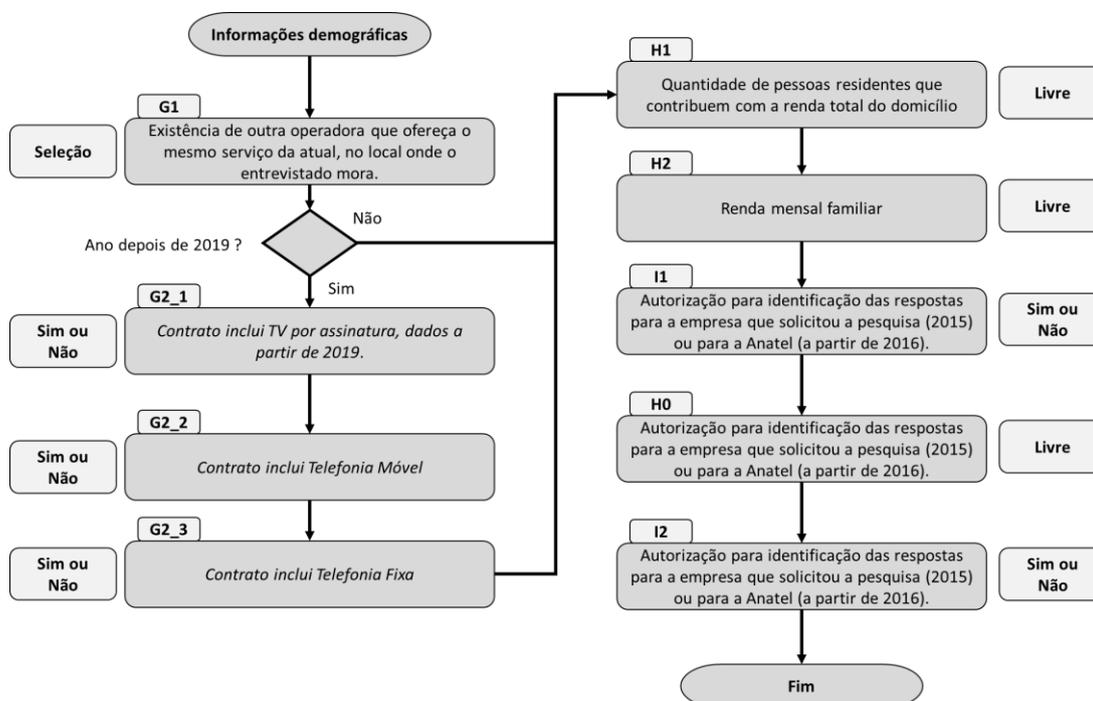
Figura 18 - Fluxo do questionário para satisfação específica Parte 2.



Fonte: Autoria própria.

A Figura 18 apresenta a última etapa do questionário, referente às informações demográficas. Neste caso, o cliente que participa da pesquisa informa alguns dados como existência de concorrência na região, quantidade de familiares, renda mensal, município, entre outros. A partir de 2019 foram incluídas mais três perguntas relacionadas à existência de concorrência na região, com algumas informações mais detalhadas, por isso esses atributos encontram-se vazios para o período de 2015 a 2019.

Figura 19 - Fluxo do questionário para informações demográficas.



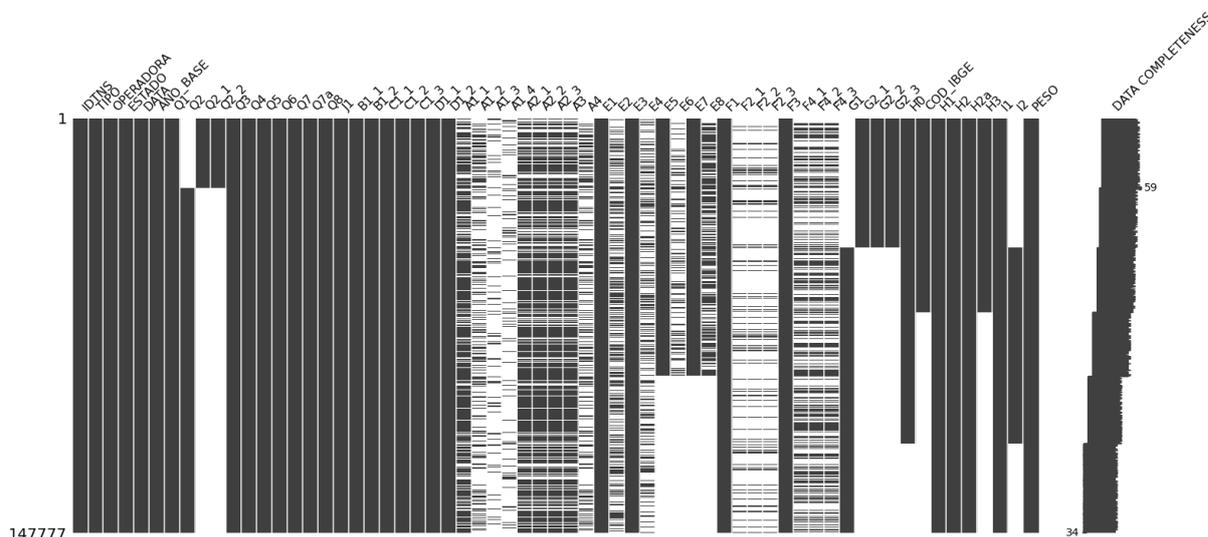
Fonte: Autoria própria.

3.3.3 Preparação da Base de Dados

A Figura 20 apresenta uma matriz de dados faltantes. Nesse gráfico, é possível entender melhor a estrutura do questionário e suas ramificações. Observa-se que a coluna Q2 está presente apenas entre 2015 e 2019, e que as colunas Q2_1 e Q2_2 aparecem apenas em 2020, e por esse motivo que a partir de uma determinada linha, as colunas estão vazias. As perguntas E2, E4, E6 e E8 só são respondidas caso seja respondida “Sim” para as perguntas anteriores a ela, ou seja, algumas células estão vazias pois o cliente respondeu à questão de forma negativa. Por exemplo, a questão E3 pergunta ao cliente se ele entrou em contato com a operadora para alterar um plano nos últimos seis meses, caso ele responda sim a este questionamento, ele em

seguida responde à questão E4, referente a satisfação com este serviço prestado pela operadora, e caso seja respondido não, não é respondida à pergunta E4.

Figura 20 – Diagrama de células vazias na base de dados.



Fonte: Autoria própria.

A base de dados investigada permite a utilização e manipulação em diversas configurações. Como o recurso possui questões condicionais, um recorte de 5 anos, abrangência nacional e 147.777 linhas, o mesmo arquivo pode gerar outras bases de dados para aplicação de ML. Para esta pesquisa, primeiro foi realizada uma preparação inicial dos dados, e depois eles foram utilizados para criação de 3 modelos com base na coluna de saída “J1” e indicador NPS.

A Tabela 15 apresenta as três etapas realizadas para preparação da base de dados. A primeira preparação consistiu em identificar o recorte dos dados utilizados, remoção de colunas, linhas com células vazias e repostas às quais o cliente não sabia responder. O período utilizado foi de 2017 a 2020, pois algumas perguntas relacionadas aos concorrentes (G1, G2_1, G2_2 e G2_3) só foram incluídas a partir de 2017. Não foram adotadas restrições de idade, estado, remuneração, sexo e quantidade de pessoas usuárias do serviço de banda-larga. Após esta etapa a base de dados passou de 147.777 linhas para 91.935 linhas.

Tabela 15 – Etapas de preparação da base.

Etapa	Quantidade de colunas após a etapa	Quantidade de linhas após a etapa
Limitação da data para de 2017 a 2020.	63	91.935
Remoção de colunas	25	91.935
Remoção de instâncias que possuíam identificadores de que a pergunta não foi respondida.	25	64.647

Fonte: Autoria própria.

Para ampliar a proporção utilizada da base de dados foram consideradas as colunas em que os clientes responderam sim ou não para um determinado assunto, como por exemplo E2, E4, E6 e E8, e conseqüentemente removidos as perguntas condicionadas a estas questões. Portanto, foram removidas as colunas A2_1, A2_2, A2_3, A1_4, A3, A4, E2, E4, E6, E8, F2_1, F2_2, F2_3, F4_1, F4_2 e F4_3. Outras colunas com dados repetidos, irrelevantes, generalizados, ou com poucos dados, também foram removidas as colunas Q2, Q2_1, Q2_2, Q3, Q4, Q7a, IDTNS, G1, G2_1, G2_2, G2_3, PESO, Q1, Q6, H3, COD_IBGE, H2a, I2 e H0. Depois deste processamento, a base de dados passou de 63 colunas para 25. A descrição de cada uma das colunas pode ser vista no Apêndice A.

Como foram removidas as colunas com respostas condicionadas, ou seja, aquelas que só eram respondidas conforme uma pergunta anterior a ela, a base não apresentou células vazias. Em seguida foram removidas aquelas células com valores identificadores de que o cliente não respondeu à pergunta. De acordo com o ANATEL (2018) respostas com 99, 999, 9999 e 99999 são consideradas respostas em que o entrevistado não soube responder, por isso, todas as linhas que apresentaram tais valores foram removidas, resultando em um total de 27.288 instâncias excluídas. Por fim, colunas com valores categóricos foram transformados em grandezas numéricas, e outras que possuíam valores vazios ou preenchidos para respostas de sim ou não, foram transformadas em valores binários 0 ou 1, sendo 0 para Não e 1 para Sim. A base de dados resultante possuiu 64.647 linhas e 25 colunas, sendo a coluna J1, referente ao nível de satisfação geral utilizada como referência para construção dos três modelos.

A Tabela 16 apresenta a proporção de classes para cada modelo gerado. Os resultados

apresentam poucos clientes considerados promotores, ou seja, o balanceamento do Modelo 3 indica que apenas 19% dos clientes são promotores. O resultado implica que os modelos 1 e 2 apresentam predominância de clientes insatisfeitos, sendo 60% no primeiro modelo e 69% no segundo modelo.

Tabela 16 – Formato de cada modelo.

Modelo	Classe	Proporção	Instâncias
Modelo 1	Satisfeito	40%	38.890
	Insatisfeito	60%	26.057
Modelo 2	Satisfeito	31%	12.463
	Insatisfeito	69%	27.108
Modelo 3	Promotor	19%	12.463
	Neutro	39%	25.057
	Detrator	42%	27.108

Fonte: Autoria própria.

3.3.4 Aplicação das Técnicas de ML

A aplicação de ML nos três modelos foi realizada utilizando as bibliotecas *scikit-learn* e *SciKeras*. Primeiro foram selecionados os modelos a serem aplicados, em seguida foi construído o campo de hiper parâmetros para aplicação do método *Grid-Search*, que automatiza a tarefa de análise de hiperparâmetros com poucas linhas de código. Com a seleção dos parâmetros ótimos, os algoritmos foram treinados, testados e analisados com as métricas de acurácias, precisão, pontuação F1, *recall*, *roc-auc* (*Receiver Operating Characteristic – Area Under the Curve*), e utilizando a validação cruzada *k-fold* com aplicação de validação cruzada.

A Tabela 17 apresenta todas as técnicas e os campos de parâmetros escolhidos para o *Grid Search*. Este método realiza uma busca da melhor combinação de parâmetros através da validação cruzada (GÉRON, 2019). Todos os campos foram construídos por meio de testes individuais das técnicas, considerando tempo de execução e desempenho. O método *Grid Search* foi aplicado com a utilização da biblioteca *scikit-learn* com *cross validation* de 5 *k-folds*. Os parâmetros resultantes foram selecionados para treinar e testar todas as técnicas. Por fim, foi realizado um teste adicional com validação cruzada de todas as técnicas, com 10 *k-folds* e métrica acurácia. Os dados foram analisados através de *box-plot*.

Tabela 17 - Técnicas e campos de hiperparâmetros.

ML	Parâmetros	Campo
Ada Boost (AB)	<i>n_estimators</i>	1, 5 e 10
	<i>learning_rate</i>	0,1 e 1,2
	<i>splitter</i>	<i>Best e Random</i>
	<i>criterion</i>	<i>gini e entropy</i>
Decision Tree (DT)	<i>max_depth</i>	6, 12, 16 e 24
	<i>min_samples_leaf</i>	2 e 4
	<i>min_samples_split</i>	2 e 4
	<i>loss</i>	<i>log_loss e exponential</i>
	<i>max_features</i>	log2 e sqrt
	<i>learning_rate</i>	0,01, 0,05, 0,1, 0,5 e 1,0
	<i>max_depth</i>	3, 4 e 5
Gradient Boosting (GB)	<i>min_samples_leaf</i>	4, 5 e 6
	<i>subsample</i>	0,6, 0,7 e 0,8
	<i>n_estimators</i>	5, 10, 15 e 20
	<i>max_iter</i>	1.000, 1.200 e 1.500
	<i>learning_rate</i>	0,1
Histogram Gradient Boosting (HGB)	<i>max_depth</i>	25, 50 e 75
	<i>l2_regularization</i>	1,5
	<i>n_neighbors</i>	1, 2, 4, 6, 7 e 10
KNN	<i>weights</i>	<i>uniform e distance</i>
	<i>penalty</i>	<i>l2' e none</i>
	<i>tol</i>	1e-6 e 1e-2
Logistic Regression (LR)	<i>fit_intercept</i>	<i>True' e False</i>
	<i>max_iter</i>	10.000
	<i>n_estimators</i>	200 e 400
	<i>max_depth</i>	6, 12 e 24
	<i>min_samples_split</i>	2 e 4
Random Forest (RF)	<i>min_samples_leaf</i>	2 e 4
	<i>criterion</i>	<i>gini' e 'entropy'</i>
	<i>"hidden_layer_dim"</i>	24, 48 e 96
	<i>"loss"</i>	<i>binary_crossentropy</i>
	<i>"optimizer"</i>	<i>adam e sgd</i>
	<i>"optimizer__learning_rate"</i>	0,0001, 0,001 e 0,1
	<i>"activation_hidden_layer"</i>	<i>sigmoid e relu</i>
SVM	<i>gamma</i>	1, 0,1, 0,01 e 0,001
	<i>kernel</i>	<i>rbf e 'sigmoid'</i>
	<i>C</i>	1, 10, 100 e 1.000

Fonte: Autoria própria.

O Tabela 18 apresenta as técnicas e melhores parâmetros resultantes no processo de *Grid Search*. Considerando os três modelos, é possível identificar que em algumas técnicas houve pouca variação dos parâmetros escolhidos, como o caso do SVM, RL e AB, que resultaram na mesma composição de parâmetros para os três modelos. Como a realização do *Grid Search* pode ser um processo demorado, a biblioteca *joblib* foi utilizada para salvar os modelos treinados com os hiperparâmetros configurados, e assim prevenir contra a perda do progresso de desenvolvimento.

Tabela 18 - Resultados do *Grid Search* por modelo e técnica

ML	Parâmetros	Modelo 1	Modelo 2	Modelo 3
AB	<i>n_estimators</i>	10	10	10
	<i>learning_rate</i>	1	1	1
	<i>splitter</i>	"Best"	"Best"	"Best"
	<i>criterion</i>	"gini"	"entropy"	"entropy"
DT	<i>max_depth</i>	6	6	6
	<i>min_samples_leaf</i>	2	2	2
	<i>min_samples_split</i>	2	4	2
	<i>loss</i>	"exponential"	"log_loss"	"log_loss"
GB	<i>max_features</i>	"sqrt"	"sqrt"	"log2"
	<i>learning_rate</i>	0,1	0,1	0,1
	<i>max_depth</i>	5	5	5
	<i>min_samples_leaf</i>	5	6	5
	<i>subsample</i>	0,8	0,8	0,7
	<i>n_estimators</i>	20	20	20
	<i>max_iter</i>	1200	1000	1000
HGB	<i>learning_rate</i>	0,1	0,1	0,1
	<i>max_depth</i>	25	50	25
	<i>l2_regularization</i>	1,5	1,5	1,5
KNN	<i>n_neighbors</i>	10	7	10
	<i>weights</i>	"distance"	"distance"	"distance"
	<i>penalty</i>	l2'	l2'	l2'
LR	<i>tol</i>	1,00E-06	1,00E-06	1,00E-06
	<i>fit_intercept</i>	"False"	"False"	"False"
	<i>max_iter</i>	10000	10000	10000
	<i>n_estimators</i>	400	200	400
	<i>max_depth</i>	12	12	24
RF	<i>min_samples_split</i>	4	2	2
	<i>min_samples_leaf</i>	4	2	4
	<i>criterion</i>	"gini"	"entropy"	"gini"
RNA	<i>"hidden_layer_dim"</i>	96	48	96

	"loss"	"binary_crossentropy"	"binary_crossentropy"	"categorical_crossentropy"
	"optimizer"	"adam"	"adam"	"adam"
	"optimizer_learning_rate"	0,001	0,0001	0,001
	"activation_hidden_layer"	"relu"	"sigmoid"	"relu"
	gamma	0,001	0,001	0,001
SVM	kernel	rbf	rbf	rbf
	C	10	10	10

Fonte: Autoria própria.

3.3.5 Análise dos Atributos mais relevantes

Duas abordagens foram utilizadas para analisar os atributos mais relevantes para a satisfação de clientes de banda larga no Brasil. O primeiro deles, é mais simples, é a leitura dos dados “*feature importances*” das técnicas treinadas RF DT e AB. O método calcula o decréscimo médio de impureza durante o treinamento destas técnicas, extraindo-se as importâncias encontradas a partir da biblioteca *scikit-learn* (SCIKIT-LEARN, 2022). Este procedimento foi aplicado para os três modelos, e os resultados foram comparados.

A segunda abordagem consistiu em aplicar a análise de valores SHAP (*SHapley Additive exPlanations*). Para explorar o método, foi utilizado a biblioteca SHAP do *Python*, que permite aplicação e plotagem de gráficos para análise (SHAP, 2018). Como apresenta Lundberg e Lee (2017), o SHAP atribui a cada atributo um valor de importância para uma determinada previsão. Para esta pesquisa, a técnica RF foi selecionada para aplicar o SHAP, e assim foi utilizado o método *Tree Explainer* que foi apresentado por Lundberg *et al.* (2020). Os resultados foram analisados por meio dos gráficos de barras e *beeswarm* para todos os três modelos.

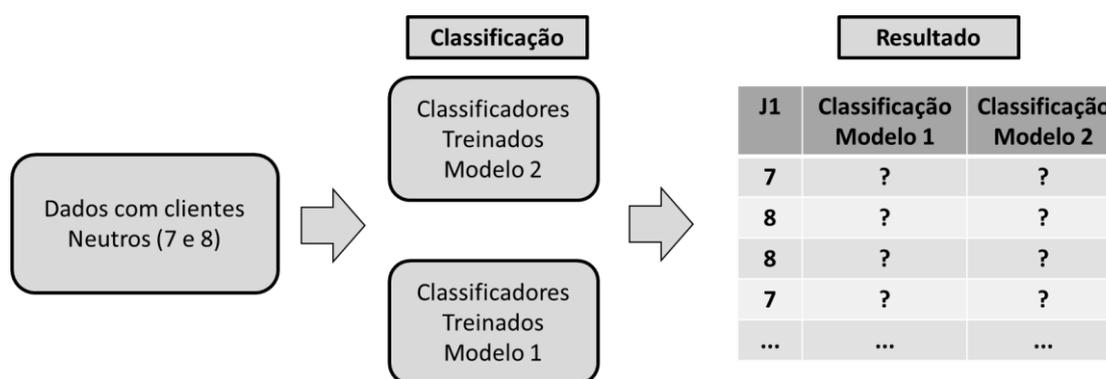
3.3.6 Análise dos Clientes Neutros

O Modelo 2 é um recorte da base de dados em que foi removido os clientes que responderam nível de satisfação 7 ou 8. Neste caso, as técnicas de ML foram treinadas considerando apenas os extremos, onde clientes que atribuíram notas acima ou igual a nove são considerados satisfeitos, e abaixo ou igual a seis são insatisfeitos. Esta formatação visa reproduzir a classificação da base conforme o NPS, mas sem considerar os clientes atribuídos como neutros.

A Figura 21 apresenta um diagrama de fluxo de análise dos neutros. Considerando as

técnicas do Modelo 2, os dados removidos que são referentes aos clientes que atribuíram notas 7 e 8, foram utilizados como entrada para os classificadores após o treinamento, para que estes fossem classificados conforme os critérios treinados. Os algoritmos do Modelo 1 também foram aplicados para classificar estes clientes neutros. Os resultados foram analisados conforme os percentuais de classificação satisfeitos e insatisfeitos conforme as notas 7 ou 8 atribuídas nestas instâncias. Para auxiliar a análise, foram aplicados gráficos de mapa de calor e tabela cruzada.

Figura 21 – Diagrama de análise de clientes Neutros.



Fonte: Autoria própria.

Os clientes neutros representam uma indecisão quanto à satisfação com os serviços prestados. Por isso, torna-se necessário identificar se tais clientes têm mais características de satisfação ou insatisfação. Como os algoritmos aplicados no Modelo 1 e Modelo 2 foram treinados com estratégias de agrupamento distintas, a aplicação deles para classificar os clientes neutros busca-se compreender melhor as características destas instâncias através de um comparativo entre os resultados.

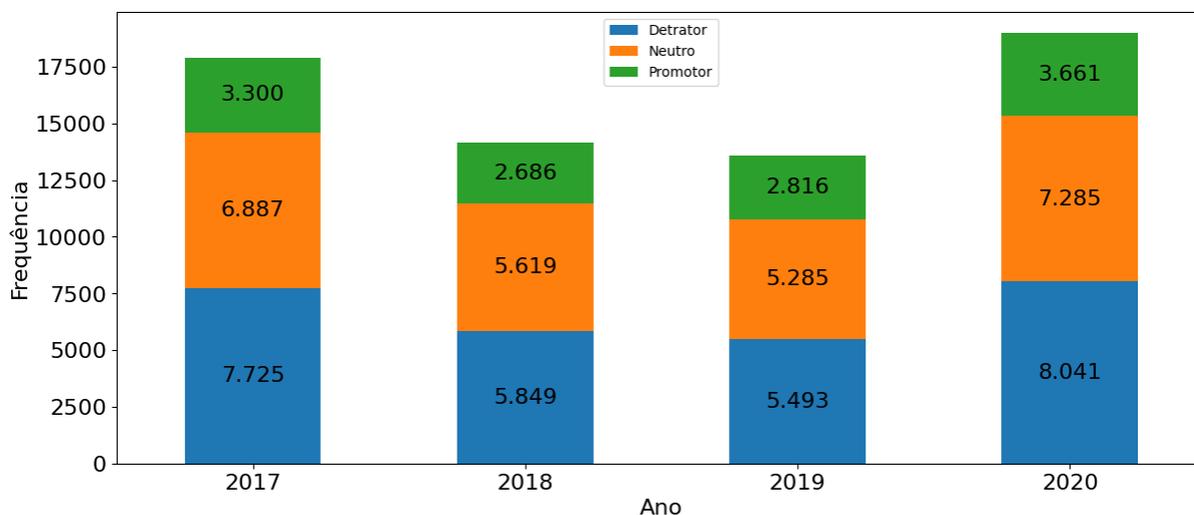
3.4 RESULTADOS

3.4.1 Análise Descritiva dos Dados

A análise descritiva dos dados foi realizada para extrair informações da base, como balanceamento, distribuição dos quantitativos por ano e operadora. A primeira análise realizada é apresentada pela Figura 22, que indica a quantidade de instâncias por ano. Entre 2017 e 2020 a base apresenta pouca variação de respostas, em 2017 ela possui 17.912 respostas, depois ocorreu uma queda em 2018 e 2019, mas em 2020 o número aumenta para 18.987 respostas no ano. A proporção de clientes classificados conforme os critérios do NPS também mantiveram

o mesmo índice de balanceamento ao longo do tempo. Ou seja, o NPS se manteve estável ao longo do período estudado.

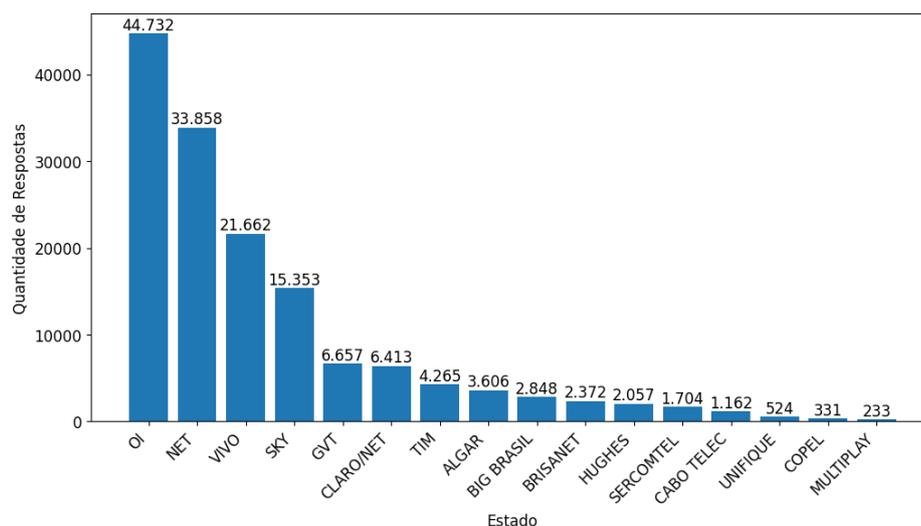
Figura 22 - Quantidade de respostas por ano.



Fonte: Autoria própria.

A Figura 23 apresenta as quantidades de respostas por operadora. Os resultados da pesquisa demonstram dados de clientes de 16 operadoras, sendo OI (44.732) e NET (33.858) as com maior número de respostas, seguido de VIVO com 21.662 respostas, e SKY com 15.353 respostas.

Figura 23 – Quantidade de respostas por operadora.

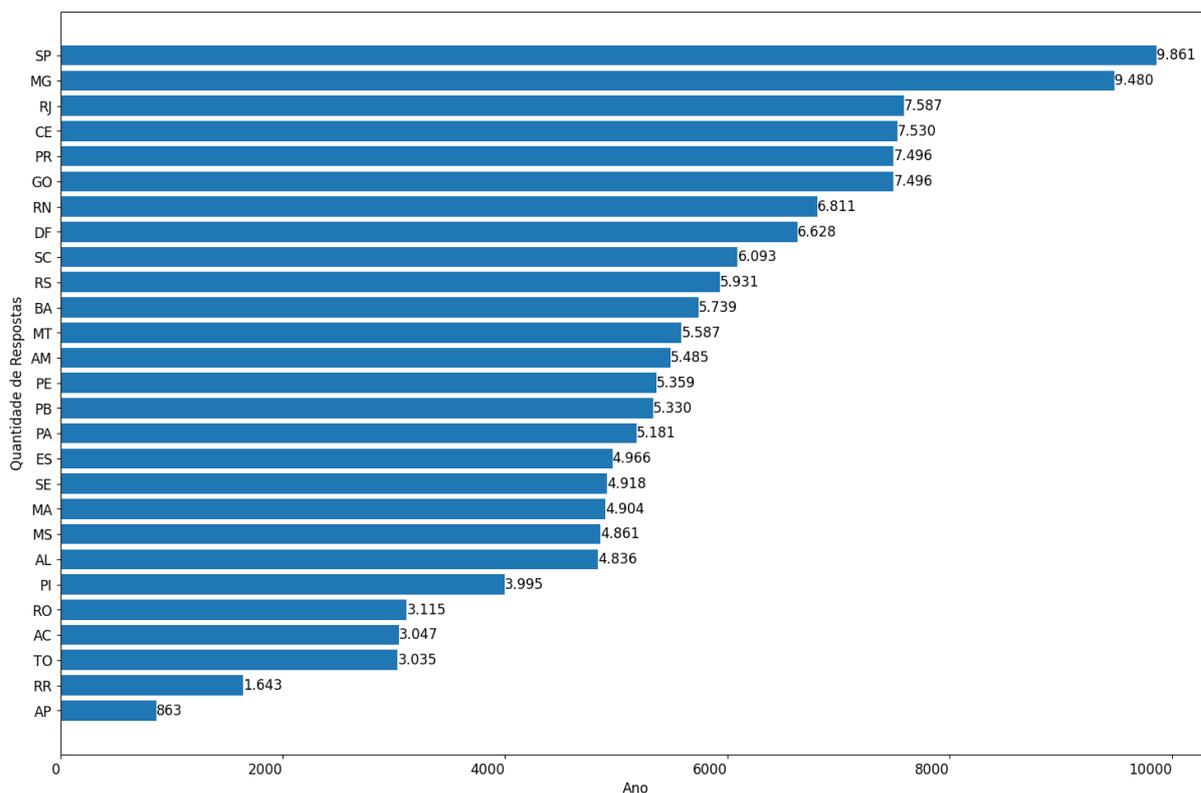


Fonte: Autoria própria.

A Figura 24 apresenta a quantidade de respostas por estado. Os dados da pesquisa de satisfação da ANATEL abrangem todos os estados brasileiros, com destaque para São Paulo e

Minas Gerais que apresentam a maior quantidade de respondentes, 9.861 e 9.480 respectivamente. Os estados que possuem menores números de clientes que responderam foram Roraima e Amapá.

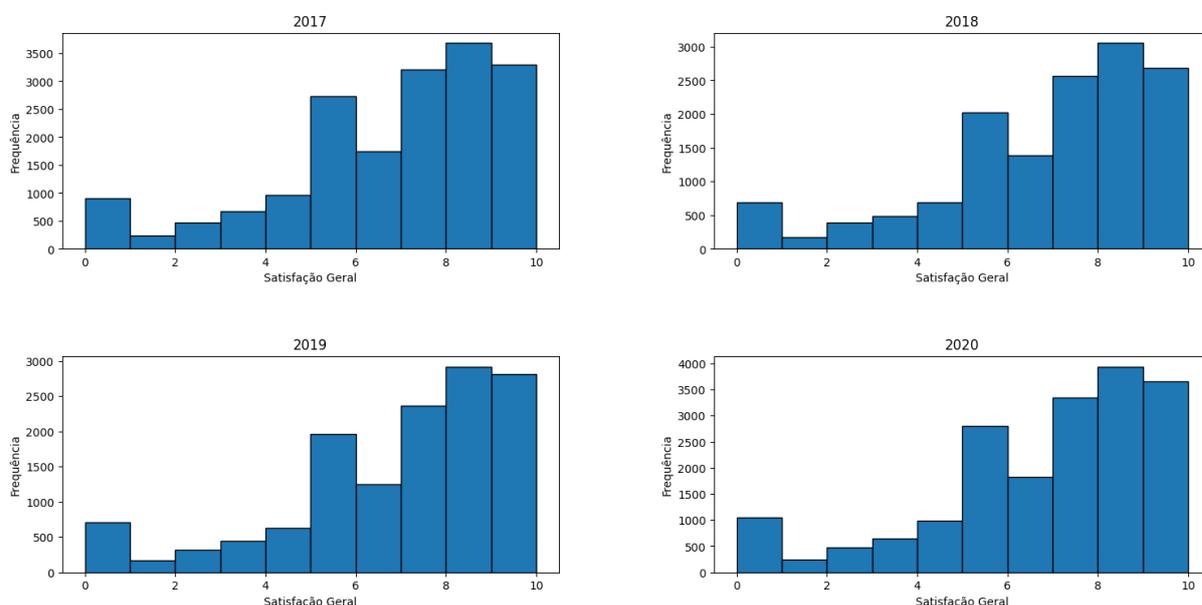
Figura 24 – Quantidade de respostas por estado.



Fonte: Autoria própria.

A Figura 25 mostra quatro histogramas da satisfação geral por ano. Não existem variações da nota ao longo do tempo, pois a distribuição das notas é semelhante em todos os anos, com variações sutis em determinadas notas. O valor médio da satisfação geral em 2017 foi equivalente a 6,40, em 2018 6,48, 6,54 em 2019 e 6,42 em 2020, ou seja, a satisfação média dos clientes de banda-larga dos dados estudados foi próxima de 6,5 entre 2017 e 2020.

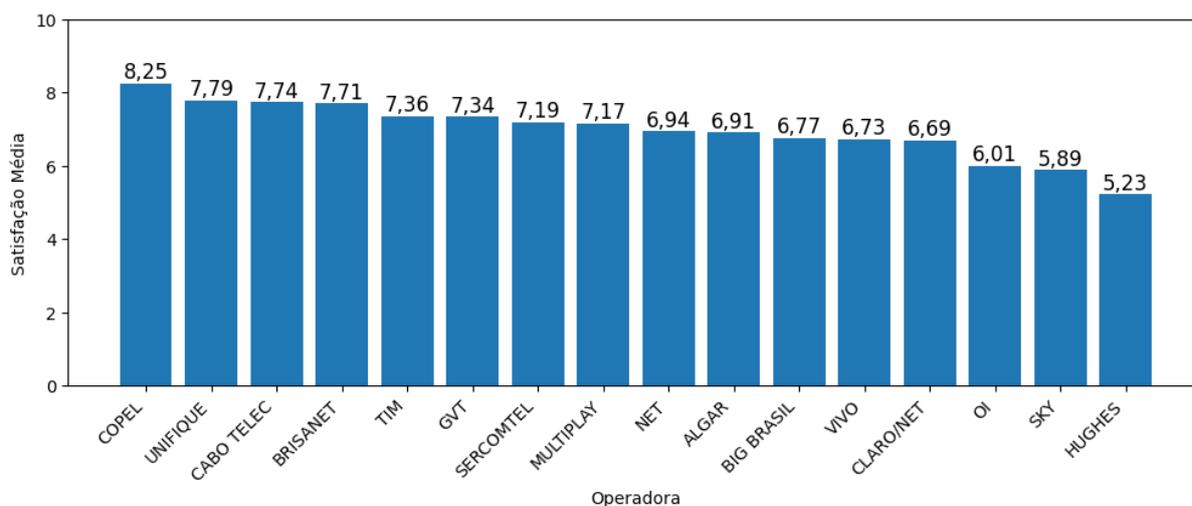
Figura 25 – Histograma da satisfação por ano.



Fonte: Autoria própria.

A Figura 26 apresenta a satisfação média por operadoras. A empresa com maior satisfação média é a COPEL com 8,25, seguida da Unifique com 7,79 e Cabo Telecom com 7,74. A empresa apontada com menor desempenho pelos consumidores é a Hughes com 5,23. A respeito das duas operadoras com maior quantidade de resposta, neste caso a Oi e a NET, a segunda possui maior satisfação média em relação à primeira, com 6,94, acima do 6,01 da primeira. Os resultados mostram que apesar da satisfação média ser próxima de 7, existe uma diferença significativa entre as melhores e as piores, por exemplo, a Oi é a operadora mais frequente na base de dados, mas é a terceira pior em média de satisfação, apresentando uma diferença significativa para a primeira colocada COPEL.

Figura 26 – Satisfação média por operadora.



Fonte: Autoria própria.

3.4.2 Modelo 1

A Tabela 19 apresenta o desempenho de todas as técnicas treinadas com os parâmetros selecionados pelo *Grid Search*. Estão destacados em verde, os melhores resultados de alguns indicadores, e em vermelho algum destaque negativo, com piores resultados. Como é possível observar, todas as técnicas apresentaram uma acurácia variando entre 0,81 a 0,86, com destaque positivo para a técnicas RF, HGB e GB. Entretanto, a técnicas KNN apresentou pior desempenho de acurácia, com resultado médio próximo de 0,8132.

Tabela 19 – Desempenho das Técnicas Modelo 1.

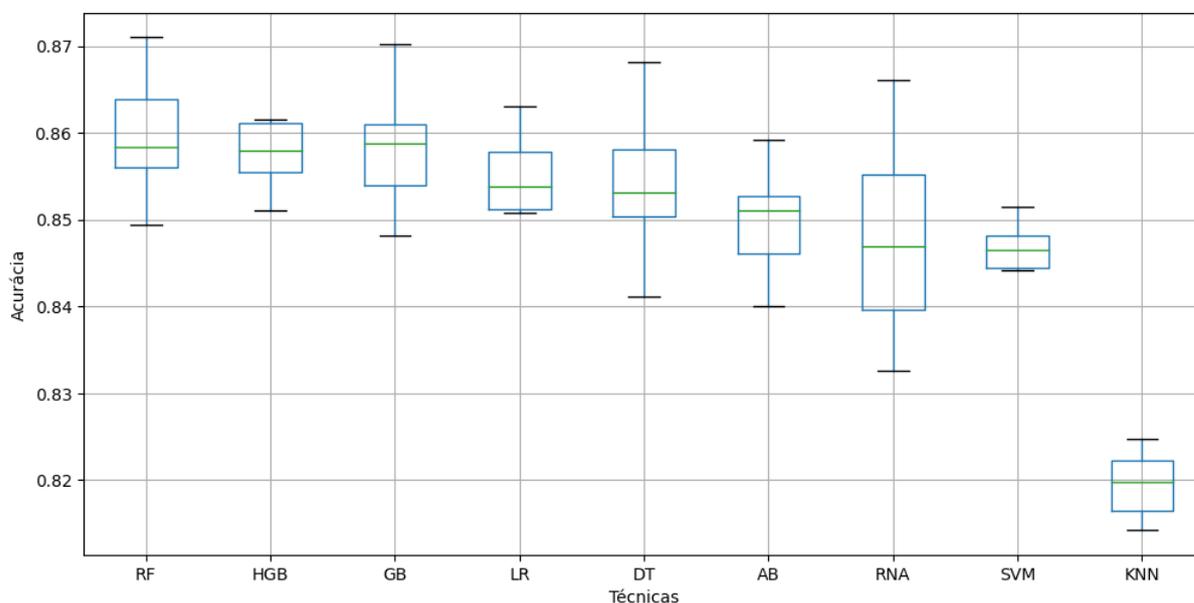
ML	Acurácia	Precisão		Recall		F1		AUC-Score
		Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	
AB	0,8502	0,8776	0,8104	0,8705	0,8202	0,8741	0,8153	0,9254
DT	0,8529	0,8745	0,8205	0,8800	0,8128	0,8772	0,8167	0,9270
GB	0,8576	0,8711	0,8363	0,8937	0,8042	0,8823	0,8199	0,9326
HGB	0,8596	0,8794	0,8298	0,8865	0,8198	0,8829	0,8248	0,9345
KNN	0,8132	0,8541	0,7568	0,8286	0,7903	0,8412	0,7732	0,8908
LR	0,8545	0,8824	0,8143	0,8726	0,8277	0,8774	0,8209	0,9277
RF	0,8596	0,8765	0,8335	0,8902	0,8142	0,8833	0,8237	0,9344
RNA	0,8394	0,8208	0,8790	0,9352	0,6975	0,8743	0,7778	0,9259
SVM	0,8427	0,8678	0,8055	0,8690	0,8039	0,8684	0,8047	0,9184

Fonte: Autoria própria.

Como a aplicação de ML nesta pesquisa visa classificar clientes em satisfeitos e insatisfeitos, é importante que o índice de falsos positivos seja reduzido, pois assim o modelo será mais capaz de identificar corretamente clientes que estão insatisfeitos com a operadora. Dessa forma, no Modelo 1, as técnicas que apresentaram maiores índices de precisão para identificação de insatisfeitos foram AB, HGB e LR. Por fim, outros resultados que valem serem destacados, a pontuação AUC para todas as técnicas teve um valor médio próximo de 0,92, e as técnicas HGB e GB apresentaram melhores desempenhos de pontuação F1.

A Figura 27 apresenta o desempenho da validação cruzada para a métrica acurácia. Como é possível identificar, as técnicas SVM e HGB apresentaram a menor variância relativa da métrica. Estas duas técnicas também apresentaram menor amplitude entre mínimos e máximos. Outras técnicas como RF, DT e RL, apresentam resultados intermediários de variância, mas também demonstram ter amplitudes de resultados altos. A Figura 26 também mostra que o KNN apresentou pior desempenho de acurácia, com valor médio equivalente a 0,8132.

Figura 27 – *Box plot* da acurácia no Modelo 1.



Fonte: Autoria própria.

A Tabela 20 apresenta a relação de importância de atributos extraídos das técnicas RF, DT e GB. As técnicas apresentam os mesmos cinco primeiros atributos, com diferenças na posição entre elas. A visão do cliente sobre a capacidade da empresa em fornecer o que foi prometido (B1_2), é o critério mais relevante para as técnicas RF (21,00%) e GB (27,17%).

Para DT, o atributo mais relevante é a satisfação do cliente com a velocidade de navegação da internet (C1_3), resultado em 65,61%. Este atributo também é destaque para RF e GB, onde ficou em segundo e terceiro respectivamente. O atributo relacionado aos valores cobrados pela empresa (C1_1), é o terceiro atributo para o RF e segundo para o GB.

Tabela 20 – Atributos mais relevantes de acordo com RF, DT e GB resultantes no Modelo 1.

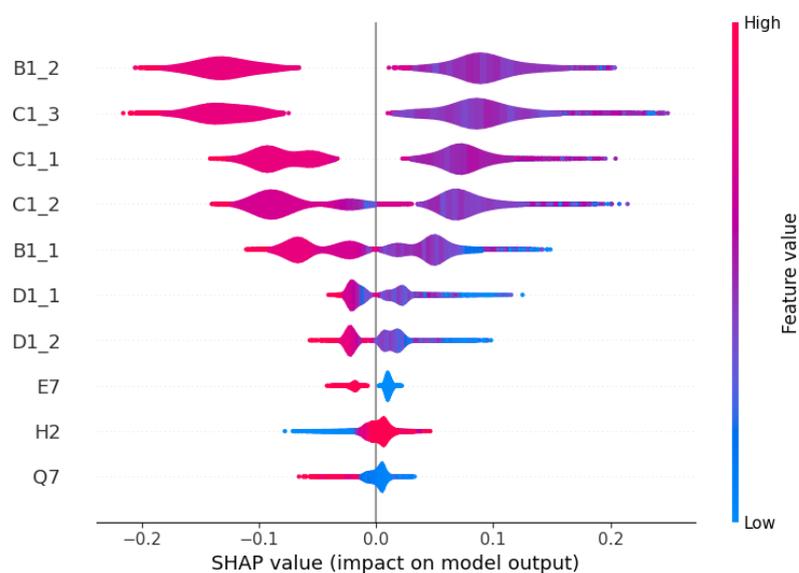
Código	Atributo	RF	DT	GB
B1_2	Nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade.	21,00%	22,46%	27,17%
C1_3	Notas atribuídas à velocidade de navegação.	20,44%	65,61%	23,95%
C1_1	Notas atribuídas à cobrança de valores na conta de acordo com o contratado.	14,58%	3,34%	25,38%
C1_2	Notas atribuídas à capacidade de manter a conexão sem quedas.	14,05%	5,57%	8,78%
B1_1	Nota atribuída com respeito à facilidade de entendimento dos planos e serviços contratados.	9,07%	1,71%	6,90%

Fonte: Autoria própria.

Os valores SHAP apresentados pela Figura 28 para predição de valores insatisfeitos mostram uma relação semelhante aos resultados da Tabela 21, pois os cinco primeiros atributos resultantes foram os mesmos. No caso do SHAP, o atributo B1_2 foi o primeiro na ordem de impacto para saída, e como pode ser observado na Figura 27, notas altas do cliente com este atributo, resultam em impactos negativos para classificação deste como insatisfeito. O mesmo ocorre para os atributos C1_3 e C1_1.

Figura 28 – Gráfico *Beeswarm* com valores SHAP para predição de clientes Insatisfeitos no

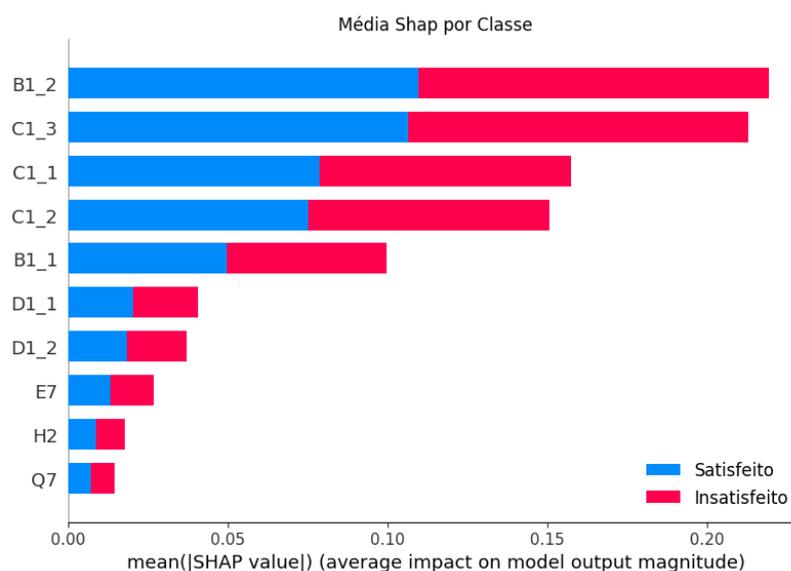
Modelo 1.



Fonte: Autoria própria.

A Figura 29 apresenta os valores médios SHAP absolutos estratificados por classe. Os resultados indicaram balanceamento de impacto para classificação de clientes como satisfeitos e insatisfeitos. O gráfico também demonstra que a mesma relação de atributos apresentados pela Figura 27 e Tabela 21, com B1_2, C1_3, C1_1, C1_2 e B1_1 como os que mais relevantes para classificação de um cliente como satisfeito ou insatisfeito.

Figura 29 – Valores SHAP absolutos estratificados por classe.



Fonte: Autoria própria.

3.4.3 Modelo 2

A Tabela 21 apresenta os valores dos indicadores de desempenho resultantes da aplicação das técnicas de ML no Modelo 2. Pode-se notar que os resultados são relativamente melhores que os apresentados no Modelo 1. Como é possível observar, as técnicas apresentam acurácia média aproximadamente igual a 0,94, enquanto que no primeiro modelo o resultado foi de aproximadamente 0,85. Uma possível explicação para este fato é a remoção dos clientes neutros durante o processo de treinamento e teste. Como estes clientes pertencem a uma região considerada incerta pelo NPS, sua atribuição pode ocasionar confusão no padrão das duas classes. No caso do Modelo 2, as técnicas foram aplicadas e testadas sem estes dados neutros, o que pode ter favorecido os resultados, diferentemente dos algoritmos treinados no Modelo 1.

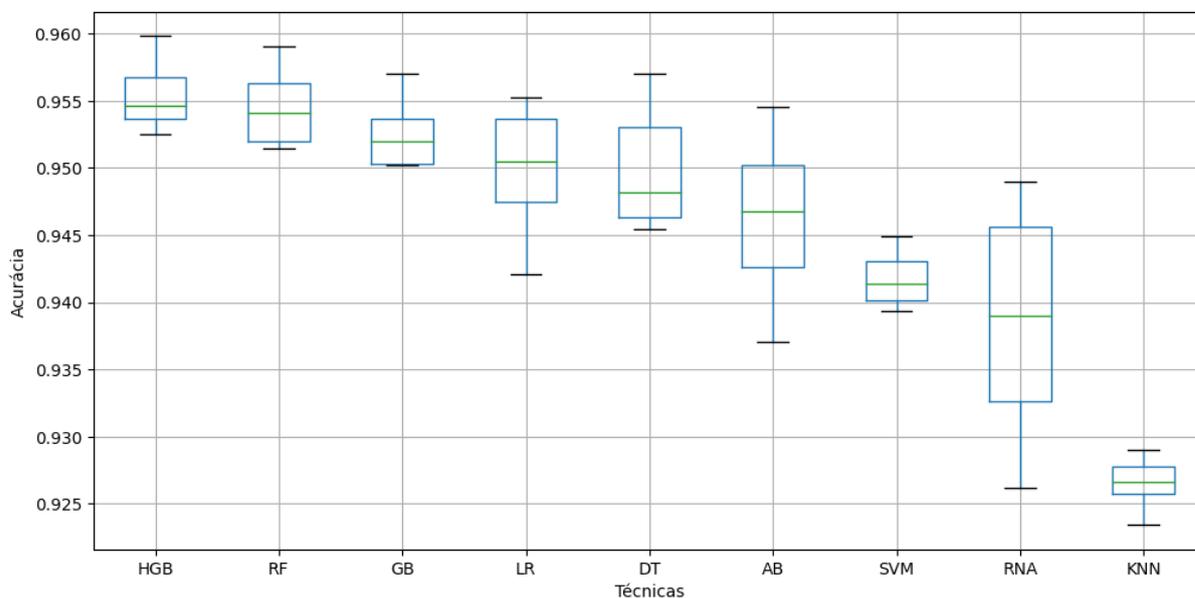
Tabela 21 – Desempenho das técnicas para o Modelo 2.

ML	Acurácia	Precisão		Recall		F1		AUC-Score
		Insa-tisfeito	Satisfeito	Insatis-feito	Satisfeito	Insatis-feito	Satisfeito	
AB	0,9479	0,9625	0,9175	0,9606	0,9212	0,9616	0,9194	0,9836
DT	0,9474	0,9598	0,9210	0,9627	0,9151	0,9613	0,9181	0,9805
GB	0,9523	0,9551	0,9461	0,9755	0,9035	0,9652	0,9243	0,9862
HGB	0,9537	0,9614	0,9369	0,9706	0,9179	0,9660	0,9273	0,9867
KNN	0,9183	0,9357	0,8806	0,9444	0,8634	0,9400	0,8719	0,9619
LR	0,9513	0,9625	0,9275	0,9658	0,9209	0,9642	0,9242	0,9800
RF	0,9541	0,9592	0,9428	0,9737	0,9128	0,9664	0,9275	0,9868
RNA	0,9488	0,9545	0,9361	0,9707	0,9026	0,9625	0,9190	0,9810
SVM	0,9377	0,9517	0,9078	0,9567	0,8979	0,9542	0,9028	0,9761

Fonte: Autoria própria.

Para o Modelo 2, como apresenta a Tabela 21, as técnicas RF, HGB e GB apresentaram melhores desempenhos de acurácia, com valores 0,9541, 0,9537 e 0,9523 respectivamente. Já a técnica KNN apresentou pior desempenho, com valor próximo de 0,9183. Para a precisão na identificação de insatisfeitos, as técnicas AB, LR e HGB apresentaram melhores resultados, com 0,9625, 0,9625 e 0,9614. Por fim, vale destacar que todas as técnicas tiveram desempenho próximo na pontuação AUC, com valor médio de 0,98.

A Figura 30 apresenta o desempenho da acurácia de todas as técnicas com a validação cruzada. O gráfico apresenta que a rede neural apresentou maior variação em relação a todas as outras técnicas, o que mostra um baixo desempenho do algoritmo para classificação da satisfação de clientes no Modelo 2. Já outras técnicas como GB, SVM, KNN e RF mostraram baixa variação na acurácia. O menor desvio padrão foi obtido pelo GB, com 0,004123.

Figura 30 – *Box plot* da acurácia no Modelo 2.

Fonte: Autoria própria.

A Tabela 22 apresenta a relação dos atributos mais importantes conforme as técnicas RF, DT e GB. O levantamento mostrou que os cinco primeiros atributos é o mesmo para todas as técnicas, com mudanças apenas na ordem em cada técnica. O RF resultou em 21,42% de relevância para o atributo C1_3. Este atributo também apresentou resultado considerável para DT (20,75%) e GB (11,98%), porém com menor impacto que em RF. A nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido (B1_2) também é destaque para as técnicas, ficando em primeiro lugar para DT (68,05%) e GB (41,51%), e segundo lugar para RF (21,15%). Outro atributo de destaque é o C1_2, que ficou em segundo lugar para GB (19,36%).

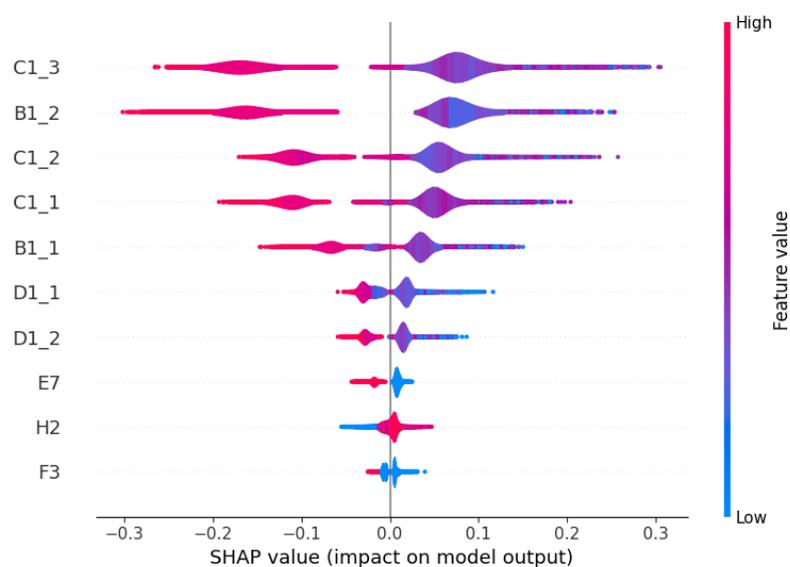
Tabela 22 – Atributos mais relevantes de acordo com RF, DT e GB resultantes no Modelo 2.

Código	Atributo	RF	DT	GB
C1_3	Notas atribuídas à velocidade de navegação.	21,42%	20,75%	11,98%
B1_2	Nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade.	21,15%	68,05%	41,51%
C1_2	Notas atribuídas à capacidade de manter a conexão sem quedas.	14,37%	5,11%	19,36%
C1_1	Notas atribuídas à cobrança de valores na conta de acordo com o contratado.	13,91%	3,55%	11,44%
B1_1	Nota atribuída com respeito à facilidade de entendimento dos planos e serviços contratados.	8,05%	0,94%	7,23%

Fonte: Autoria própria.

A Figura 31 apresenta o gráfico *Beeswarm* com os valores SHAP para predição de clientes como insatisfeito e satisfeito no Modelo 2. Os três primeiros atributos com maiores impactos para esta saída são C1_3, B1_2 e C1_2. Em todos os casos, notas altas para estas questões indicam impacto negativo para classificação do cliente como insatisfeito. Ou seja, conforme o consumidor esteja satisfeito com estes atributos, o impacto é maior para classificá-los como satisfeito. Outros atributos como notas atribuídas aos cobrança dos valores conforme o funcionamento do serviço (C1_1), facilidade de entendimento dos planos, entre outros com menores impactos (B1_1).

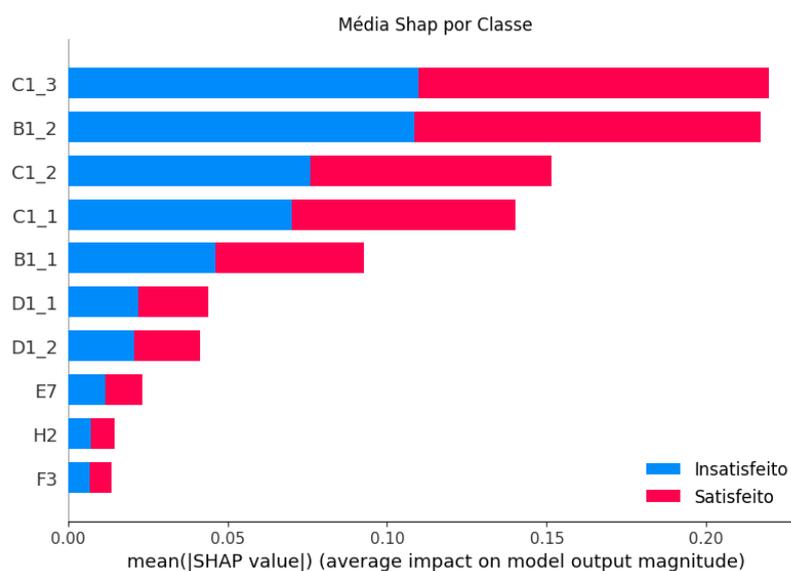
Figura 31 - Gráfico *Beeswarm* com valores SHAP para predição de clientes Insatisfeitos no Modelo 2.



Fonte: Autoria própria.

Os valores médios SHAP absolutos e estratificados por classe são apresentados pela Figura 32. É possível identificar que os cinco primeiros atributos são equivalentes ao resultante pelas técnicas RF, DT e GB. É importante destacar que existe uma importância quase equivalente para classificação de satisfeito e insatisfeito, os resultados do gráfico para C1_3, B1_2 e C1_2 mostram este equilíbrio.

Figura 32 – Valores SHAP absolutos estratificados por classe.



Fonte: Autoria própria.

3.4.4 Modelo 3

O Modelo 3 teve como objetivo aplicar técnicas de classificação para prever se um cliente é “Detraitor”, “Neutro” ou “Promotor”, ou seja, um modelo multiclasse. A Tabela 23 mostra os resultados de acurácia para cada uma das técnicas. O desempenho para este quesito em modelos de classificação com múltiplas classes é inferior ao encontrado nos Modelos 1 e 2. O resultado médio para este indicador é de 76%, sendo o RF, GB e HGB como as técnicas com melhores desempenho. Assim como nos demais modelos, o KNN também apresentou pior desempenho neste quesito.

Tabela 23 – Resultados de Acurácia para o Modelo 3.

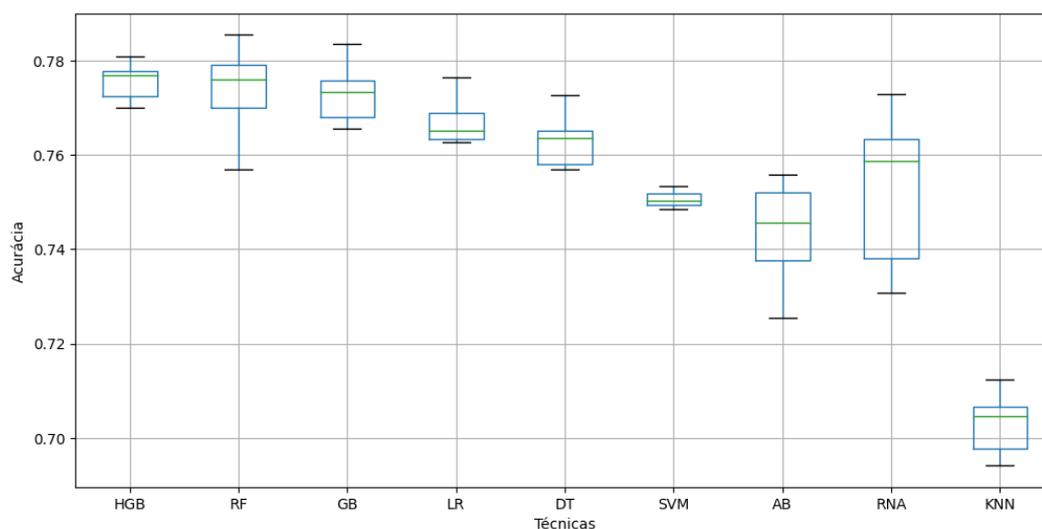
ML	Acurácia	Precisão			Recall			F1		
		Promo- tor	Neutro	Detra- tor	Promo- tor	Neutro	Detra- tor	Promo- tor	Neutro	Detra- tor
AB	0,7420	0,7114	0,6747	0,8181	0,6653	0,6895	0,8260	0,6876	0,6820	0,8220
DT	0,7617	0,7608	0,6882	0,8368	0,6299	0,7526	0,8311	0,6892	0,7189	0,8340
GB	0,7708	0,7869	0,6930	0,8462	0,6301	0,7740	0,8330	0,6998	0,7313	0,8395
HGB	0,7739	0,7599	0,7060	0,8476	0,6821	0,7527	0,8360	0,7189	0,7286	0,8418
KNN	0,6910	0,6639	0,5927	0,8306	0,4992	0,7420	0,7328	0,5699	0,6590	0,7786
LR	0,7649	0,7598	0,6840	0,8545	0,6577	0,7638	0,8155	0,7051	0,7217	0,8345
RF	0,7730	0,7877	0,6961	0,8475	0,6425	0,7718	0,8347	0,7078	0,7320	0,8410
RNA	0,7545	0,7076	0,6693	0,8856	0,7416	0,7583	0,7571	0,7242	0,7110	0,8163
SVM	0,7446	0,7253	0,6666	0,8354	0,6323	0,7362	0,8044	0,6756	0,6997	0,8196

Fonte: Autoria própria.

Considerando a classe de detratores, o RF, HGB e GB e LR obtiveram resultados acima de 0,84, conforme apresentado pela Tabela 23. Estas técnicas também apresentaram resultados de destaque no *Recall* e pontuação F1. Importante destacar que os indicadores para classificação de clientes em promotores e neutros está abaixo em relação a detratores, o KNN, por exemplo, possui 0,8306 de precisão para classificar um cliente como detraitor, mas 0,6639 para promotor e 0,5927 em Neutro.

O resultado da validação cruzada é apresentado em formato de *Box Plot* pela Figura 33. Assim como nos demais modelos, é possível notar que a RNA resultou em maior variância e amplitude, com desvio padrão equivalente a 0,1016. Este resultado está abaixo de outras técnicas, como SVM (0,005657), KNN (0,005663), HGB (0,007913) e LR (0,006274). Com isso, o HGB apresentou maior acurácia média, baixa variação, e resultados condizentes de precisão e recall para detecção de clientes detratores.

Figura 33- Box plot da acurácia no Modelo 3.



Fonte: Autoria própria.

Os atributos mais relevantes extraídos das técnicas RF, DT e GB são apresentados pela Tabela 24. Os dados da figura mostram um alinhamento com os resultados encontrados no Modelo 1 e Modelo 2, pois são os mesmos atributos, com mudanças na ordem e pesos. No Modelo 3, o atributo C1_3 foi o mais relevante para as três técnicas, seguido do B1_2. Outros questionamentos como satisfação em relação a cobrança, capacidade de manter a conexão sem quedas e comunicação dos planos também compõem as demais posições, mas com pesos relativos menores que as duas primeiras.

Tabela 24 - Atributos mais importantes para RF, DT e GB.

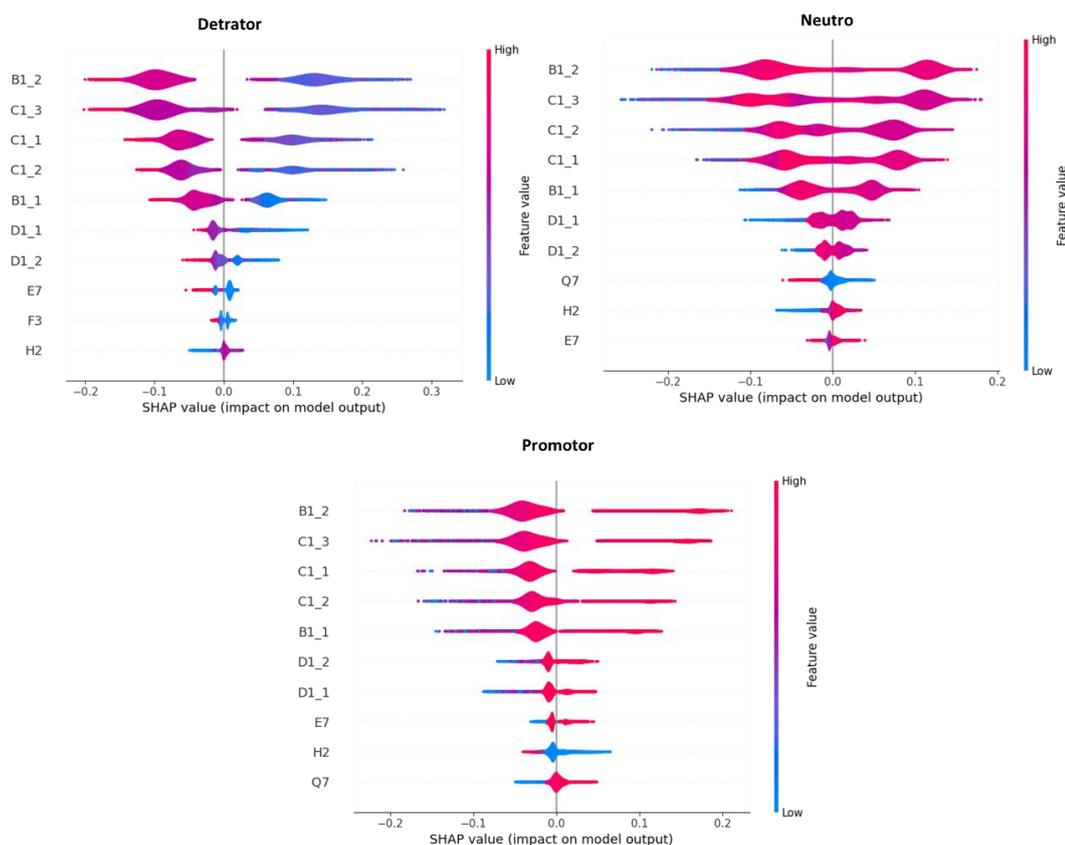
Código	Atributo	RF	DT	GB
C1_3	Notas atribuídas à velocidade de navegação.	20,53%	53,55%	24,21%
B1_2	Nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade.	17,36%	31,34%	22,11%
C1_1	Notas atribuídas à cobrança de valores na conta de acordo com o contratado.	13,89%	5,24%	20,72%

C1_2	Notas atribuídas à capacidade de manter a conexão sem quedas.	12,62%	7,56%	10,86%
B1_1	Nota atribuída com respeito à facilidade de entendimento dos planos e serviços contratados.	9,09%	2,09%	9,10%

Fonte: Autoria própria.

Os gráficos *Beeswarm* com valores SHAP para classificação dos Detratores, Neutros e Promotores, são mostrados pela Figura 34. Para identificar um cliente como detratador, o impacto da satisfação do cliente em cumprir o que foi prometido (B1_2), velocidade de navegação (C1_3) e cobrança (C1_1), mostram índices de importância alta. Neste caso, é possível observar que notas altas nestes atributos resultam em impacto negativo para classificar os detratores, e caso contrário, tem-se um impacto positivo. No caso de Neutros e Promotores, as notas altas para os atributos citados têm impacto positivo. No entanto, estes casos não apresentam uma divisão visível como para classificação de Detratores.

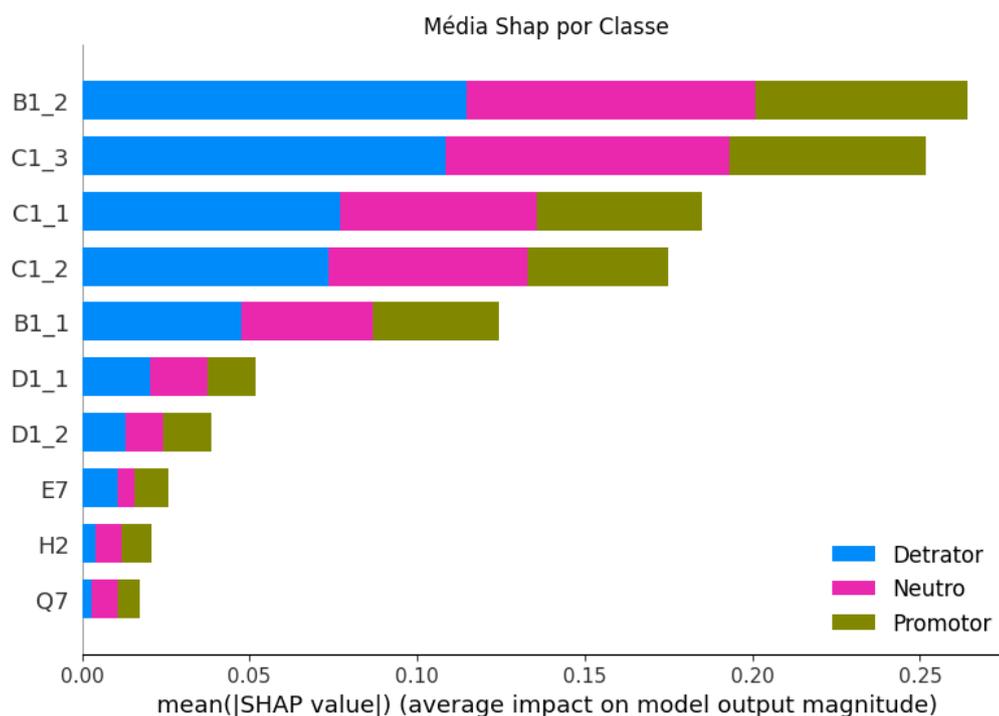
Figura 34 - Gráficos *Beeswarm* com valores SHAP para o Modelo 3.



Fonte: Autoria própria.

A Figura 35 apresenta os valores médios e absolutos do SHAP e estratificados por classe. O gráfico mostra o impacto que os atributos relacionados à cobrança, comunicação dos planos, velocidade de navegação, conexão sem quedas e comprometimento da operadora em fornecer o que foi prometido, sendo os cinco atributos com maior impacto para classificação. Este resultado também é válido quando observado para as classes específicas, pois seus valores são próximos.

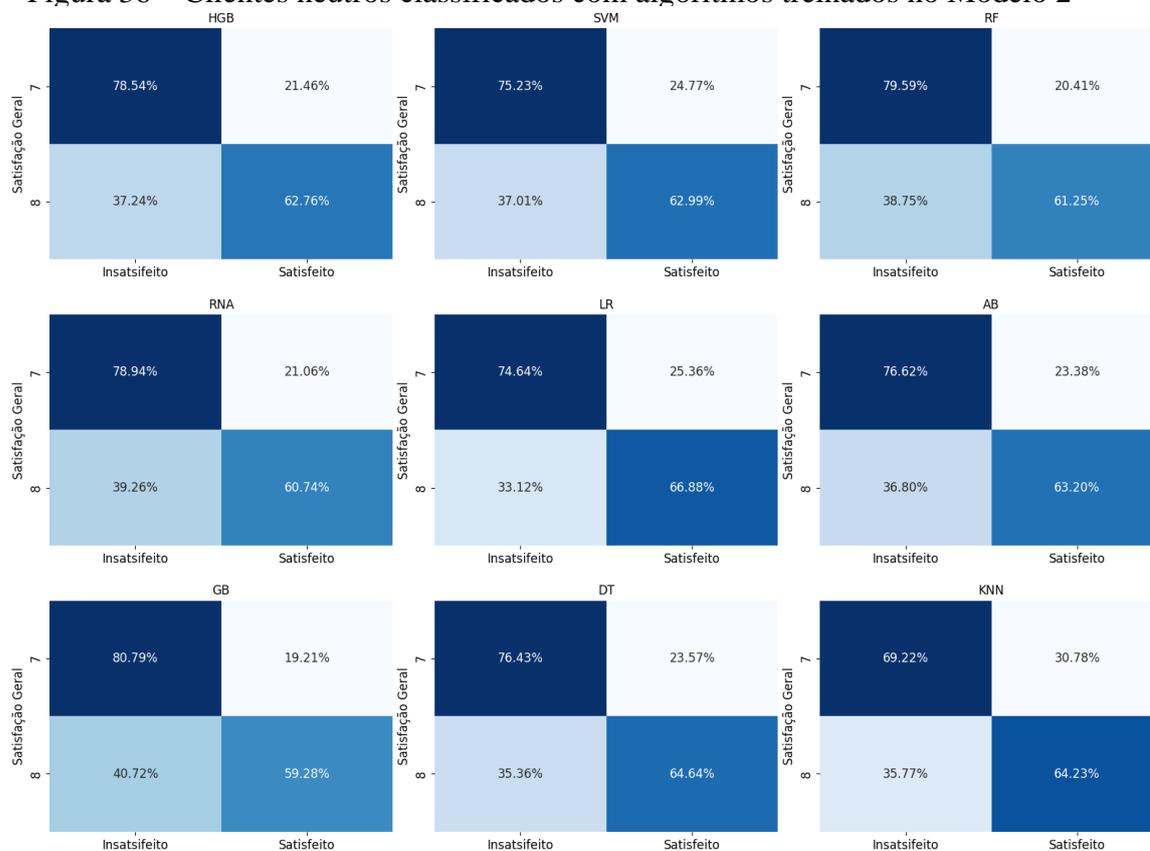
Figura 35 – Valores médios absolutos de SHAP estratificados por classe no Modelo 3.



3.4.5 Análise dos Neutros

A Figura 36 apresenta mapas de calor conforme o resultado da classificação de clientes neutros no Modelo 2 por técnica. Por exemplo, para o RF no Modelo 2, dos respondentes que atribuíram nota 7 para satisfação geral, o algoritmo classificou 79,59% como insatisfeitos e 20,41% como satisfeitos, e os que responderam nota 8, 61,25% foram classificados como satisfeitos e 38,75% como insatisfeitos. As demais técnicas apresentaram proporções de classificação próximas, onde mostra que clientes que atribuíram nota 7, de 69,22% a 80,79% são considerados insatisfeitos pelas técnicas, já nota 8 de 59,28% a 66,88% são satisfeitos. Os resultados indicam que os algoritmos treinados no Modelo 2 consideram as notas 7 mais próximas do insatisfeito, e 8 de satisfeito.

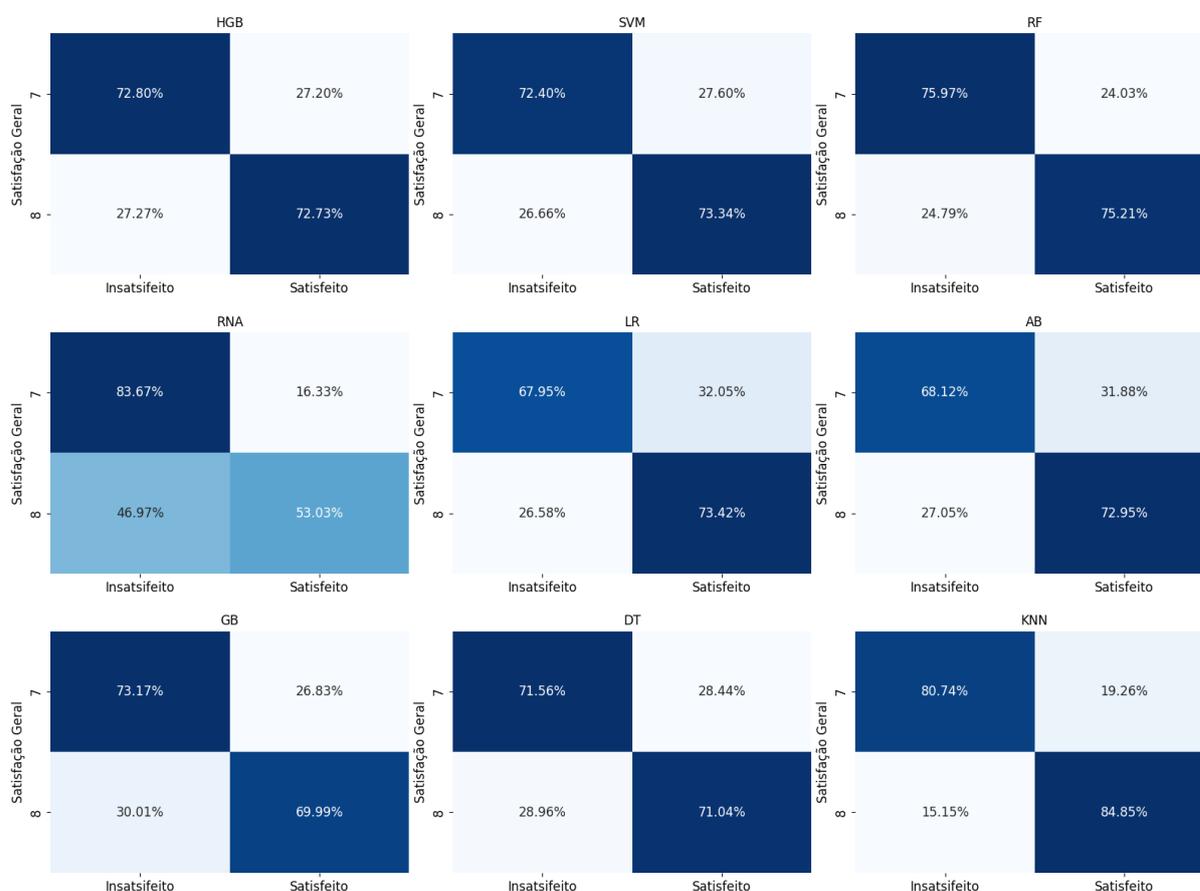
Figura 36 – Clientes neutros classificados com algoritmos treinados no Modelo 2



Fonte: Autoria própria.

Este mesmo experimento também foi realizado utilizando os algoritmos treinados no Modelo 1, que é apresentado pela Figura 37. Os resultados também mostram equilíbrio como os algoritmos do Modelo 2, porém neste caso vale lembrar que os classificadores foram treinados para considerar clientes que responderam 7 como insatisfeitos e 8 como satisfeitos, o que elevou a proporção de satisfeitos e insatisfeitos para as notas 7 e 8. Isto ocasionou um aumento das proporções de respondentes nota 8 classificados como satisfeito, que variou de 53,03% a 84,85%, e nota 7 como insatisfeitos com amplitude de 67,95% a 80,74%.

Figura 37 – Clientes neutros classificados com algoritmos treinados no Modelo 1.



Fonte: Autoria própria.

Os resultados do Modelo 2 mostram que os clientes neutros podem ocasionar incerteza na classificação e desempenho das técnicas. Primeiro, os desempenhos dos algoritmos apresentaram melhora relativa ao Modelo 1, pois utilizou apenas extremos para classificação, o que favorece o processo de treinamento. Segundo a classificação de clientes que responderam notas 7 e 8 para satisfação geral demonstra incerteza de detecção se estes são satisfeitos e insatisfeitos, tanto para os algoritmos do Modelo 1 quanto do Modelo 2. Apesar da maioria das técnicas identificar 7 como insatisfeitos e 8 como satisfeitos, ainda assim uma quantidade considerável de instâncias são atribuídas como a classe oposta. Os resultados apresentam que a escala *Likert* de 10 pontos amplia a incerteza para técnicas de classificação.

Com os resultados foi possível atender aos dois questionamentos gerados pelo Modelo 2. A primeira questão (Q1) foi se o NPS consegue diferenciar os satisfeitos dos insatisfeitos. Os resultados indicam que esta distinção não é tão exata, pois a classe de neutros do NPS apresentou uma característica mista entre insatisfeito e satisfeito conforme a nota atribuída pelo

cliente. Esta característica é respondida pela segunda questão Q2, sobre se os neutros são mais satisfeitos ou insatisfeitos. E para este caso, os clientes que atribuíram nota 8, são mais satisfeitos, e nota 7 insatisfeitos, mas ainda assim estes possuem incertezas nesta atribuição.

De acordo com Reichheld (2003) os clientes considerados neutros também estão no espectro de satisfeitos com o serviço, no entanto estes estão em uma região em que seu nível de satisfação não impacta em resultados futuros para uma empresa, pois existe uma possibilidade baixa destes clientes promoverem o serviço. No entanto, como os resultados apresentados pela predição de ML os clientes neutros podem ter perfil tanto de satisfeitos quanto de insatisfeitos. Portanto, considerar os clientes neutros como aqueles que não impactam para o negócio, pode levar a considerações erradas. Assim como Kristensen e Eskildsen (2011a) apresentaram, as classes do NPS são imprecisas, e podem ser insuficientes para gestão da qualidade de um serviço.

3.5 DISCUSSÃO

De forma geral, foram aplicadas técnicas supervisionadas de ML para classificar clientes conforme sua satisfação em dados extraídos da pesquisa de satisfação de clientes da ANATEL. Com isso, foi utilizado como base o indicador NPS, normalmente utilizado por prestadores de serviços para classificar clientes em detratores, neutros e promotores. Com isso, a partir da variável de saída “Satisfação Geral com o Serviço”, foram preparados três modelos com limiares diferentes para subdivisão de clientes conforme as referências do NPS. O Modelo 1 consistiu em uma classificação binária, onde clientes satisfeitos são aqueles que atribuíram notas acima ou igual a 8, e abaixo disso são considerados insatisfeitos. O Modelo 2 os clientes que atribuíram notas 7 e 8 foram removidos da base, e clientes satisfeitos foram aqueles com notas acima ou igual a 9, e insatisfeitos abaixo ou igual que 6. Por fim, o Modelo 3 foi realizado uma classificação múltipla conforme as classes do NPS.

Com os resultados de desempenho das técnicas para classificação dos clientes, é possível concluir que a presença de clientes neutros (notas 7 e 8 na satisfação geral), na etapa de treinamento prejudica a classificação binária. Os resultados do Modelo 1 em comparação com o Modelo 2 são piores, onde o primeiro caso resultou em acurácia média de 84,7% e o segundo 94,8%, quase dez pontos percentuais de diferença. Além da acurácia, outros indicadores como precisão e recall para detecção de insatisfeitos também apresentaram resultados melhores segundo modelo.

O desempenho da classificação binária deixa mais claro o experimento realizado de

classificar os clientes que atribuíram notas 7 e 8 utilizando as técnicas treinadas nos Modelos 1 e 2. Neste caso, todas as técnicas com os critérios de cada modelo consideraram a seguinte situação: a maioria dos clientes que atribuíram no 8 estão satisfeitos e os que votaram 7 são insatisfeitos. No entanto, os resultados mostraram que este não é um resultado claro, pois as técnicas ainda consideraram muitas instâncias em classes diferentes, por exemplo, no Modelo 2 a técnica RF classificou 61,25% dos clientes nota 8 como satisfeitos, mas ainda assim consideram 38,75% como insatisfeitos, mesmo a nota 8 sendo mais próxima do limiar utilizado para definir a classe. Um comportamento semelhante ocorre com outras técnicas, porém com valores diferentes.

Os resultados de desempenho para classificação múltipla apresentaram resultados médios de acurácia menor que os Modelos 1 e 2, com 75,2%. No entanto, a precisão para a classificação de clientes como Detratores, teve um valor médio equivalente a 84,4%, quase próximo do Modelo 1, que resultou em 86,7% de precisão média para classificação de clientes como insatisfeitos. Em todos os Modelos, vale destacar as seguintes técnicas que obtiveram os melhores resultados em acurácia, precisão e variância da validação cruzada: RF, HGB, GB e AB.

A Tabela 25 apresenta uma síntese dos atributos mais relevantes e suas posições, obtidos por meio das técnicas de ML RF, DT e GB, e pelo método SHAP. Em todos os métodos aplicados, os cinco primeiros atributos resultantes foram: a nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade (B1_2), à velocidade de navegação (C1_3), à cobrança de valores na conta de acordo com o contratado (C1_1), à capacidade de manter a conexão sem quedas (C1_2) e com relação à facilidade de entendimento dos planos e serviços contratados (B1_1). Para as técnicas RF, DT e GB os atributos que apresentaram maiores índices de importância foram C1_3, B1_2 e C1_1.

Tabela 25 – Síntese da ordem dos atributos mais relevantes obtidos pelas técnicas ML (RF, DT e GB) e SHAP.

Código	Atributo	Ordem de Importância por Modelo					
		Modelo 1		Modelo 2		Modelo 3	
		ML	SHAP	ML	SHAP	ML	SHAP
C1_3	Notas atribuídas à velocidade de navegação.	2	2	1	1	1	2
B1_2	Nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade.	1	1	2	2	2	1
C1_1	Notas atribuídas à cobrança de valores na conta de acordo com o contratado.	3	3	4	4	3	3
C1_2	Notas atribuídas à capacidade de manter a conexão sem quedas.	4	4	3	3	4	4
B1_1	Nota atribuída com respeito à facilidade de entendimento dos planos e serviços contratados.	5	5	5	5	5	5

Fonte: Autoria própria.

Os resultados obtidos através do método SHAP, também indicaram que os atributos B1_2, C1_3 e C1_1 resultaram em maiores valores médios absolutos de impacto na saída. Os dados obtidos através do SHAP também permitiram identificar os impactos de cada atributo de forma mais detalhada. Em todos os casos, os resultados de importância de atributos resultaram nos mesmos cinco atributos, com apenas mudanças de posições entre elas. Este resultado mostra alinhamento com o resultado encontrado por outros métodos.

Os resultados encontrados para a importância de atributos, não indicam com certeza que um aumento da satisfação nestes cinco atributos implica em clientes satisfeitos ou insatisfeitos. Porém, os resultados apresentaram que estes atributos têm maiores impactos na classificação, ou seja, são estes atributos que mais contribuem para que uma técnica identifique um cliente que esteja satisfeito ou não. Pela perspectiva prática, empresas do ramo de telecomunicações podem direcionar esforços nestes cinco atributos como prioridade para melhoria e aprimoramento, pois são eles que podem impactar mais no resultado de satisfação dos clientes.

A pesquisa desenvolvida por Markoulidakis *et al.* (2020) também explorou ML com

utilização do NPS, porém este utilizou dados de clientes de operadoras de telefonia móvel pós-paga na Grécia. Os autores levantaram alguns atributos importantes para classificação utilizando o SHAP para modelo de regressão linear. Quatro atributos foram destacados pelos autores, “*Network Voice*”, indica a qualidade da rede para serviços de voz, “*Tariff Plan*”, o plano da tarifa cobrada, “*Billing*”, sobre a conta cobrada, e por fim “*Network Data*”, referente a rede de dados. Apesar de empresas com serviços diferentes, mas dentro do mesmo setor, é possível realizar algumas relações. Os resultados de Markoulidakis *et al.* (2020) indicaram que os atributos mais importantes são relacionados à cobrança e qualidade da rede, assim como os resultados apresentados neste artigo também mostraram que alguns dos atributos mais relevantes também estão relacionados ao pagamento e à qualidade da conexão.

Outro trabalho que apresentou análise de atributos mais relevantes foi o de Hosseini e Ziaei Bideh (2014), onde aplicou-se um questionário de satisfação para clientes de telefonia móvel na província de Yazd no Irã. Os autores apresentaram como atributos mais relevantes para a satisfação os serviços de valor agregado, suporte ao cliente, qualidade da rede e preço dos planos. Assim como os dados escritos por Markoulidakis *et al.* (2020), a publicação de Hosseini e Ziaei Bideh (2014) também indicaram atributos relacionados ao pagamento e à qualidade da rede

Apesar de divergências de termos, serviço prestado e metodologia utilizada para calcular os atributos, esta pesquisa apresenta certo alinhamento com os artigos de Markoulidakis *et al.* (2020) e Ziaei Bideh (2014). Este trabalho apresentou os cinco atributos mais importantes para classificação, e destes, um é relacionado a à cobrança (notas atribuídas à cobrança de valores na conta de acordo com o contratado), e dois relacionados a à qualidade da rede, como notas atribuídas à velocidade de navegação e capacidade de manter a conexão sem quedas. Portanto, os atributos mais relevantes resultados neste artigo indicam relação com duas pesquisas encontradas na literatura.

3.6 CONCLUSÃO

A partir de 2016 ocorreu um crescimento significativo de publicações sobre utilização de ML em gestão da qualidade de serviços. Os artigos disponíveis na literatura se diversificam em vários aspectos, como objetivos científicos, setores, bases de dados, métodos, tipos de aprendizado, técnicas, entre outros. Considerando que o setor de telecomunicações ainda possui um baixo número de publicações na literatura internacional e nenhum trabalho na literatura

brasileira, esta pesquisa teve como objetivo aplicar técnicas de ML para analisar dados de satisfação de serviços de telecomunicações no Brasil.

Portanto, os resultados apresentados neste artigo mostraram desafios para aplicar técnicas de ML para classificar a satisfação de clientes. Como limitação do estudo, devido à natureza da base de dados, que possui como saída uma escala *Likert* de 10 pontos, transformar esta escala em classes implica em incertezas devido à diversidade de opções para seleção do cliente, e níveis intermediários e neutros de satisfação. Além disso, este artigo apresentou cinco atributos que mais impactam a classificação de clientes por meio das técnicas, que podem ser exploradas por empresas provedoras de serviços de banda-larga para gerir a qualidade dos seus serviços. Por fim, como sugestão de trabalhos futuros, podem ser exploradas outras técnicas de classificação que não foram utilizadas neste estudo, aplicar e aprofundar em mais métodos de pré-processamento, como linearização, imputação de dados e balanceamento, e também aplicar o SHAP para outros algoritmos além do RF.

CONCLUSÕES

Esta pesquisa teve como objetivo principal estudar a literatura sobre aplicação de ML na análise da qualidade de serviços e aplicar técnicas de ML em uma base de dados de satisfação de clientes de banda-larga no Brasil. Para isso, foram desenvolvidos dois artigos, o primeiro foi composto de uma revisão sistemática com o propósito de explorar a literatura científica sobre o tema. Já no segundo artigo, foram aplicadas técnicas de ML para analisar a satisfação de clientes de banda larga no Brasil, e assim avaliar o desempenho das técnicas treinadas para classificação, incluindo o comportamento da classificação para clientes considerados neutros pelo NPS, e por fim, identificar os atributos mais relevantes para a satisfação.

No primeiro artigo, foi possível identificar que as publicações sobre o tema começaram em 1995, porém tiveram aumento significativo a partir de 2016, e manteve-se crescente até o ano de 2021. No levantamento, também foi possível identificar que os setores de hotelaria, educação, saúde, transporte e telecomunicações são os cinco que mais possuem publicações, e outros como turismo, alimentação, tecnologia da informação, energia e serviços gerais apresentaram ao menos uma publicação. No entanto, com os dados da literatura não foi encontrada nenhuma publicação nos setores de serviços públicos e financeiro, o que indica uma lacuna na literatura para estas áreas.

No setor de hotelaria, a maioria das publicações realizaram estudos de bases de dados extraídas de sites como *TripAdvisor*, *Yep* e *Booking*, que são portais destinados à avaliação e reserva de hotéis. Por meio de *web scraping* e/ou API's (*Application Programming Interface*),

os dados destas plataformas podem ser extraídos e processados para pesquisa, ou seja, é possível concluir que a disponibilidade e acessibilidade de dados favoreceu o desenvolvimento de pesquisas neste setor. Da mesma forma, o setor de educação apresenta maioria de publicações com utilização de dados originários de questionários de satisfação, onde muitos pesquisadores aplicaram as pesquisas dentro das próprias universidades onde trabalharam para aplicar ML.

De todos os artigos analisados, notou-se que a maioria dos autores estão filiados a países como EUA, China, Malásia e Reino Unido. Além disso, as nacionalidades das bases de dados estudadas na literatura estão concentradas em EUA, China, Espanha, Malásia e Turquia. Portanto, este resultado indica que alguns países carecem de pesquisas e publicações sobre o tema, como é o caso do Brasil, onde apenas dois artigos possuem autores filiados no país, e apenas uma base de dados nacional foi explorada.

Outro resultado que vale ser destacado no Artigo 1 é sobre os periódicos. Com a revisão sistemática da literatura, verificou-se que as pesquisas estão distribuídas em periódicos destinados a assuntos voltados à qualidade de serviços e seus respectivos setores, sem estar concentrado em periódicos específicos sobre ML e *data mining*. Portanto, as pesquisas sobre ML em qualidade de serviço estão disseminadas nas revistas das próprias áreas de estudo e aplicação, o que indica uma heterogeneidade do conhecimento e pesquisa sobre o tema.

Portanto, com os resultados do Artigo 1, foi possível construir uma agenda de pesquisa, que apresentou as principais lacunas e oportunidades que podem ser preenchidas por pesquisadores em trabalhos futuros. Neste caso, foram apresentadas três lacunas, uma relacionada aos setores de serviços que apresentaram poucas publicações, outra sobre fontes de dados que podem ser exploradas, e por fim, sobre países com baixa quantidade de publicações.

Com a agenda de pesquisa apresentada no final do Artigo 1, foi identificado que o setor de telecomunicações brasileiro foi pouco explorado na literatura sobre aplicação de ML para qualidade de serviços. Dessa forma, com a aplicação realizada em dados da ANATEL para satisfação de clientes com serviços de banda larga, concluiu-se que algumas técnicas como HGB, RF, DT e GB apresentam melhores desempenho para classificação. Além disso, com a utilização da escala NPS, os resultados mostraram que os clientes considerados neutros podem impactar no desempenho da classificação, pois eles possuem perfil incerto sobre o índice da satisfação com o serviço.

Por fim, a satisfação do cliente com a capacidade do serviço em fornecer internet sem quedas, velocidade de navegação, cobrança, entendimento dos planos e fornecimento dos serviços conforme o prometido, são os atributos mais relevantes para a satisfação de clientes em serviços de banda-larga no Brasil. Com isso, as empresas prestadoras de serviço no país

podem direcionar atenção a estes atributos, e assim gerar iniciativas para melhoria da qualidade do serviço de banda-larga no Brasil.

Portanto, nesta pesquisa foi possível identificar diversidade de publicações sobre aplicação de ML para qualidade de serviços e satisfação de clientes, lacunas na literatura, oportunidades de pesquisa, estudos sobre aplicação de ML para classificar clientes com base no NPS, e atributos mais relevantes para a satisfação dos serviços estudados. Com isso, a utilização de ML dentro deste contexto pode ocasionar diversos benefícios práticos e científicos, com possibilidade de aplicação em diversos setores.

Para o artigo em que foi relatada a revisão sistemática, pode-se destacar algumas limitações, como a utilização de apenas duas fontes de dados (*Scopus* e *WoS*), a apresentação das contribuições de apenas os cinco setores mais frequentes, deixando de explorar melhor os outros de menor expressão, a construção da *string* de busca limitada a setores e aplicação empírica nas plataformas, e por fim, devido a grande quantidade de artigos extraídos, existiu a possibilidade de alguns terem sido classificados de forma errada, ou seja, artigos que deveriam ter sido incluídos foram excluídos da base devido a uma análise errada do pesquisador.

Já para o segundo artigo, algumas limitações no desenvolvimento da pesquisa foram: a falta de aplicação de técnicas de pré-processamento, a exploração de poucos métodos de importância de atributos, utilização de apenas um recorte da base de dados, limitação dos dados para apenas os anos de 2017 a 2020 e a aplicação de apenas técnicas de classificação.

Como sugestão para trabalhos futuros, no primeiro artigo podem ser realizadas buscas em outras bases de dados além de *Scopus* e *WoS*, expansão da *string* de busca para identificação de outras palavras-chaves que podem resultar em mais artigos, ou até mesmo especificar mais a pesquisa, como por exemplo, levantar artigos que exploraram apenas dados de plataformas online, e assim ter uma análise mais detalhada de cada publicação.

Para o segundo artigo, é recomendado utilização de mais técnicas de pré-processamento para otimizar os resultados das técnicas, buscar outros métodos de atributos mais relevantes e explorar aplicação de técnicas de clusterização. No Brasil existem outras bases de dados que podem ser exploradas, como satisfação de clientes com telefonia móvel e TV por assinatura da ANATEL, satisfação de aeroportos da SAC, redes sociais e sites online. Por fim, como mostrou os dados do Artigo 1, outros setores como de serviços públicos e financeiro são lacunas da literatura, e pesquisas sobre ML para qualidade de serviços nestas áreas também são oportunidades para pesquisas futuras.

A gestão da qualidade de serviços apresenta desafios e benefícios para organizações que prestam serviços. Esta prática pode ocasionar a geração de bases de dados devido a

utilização de indicadores de satisfação. Assim, como foi apresentado nesta pesquisa, a aplicação de ML para qualidade de serviços pode contribuir para o processamento e análise destes dados, com a construção de sistemas preditivos, levantamento de relevância de atributos e análise de clusters, e além disso existem exemplos de pesquisas em diversos setores. Portanto, o desenvolvimento de pesquisas com este tema pode ocasionar benefícios práticos e teóricos, o que foi apresentado neste trabalho, com uma revisão sistemática, onde a literatura científica sobre o tema foi analisada, e com uma aplicação de ML para serviços de banda-larga no Brasil.

REFERÊNCIAS

ABIMANYU,D.; POERNOMO, S. Indonesian online travel agent sentiment analysis using machine learning methods. **Indonesian Journal of Electrical Engineering and Computer Science**, vol. 14, no. 1, p. 113–117, 2019.

ABRADEE. 22a Pesquisa Abradee de Satisfação do Cliente Residencial. **ABRADEE**, 2020. Available at: <https://www.abradee.org.br/22a-pesquisa-abradee-de-satisfacao-do-cliente-residencial/>. Acessado em: 7 Abr. 2022.

AHANI, A.; NILASHI, M.; YADEGARIDEHKORDI, E.; SANZOGNI, L.; TARIK, A. R.; KNOX, K.; SAMAD, S.; IBRAHIM, O. Revealing customers' satisfaction and preferences through online review analysis: The case of Canary Islands hotels. **Journal of Retailing and Consumer Services**, vol. 51, p. 331–343, 2019. DOI 10.1016/j.jretconser.2019.06.014.

AHANI, A.; NILASHI, M.; ZOGAAN, W. A.; SAMAD, S.; ALJEHANE, N. O.; ALHARGAN, A.; MOHD, S.; AHMADI, H.; SANZOGNI, L. Evaluating medical travelers' satisfaction through online review analysis. **Journal of Hospitality and Tourism Management**, vol. 48, p. 519–537, 2021.

AHMED, A. Z.; RODRIGUEZ-DIAZ, M. Significant Labels in Sentiment Analysis of Online Customer Reviews of Airlines. **Sustainability**, vol. 12, no. 20, 2020.

ALBUQUERQUE, C.; EDUARDO, E. Evaluation Of The Capability Of The Mobile Phone Service In Southern Brazil Through The Perception Of Its Customers. **International Journal for Quality Research**, vol. 12, no. 2, p. 441–458, 2018.

ALHAMAD, I. A.; SINGH, H. P. Predicting Key Factors Impacting Online Hotel Ratings Using Data Mining Approach: A Case Study of the Makkah City of Saudi Arabia.

International Transaction Journal Of Engineering Management & Applied Sciences & Technologies, vol. 12, no. 2, 2021.

ALHENDAWI, K. M.; BAHARUDIN, A. S. A classification model for predicting web users satisfaction with information systems success using data mining techniques. **Journal of Software Engineering**, vol. 8, no. 4, p. 265–277, 2014. DOI 10.3923/jse.2014.265.277.

ALI, S; WANG, G. J.; RIAZ, S. Aspect Based Sentiment Analysis of Ridesharing Platform Reviews for Kansei Engineering. **IEEE ACCESS**, vol. 8, p. 173186–173196, 2020.

ALTUNTAS, S.; DERELI, T.; ERDOĞAN, Z. Evaluation of service quality using SERVQUAL scale and machine learning algorithms: a case study in health care. **Kybernetes**, vol. 51, no. 2, 2021.

ALTUNTAS, S.; KANSU, S. An innovative and integrated approach based on SERVQUAL, QFD and FMEA for service quality improvement: A case study. **Kybernetes**, vol. 49, no. 10, p. 2419–2453, 2020.

AMAN, J. J. C.; SMITH-COLIN, J.; ZHANG, W. W. Listen to E-scooter riders: Mining rider satisfaction factors from app store reviews. **Transportation Research Part D-transport And Environment**, vol. 95, 2021.

ANATEL. Banco de Dados da Pesquisa - Banda Larga Fixa. **Dados Abertos Governo Federal** 2020. Disponível em: <https://dados.gov.br/dados/conjuntos-dados/pesquisas-de-satisfacao-e-qualidade-percebida>. Acesso em: 23 fev. 2023.

ANATEL. Glossário e Metadados da Pesquisa de Satisfação e Qualidade Percebida. **Dados Abertos Governo Federal** 2022. Disponível em: https://www.anatel.gov.br/dadosabertos/PDA/Pesquisa/Pesquisa_Satisfacao_Glossario_e_Metadados.pdf . Acesso em: 01 abr. 2023.

ANATEL. Manual de Aplicação da Pesquisa para Aferição do Grau de Satisfação e da

Qualidade Percebida Junto aos Usuários de Serviços de Telecomunicações. **Site Governo Federal**, 2018. Disponível em: <https://sistemas.anatel.gov.br/anexar-api/publico/anexos/download/3236b890e56e212bc319e6d1e2076655>. Acesso em: 21 fev. 2023.

ANATEL. Satisfação e Qualidade Percebida. 2022. **Site Governo Federal**, Disponível em: <https://www.gov.br/anatel/pt-br/consumidor/compare-as-prestadoras/pesquisa-de-satisfacao-e-qualidade>. Acessado em: 21 fev. 2023.

ANTONIO, N.; DE ALMEIDA, A. M.; NUNES, L.; BATISTA, F.; RIBEIRO, R. Hotel online reviews: creating a multi-source aggregated index. **International Journal Of Contemporary Hospitality Management**, vol. 30, no. 12, p. 3574–3591, 2018.

AYDIN, Z. E.; OZTURK, Z. K.; CICEK, Z. I. E. Turkish Sentiment Analysis for Open and Distance Education Systems. **Turkish Online Journal of Distance Education**, vol. 22, no. 3, p. 124–138, 2021.

BAGHERZADEH, S.; SHOKOUHYAR, S.; JAHANI, H.; SIGALA, M. A generalizable sentiment analysis method for creating a hotel dictionary: using big data on TripAdvisor hotel reviews. **Journal Of Hospitality And Tourism Technology**, vol. 12, no. 2, p. 210–238, 2021.

BAIER, L.; KÜHL, N.; SCHÜRITZ, R.; SATZGER, G. Will the customers be happy? Identifying unsatisfied customers from service encounter data. **Journal of Service Management**, vol. 32, no. 2, p. 265–288, 2021.

BERNARDES, Bruna Vieira da Rosa. **Caracterização da pesquisa de satisfação e qualidade percebida da Anatel para telefonia móvel**. 2020. 75 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Telecomunicações) - Universidade Federal Fluminense, 2020

BERRY, L. L.; PARASURAMAN, A.; ZEITHAML, V. A. **Improving service quality in America: Lessons learned**. *Academy of Management Perspectives*, vol. 8, no. 2, p. 32–45, 1994.

BOGICEVIC, V.; YANG, W.; BUJISIC, M.; BILGIHAN, A. **Visual Data Mining: Analysis of Airline Service Quality Attributes**. *Journal Of Quality Assurance In Hospitality & Tourism*, vol. 18, no. 4, p. 509–530, 2017.

BORAKATI, A. Evaluation of an international medical E-learning course with natural language processing and machine learning. **Bmc Medical Education**, vol. 21, no. 1, 2021.

BROCHADO, A.; RITA, P.; MORO, S. Discovering Patterns in Online Reviews of Beijing and Lisbon Hostels. **Journal Of China Tourism Research**, vol. 15, no. 2, p. 172–191, 2019.

BUCHLAK, Q. D.; ESMAILI, N.; LEVEQUE, J.-C.; BENNETT, C.; FARROKHI, F.; PICCARDI, M. Machine learning applications to neuroimaging for glioma detection and classification: An artificial intelligence augmented systematic review. **Journal of Clinical Neuroscience**, vol. 89, p. 177–198, Jul. 2021.

BURHANUDDIN, M. A.; ISMAIL, R.; IZZAIMAH, N.; MOHAMMED, A. A.-J.; ZAINOL, N. Analysis of mobile service providers performance using naive bayes data mining technique. **International Journal of Electrical and Computer Engineering**, vol. 8, no. 6, p. 5153–5161, 2018.

CARNERUD, D., 25 years of quality management research – outlines and trends, **International Journal of Quality & Reliability Management**, vol. 35 no. 1, p.208-231, 2018.

CAVALCANTE SIEBERT, L.; BIANCHI FILHO, J. F.; SILVA JÚNIOR, E. J. da; KAZUMI YAMAKAWA, E.; CATAPAN, A. Predicting customer satisfaction for distribution companies using machine learning. **International Journal of Energy Sector Management**, vol. 15, no. 4, 2019. <https://doi.org/10.1108/IJESM-10-2018-0007>.

CAUCHICK MIGUEL, P. A.; FLEURY, A.; PEREIRA MELLO, C. H.; NAKANO, D. N.; LIMA, E. P. de; TURRIONI, J. B.; LEE HO, L.; MORABITO, R.; SOUSA, R.; GOUVÊA DA COSTA, S. E.; PUREZA, V.; SÉRGIO, E. G. da C.; EDSON PINHEIRO DE LIMA. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. [S. l.: s.

n.], 2018. Disponível em: <https://books.google.com.br/books?id=JO1oDwAAQBAJ>.

CEYHAN, M.; ORHAN, Z.; KARRAS, D. Sentiment Analysis of Hospital Service Satisfaction. **Journal Of Research In Medical And Dental Science**, vol. 8, no. 5, p. 6–10, 2020.

CHAMORRO-ATALAYA, O.; CHÁVEZ-HERRERA, C.; SANTOS, M. A. D. L.; SANTOS, J. A. D. L.; TORRES-QUIROZ, A.; LEVA-APAZA, A.; TASAYCO-JALA, A.; PERALTA-EUGENIO, G. Machine Learning Model through Ensemble Bagged Trees in Predictive Analysis of University Teaching Performance. **International Journal of Advanced Computer Science and Applications**, vol. 12, no. 12, p. 367–373, 2021. DOI 10.14569/IJACSA.2021.0121249.

CHANG, Y. C.; KU, C. H.; CHEN, C. H. Social media analytics: Extracting and visualizing Hilton hotel ratings and reviews from TripAdvisor. **International Journal of Information Management**, vol. 48, p. 263–279, 1 Oct. 2019.

CHATTERJEE, S.; GHATAK, A.; NIKTE, R.; GUPTA, S.; KUMAR, A. Measuring SERVQUAL dimensions and their importance for customer-satisfaction using online reviews: a text mining approach. **Journal of Enterprise Information Management**, vol. 36, no. 1, 2022.

CHUNG, J.; LEE, J.; YOON, J. Understanding music streaming services via text mining of online customer reviews. **Electronic Commerce Research and Applications**, vol. 53, 2022.

COX, T.; BELL, G. A machine learning approach to process improvement in a telecommunications company. **Annals of Operations Research**, vol. 65, p. 21–34, 1996.

COX, T.; BELL, G.; GLOVER, F. A new learning approach to process improvement in a telecommunications company. **Production and Operations Management**, vol. 4, no. 3, p. 217–227, 1995.

CUNNINGHAM-NELSON, S.; BAKTASHMOTLAGH, M.; BOLES, W. Visualizing Student Opinion through Text Analysis. **IEEE Transactions on Education**, vol. 62, no. 4, p.

305–311, 2019.

DE OÑA, J.; DE OÑA, R.; CALVO, F. J. A classification tree approach to identify key factors of transit service quality. **Expert Systems with Applications**, vol. 39, no. 12, p. 11164–11171, 2012.

DE OÑA, J.; DE OÑA, R.; GARRIDO, C. Extraction of attribute importance from satisfaction surveys with data mining techniques: a comparison between neural networks and decision trees. **Transportation Letters**, vol. 9, no. 1, p. 39–48, 2017.

DE OÑA, R.; DE OÑA, J. Analysis of transit quality of service through segmentation and classification tree techniques. **Transportmetrica A-transport Science**, vol. 11, no. 5, p. 365–387, 2015.

DEJAEGER, K.; GOETHALS, F.; GIANGRECO, A.; MOLA, L.; BAESENS, B. Gaining insight into student satisfaction using comprehensible data mining techniques. **European Journal of Operational Research**, vol. 218, no. 2, p. 548–562, 2012.

DÍEZ-MESA, F.; DE OÑA, R.; DE OÑA, J. Bayesian networks and structural equation modelling to develop service quality models: Metro of Seville case study. **Transportation Research Part A: Policy and Practice**, vol. 118, p. 1–13, 2018.

DOS SANTOS, B. S.; STEINER, M. T. A.; FENERICH, A. T.; LIMA, R. H. P. Data mining and machine learning techniques applied to public health problems: A bibliometric analysis from 2009 to 2018. **Computers & Industrial Engineering**, vol. 138, p. 106120, Dec. 2019.

FARHADLOO, M.; PATTERSON, R. A.; ROLLAND, E. Modeling customer satisfaction from unstructured data using a Bayesian approach. **Decision Support Systems**, vol. 90, p. 1–11, 2016.

FARAZI, N. P.; MURSHED, M. N.; HADIUZZAMAN, M. Application of machine learning to investigate heterogeneity in users' perception of intercity train service quality in developing countries. **Case Studies on Transport Policy**, vol. 10, no. 1, p. 227–238, 2022.

GAO, K.; YANG, Y.; QU, X. B. Examining nonlinear and interaction effects of multiple determinants on airline travel satisfaction. **Transportation Research Part D-transport And Environment**, vol. 97, 2021.

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and Tensorflow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2nd ed. [S. l.]: O'Reilly Media, 2019.

GRLJEVIC, O.; BOSNJAK, Z.; KOVACEVIC, A. Opinion mining in higher education: a corpus-based approach. **Enterprise Information Systems**, vol. 16, no. 5, 2020.

GRONBERG, N.; KNUTAS, A.; HYNNINEN, T.; HUJALA, M. Palaute: An online text mining tool for analyzing written student course feedback. **IEEE Access**, vol. 9, p. 134518–134529, 2021.

GOVERNO DO BRASIL, Anatel disponibiliza Plano de Gestão Tático 2023-2024. **Site Governo Federal**, 2023. Disponível em: <https://www.gov.br/anatel/pt-br/assuntos/noticias/anatel-disponibiliza-plano-de-gestao-tatico-2023-2024>. Acessado em 14 de fev. de 2023.

GOVERNO DO BRASIL, Setor de serviços cresce 10,9% com altas nas cinco atividades pesquisadas. **Site Governo Federal**, 2022. Disponível em: <https://www.gov.br/pt-br/noticias/trabalho-e-previdencia/2022/02/setor-de-servicos-cresce-10-9-com-altas-nas-cinco-atividades-pesquisadas>. Acessado em 18 de jun de 2022.

GUO, Y.; BARNES, S. J.; JIA, Q. Mining meaning from online ratings and reviews: Tourist satisfaction analysis using latent dirichlet allocation. **Tourism Management**, vol. 59, p. 467–483, 2017.

HADWAN, M.; AL-HAGERY, M. A.; AL-SAREM, M.; SAEED, F. Arabic Sentiment Analysis of Users' Opinions of Governmental Mobile Applications. **Computers, Materials and Continua**, vol. 72, no. 3, p. 4675–4689, 2022.

HEW, K F; HU, X.; QIAO, C.; TANG, Y. What predicts student satisfaction with MOOCs: A

gradient boosting trees supervised machine learning and sentiment analysis approach.

Computers & Education, vol. 145, 2020.

HO, I. M. K.; CHEONG, K. Y.; WELDON, A. Predicting student satisfaction of emergency remote learning in higher education during COVID-19 using machine learning techniques.

PLOS ONE, vol. 16, no. 4, 2021.

HONG, J. W.; PARK, S. B. The Identification of Marketing Performance Using Text Mining of Airline Review Data. **Mobile Information Systems**, vol. 2019, 2019.

HOSSEINI, S. Y.; ZIAEI BIDEH, A. A data mining approach for segmentation-based importance-performance analysis (SOM-BPNN-IPA): A new framework for developing customer retention strategies. **Service Business**, vol. 8, no. 2, p. 295–312, 2014.

HU, N.; ZHANG, T.; GAO, B.; BOSE, I. What do hotel customers complain about? Text analysis using structural topic model. **Tourism Management**, vol. 72, p. 417–426, 2019.

IMRAN, M.; HINA, S.; BAIG, M. M. Analysis of Learner's Sentiments to Evaluate Sustainability of Online Education System during COVID-19 Pandemic. **Sustainability**, vol. 14, no. 8, 2022.

JAMES, T. L.; VILLACIS CALDERON, E. D.; COOK, D. F. Exploring patient perceptions of healthcare service quality through analysis of unstructured feedback. **Expert Systems with Applications**, vol. 71, p. 479–492, 2017.

KAUR, M.; MEHTA, H.; RANDHAWA, S.; SHARMA, P. K.; PARK, J. H. Ensemble learning-based prediction of contentment score using social multimedia in education.

Multimedia Tools and Applications, vol. 80, no. 26–27, p. 34423–34440, 2021.

KOWALSKI, R.; ESTEVE, M.; MIKHAYLOV, S. J. Improving public services by mining citizen feedback: An application of natural language processing. **Public Administration**, vol. 98, no. 4, p. 1011–1026, 2020.

KRISTENSEN, K.; ESKILDSEN, J. Is the Net Promoter Score a Reliable Performance

Measure ? **IEEE International Conference on Quality and Reliability**, 2011a, pp. 249-253.

KRISTENSEN, K.; ESKILDSEN, J. The validity of the Net Promoter Score as a business performance measure, **2011 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering**, 2011b, pp. 970-974.

KUNZE, K. N.; POLCE, E. M.; SADAUSKAS, A. J.; LEVINE, B. R. Development of Machine Learning Algorithms to Predict Patient Dissatisfaction After Primary Total Knee Arthroplasty. **Journal Of Arthroplasty**, vol. 35, no. 11, p. 3117–3122, 2020..

KWON, W.; LEE, M.; BOWEN, J. T. Exploring Customers' Luxury Consumption in Restaurants: A Combined Method of Topic Modeling and Three-Factor Theory. **Cornell Hospitality Quarterly**, vol. 63, no. 1, p. 66–77, 2022.

LANGAN, A. M.; HARRIS, W. E. National student survey metrics: where is the room for improvement? **Higher Education**, vol. 78, no. 6, p. 1075–1089, 27 2019.

LEE, M.; LEE, S.; KOH, Y. Multisensory experience for enhancing hotel guest experience: Empirical evidence from big data analytics. **International Journal of Contemporary Hospitality Management**, vol. 31, no. 11, p. 4313–4337, 2019.

LI, C.; WANG, Y.; LI, D.; CHU, D.; MA, M. An Effective Method of Evaluating Pension Service Quality Using Multi-Dimension Attention Convolutional Neural Networks. **International Journal of Software Engineering and Knowledge Engineering**, vol. 31, no. 4, p. 533–543, 2021.

LI, W. Research on Evaluation Method of Physical Education Teaching Quality in Colleges and Universities Based on Decision Tree Algorithm. **Mobile Information Systems**, vol. 2022, 2022.

LI, W.; SPACHOS, P.; CHIGNELL, M.; LEON-GARCIA, A.; ZUCHERMAN, L.; JIANG, J. A quantitative relationship between Application Performance Metrics and Quality of Experience for Over-The-Top video. **Computer Networks**, vol. 142, p. 194–207, 4 Sep. 2018.

LIN, S.-M. Analysis of service satisfaction in web auction logistics service using a combination of Fruit fly optimization algorithm and general regression neural network. **Neural Computing and Applications**, vol. 22, no. 3–4, p. 783–791, 2013.

LIU, N.; KUMARA, S.; REICH, E. Gaining Insights into Patient Satisfaction through Interpretable Machine Learning. **IEEE Journal of Biomedical and Health Informatics**, vol. 25, no. 6, p. 2215–2226, 2021.

LIU, Y.; LI, Y.; LI, W. Natural language processing approach for appraisal of passenger satisfaction and service quality of public transportation. **IET Intelligent Transport Systems**, vol. 13, no. 11, p. 1701–1707, 2019.

LUCINI, F. R.; TONETTO, L. M.; FOGLIATTO, F. S.; ANZANELLO, M. J. Text mining approach to explore dimensions of airline customer satisfaction using online customer reviews. **Journal of Air Transport Management**, vol. 83, 2020.

LUNDBERG, S. M.; ERION, G.; CHEN, H.; DEGRAVE, A.; PRUTKIN, J. M.; NAIR, B.; KATZ, R.; HIMMELFARB, J.; BANSAL, N.; LEE, S.-I. From local explanations to global understanding with explainable AI for trees. **Nature Machine Intelligence**, vol. 2, no. 1, p. 56–67, 2020.

LUO, Y.; XU, X. W. Comparative study of deep learning models for analyzing online restaurant reviews in the era of the COVID-19 pandemic. **International Journal Of Hospitality Management**, vol. 94, 2021.

LUO, Y.; HE, J.; MOU, Y.; WANG, J.; LIU, T. Exploring China's 5A global geoparks through online tourism reviews: A mining model based on machine learning approach. **Tourism Management Perspectives**, vol. 37, 2021.

MARKOULIDAKIS, I.; RALLIS, I.; GEORGOULAS, I.; KOPSIAFTIS, G.; DOULAMIS, A.; DOULAMIS, N. A Machine Learning Based Classification Method for Customer Experience Survey Analysis. **Technologies**, vol. 8, no. 4, p. 76, 2020.

MEJIA, J.; MANKAD, S.; GOPAL, A. Service quality using text mining: Measurement and consequences. **Manufacturing and Service Operations Management**, vol. 23, no. 6, p. 1354–1372, 2021.

MENDELEY. Mendeley Desktop. **Mendeley**, 2021. Disponível em: <https://www.mendeley.com/reference-management/mendeley-desktop>. Acessado em: 8 Apr. 2022.

MENENDEZ, M. E.; SHAKER, J.; LAWLER, S. M.; MD, D. R.; JAWA, A. Negative Patient-Experience Comments After Total Shoulder Arthroplasty. **Journal Of Bone And Joint Surgery-american Volume**, vol. 101, no. 4, p. 330–337, 2019.

MIRANDA-VALENCIA, B. L. Satisfaction and Consumption Emotions of Library Users at a Public University in Mexico: A Case Study. **Libri**, vol. 71, no. 2, p. 109–121, 2021.

MISHRA, D. N.; PANDA, R. K. How delightful is indian wellness tourism? A netnographic study. **Advances in Hospitality and Tourism Research**, vol. 9, no. 1, p. 132–156, 2021.

MOORE, M. T. **Constructing a sentiment analysis model for LibQUAL+ comments**. Performance Measurement And Metrics, vol. 18, no. 1, p. 78–87, 2017.

MORO, S. **Guest satisfaction in East and West: evidence from online reviews of the influence of cultural origin in two major gambling cities, Las Vegas and Macau**. Tourism Recreation Research, vol. 45, no. 4, p. 539–548, 2020.

MORO, S.; RITA, P.; OLIVEIRA, C.; BATISTA, F.; RIBEIRO, R. Leveraging national tourist offices through data analytics. **International Journal Of Culture Tourism And Hospitality Research**, vol. 12, no. 4, p. 420–426, 2018.

MORO, S.; ESMERADO, J.; RAMOS, P.; ALTURAS, B. Evaluating a guest satisfaction model through data mining. **International Journal of Contemporary Hospitality Management**, vol. 32, no. 4, p. 1523–1538, 2020.

MOTA, M. de O.; NOGUEIRA, C. A. G.; ALMEIDA, F. C. de; LIMA, P. G. N. de;

MOURA, H. J. de. Uma análise dos serviços de telefonia móvel no Brasil: uma proposta de modelo empírico. **REAd. Revista Eletrônica de Administração (Porto Alegre)**, vol. 18, no. 3, p. 747–778, 2012.

NGAI, E. W. T.; XIU, L.; CHAU, D. C. K. Application of data mining techniques in customer relationship management: A literature review and classification. **Expert Systems with Applications**, vol. 36, no. 2, p. 2592–2602, 2009.

NGUYEN, B.; NGUYEN, V.-H.; HO, T. Sentiment Analysis of Customer Feedback in Online Food Ordering Services. **Business Systems Research**, vol. 12, no. 2, p. 46–59, 2021.

NILASHI, M; ABUMALLOH, R. A.; ALGHAMDI, A.; MINAEI-BIDGOLI, B.; ALSULAMI, A. A.; THANOON, M.; ASADI, S.; SAMAD, S. What is the impact of service quality on customers' satisfaction during COVID-19 outbreak? New findings from online reviews analysis. **Telematics And Informatics**, vol. 64, 2021.

NILASHI, M.; ABUMALLOH, R. A.; MINAEI-BIDGOLI, B.; ABDU ZOGAAN, W.; ALHARGAN, A.; MOHD, S.; SYED AZHAR, S. N. F.; ASADI, S.; SAMAD, S. Revealing travellers' satisfaction during COVID-19 outbreak: Moderating role of service quality. **Journal of Retailing and Consumer Services**, vol. 64, 2022.

NOVIANTORO, T.; HUANG, J.-P. Investigating airline passenger satisfaction: Data mining method. **Research in Transportation Business and Management**, vol. 43, no. 100726, 2021.

OKUDA, M.; YASUDA, A.; TSUMOTO, S. An approach to exploring associations between hospital structural measures and patient satisfaction by distance-based analysis. **BMC Health Services Research**, vol. 21, no. 1, 2021

OLIVEIRA, A. S.; RENDA, A. I.; CORREIA, M. B.; ANTONIO, N. Hotel customer segmentation and sentiment analysis through online reviews: an analysis of selected European markets. **Tourism & Management Studies**, vol. 18, no. 1, p. 29–40, 2022.

OSORIO-ARJONA, J.; HORAK, J.; SVOBODA, R.; GARCIA-RUIZ, Y. Social media

semantic perceptions on Madrid Metro system: Using Twitter data to link complaints to space. **Sustainable Cities And Society**, vol. 64, 2021.

OTHMAN, N.; HUSSIN, M.; MAHMOOD, R. A. R. Sentiment evaluation of public transport in social media using naïve bayes method. **International Journal of Engineering and Advanced Technology**, vol. 9, no. 1, p. 2305–2308, 2019.

PAN, W.-T. Using data mining for service satisfaction performance analysis for mainland tourists in Taiwan. **International Journal of Technology Management**, vol. 64, no. 1, p. 31–44, 2014.

PÉREZ RAVE, J. I.; JARAMILLO ÁLVAREZ, G. P.; GONZÁLEZ ECHAVARRÍA, F. A psychometric data science approach to study latent variables: a case of class quality and student satisfaction. **Total Quality Management & Business Excellence**, vol. 33, p. 1–26, 2021.

PINEDA-JARAMILLO, J.; PINEDA-JARAMILLO, D. Analysing travel satisfaction of tourists towards a metro system from unstructured data. **Research in Transportation Business and Management**, vol. 43, 2021.

PIRRA, M.; PENSA, R. G. Comparing Transport Quality Perception among Different Travellers in European Cities through Co-Cluster Analysis. **Sustainability**, vol. 11, no. 24, 2019.

PRIHATNA, K. A.; SO, I. G.; SAROSO, H.; KOSASIH, W. What about service quality, satisfaction, and loyalty in e-business? a systematic review of literature. In: International Conference on Information Management and Technology, 2021, **ICIMTech 2021**, no. August, p. 767–772, 2021.

RABAIEI, K. Al; ALNAJJAR, F.; AHMAD, A. Kano model integration with data mining to predict customer satisfaction. **Big Data and Cognitive Computing**, vol. 5, no. 4, 2021

RAHIM, A I A; IBRAHIM, M. I.; CHUA, S. L.; MUSA, K. I. Hospital Facebook Reviews Analysis Using a Machine Learning Sentiment Analyzer and Quality Classifier. **Healthcare**,

vol. 9, no. 12, 2021a.

RAHIM, A I A.; IBRAHIM, M. I.; MUSA, K. I.; CHUA, S. L.; YAACOB, N. M. Patient Satisfaction and Hospital Quality of Care Evaluation in Malaysia Using SERVQUAL and Facebook. **Healthcare**, vol. 9, no. 10, 2021b.

RAHIM, A I A.; IBRAHIM, M. I.; MUSA, K. I.; CHUA, S. L.; YAACOB, N. M. Assessing patient-perceived hospital service quality and sentiment in malaysian public hospitals using machine learning and facebook reviews. **International Journal of Environmental Research and Public Health**, vol. 18, no. 18, 1 Sep. 2021c.

RAM, Y.; GAL-TZUR, A.; REHAVI, A. Identifying attributes of public transport services for urban tourists: A data-mining method. **Journal Of Transport Geography**, vol. 93, 2021..

REICHHELD F F. The one number you need to grow. **Harvard Business Review**, vol. 81, no. 12, p. 46, 2003.

SAC. **Pesquisa de Satisfação do Passageiro**. 2022. Available at:

<https://www.gov.br/infraestrutura/pt-br/assuntos/transporte-aereo/pesquisa-de-satisfacao>. Accessed on: 13 Apr. 2022.

SAMARA, D.; MAGNISALIS, I.; PERISTERAS, V. Artificial intelligence and big data in tourism: a systematic literature review. **Journal of Hospitality and Tourism Technology**, vol. 11, no. 2, p. 343–367, 2020.

SÁNCHEZ-FRANCO, M. J.; NAVARRO-GARCÍA, A.; RONDÁN-CATALUÑA, F. J. A naive Bayes strategy for classifying customer satisfaction: A study based on online reviews of hospitality services. **Journal of Business Research**, vol. 101, p. 499–506, 2019.

SÁNCHEZ-FRANCO, M J; CEPEDA-CARRION, G.; ROLDAN, J. L. Understanding relationship quality in hospitality services A study based on text analytics and partial least squares. **Internet Research**, vol. 29, no. 3, p. 478–503, 2019.

SANGKAEW, N.; ZHU, H. Understanding Tourists' Experiences at Local Markets in Phuket:

An Analysis of TripAdvisor Reviews. **Journal of Quality Assurance in Hospitality and Tourism**, vol. 23, no. 1, p. 89–114, 2022.

SCIKIT-LEARN. Feature importances with a forest of trees. **Scikit-Learn**, 2022. Disponível em: https://scikit-learn.org/stable/auto_examples/ensemble/plot_forest_importances.html. Acessado em: 13 fev. 2023.

SEZGEN, E; MASON, K. J.; MAYER, R. Voice of airline passenger: A text mining approach to understand customer satisfaction. **Journal of Air Transport Management**, vol. 77, p. 65–74, 2019.

SHABANI, H.; AZIMI, P. Evaluation of electronic service quality using an integrated fuzzy clustering and principle component analysis approach: An empirical case study. **International Journal of Applied Management Science**, vol. 9, no. 3, p. 234–251, 2017.

SHAP. An introduction to explainable AI with Shapley values. **SHAP**, 2018. Disponível em: [https://shap.readthedocs.io/en/latest/example_notebooks/overviews/An introduction to explainable AI with Shapley values.html](https://shap.readthedocs.io/en/latest/example_notebooks/overviews/An%20introduction%20to%20explainable%20AI%20with%20Shapley%20values.html). Acessado em: 3 Dec. 2022.

SCHENDES, W. Setor de telecomunicações investiu R\$8,3 bilhões em 2022. **Olhar Digital**, São Paulo, 16 de Ago. 2022. Disponível em: <https://olhardigital.com.br/2022/08/16/pro/telecomunicacoes-investimentos-2022/>. Acessado em : 14 de fev. de 2023.

SIEBERT, L. C.; BIANCHI, J. F.; DA SILVA, E. J.; YAMAKAWA, E. K.; CATAPAN, A. Predicting customer satisfaction for distribution companies using machine learning. **International Journal Of Energy Sector Management**, vol. 15, no. 4, p. 743–764, 2021.

SIMSEKLER, M. C. E.; ALHASHMI, N. H.; AZAR, E.; KING, N.; LUQMAN, R.; AL MULLA, A. Exploring drivers of patient satisfaction using a random forest algorithm. **BMC Medical Informatics And Decision Making**, vol. 21, no. 1, 2021.

SKRBINJEK, V.; DERMOL, V. Predicting students' satisfaction using a decision tree. **Tertiary Education and Management**, vol. 25, no. 2, p. 101–113, 2019..

SLOB, N.; CATAL, C.; KASSAHUN, A. Application of machine learning to improve dairy farm management: A systematic literature review. **Preventive Veterinary Medicine**, vol. 187, p. 105237, 2021.

SOUSA, G. N. De; DA SILVA GUIMARÃES, I.; AUGUSTO, J.; VIANA, N.; REINHOLD, O.; FERNANDO, A.; JACOB, L.; MANOEL FRANÇA LOBATO, F. Análise do setor de telecomunicação brasileiro: Uma visão sobre Reclamações. **RISTI -Revista Ibérica de Sistemas e Tecnologias de Informação**, No. 37, p. 31–48, 2020.

SUSANTI, A. R.; DJATNA, T.; KUSUMA, W. A. Twitter's sentiment analysis on GSM services using Multinomial Naïve Bayes. **Telkomnika (Telecommunication Computing Electronics and Control)**, vol. 15, no. 3, p. 1354–1361, 2017.

SUTHERLAND, I.; KIATKAWSIN, K. Determinants of Guest Experience in Airbnb: A Topic Modeling Approach Using LDA. **Sustainability**, vol. 12, no. 8, 2020.

TANRISEVDI, A.; OZTURK, G.; OZTURK, A. C. A supervised data mining approach for predicting comment card ratings. **International Journal Of Contemporary Hospitality Management**, vol. 34, no. 5, p. 1823–1853, 2022.

THOMAS, E. H.; GALAMBOS, N. What satisfies students? Mining student-opinion data with regression and decision tree analysis. **Research In Higher Education**, vol. 45, no. 3, p. 251–269, 2004.

THU, H. N. T. Measuring guest satisfaction from online reviews: Evidence in Vietnam. **Cogent Social Sciences**, vol. 6, no. 1, 2020.

TONG, L.; WANG, Y.; WEN, F.; LI, X. The research of customer loyalty improvement in telecom industry based on NPS data mining. **China Communications**, vol. 14, no. 11, p. 260–268, 2017.

TSAO, H.-Y.; CHEN, M.-Y.; CAMPBELL, C.; SANDS, S. Estimating numerical scale ratings from text-based service reviews. **Journal of Service Management**, vol. 31, no. 2, p.

187–202, 2020.

TURKYILMAZ, A.; TEMIZER, L.; OZTEKIN, A. A causal analytic approach to student satisfaction index modeling. **Annals of Operations Research**, vol. 263, no. 1–2, p. 565–585, 2018.

VARGAS-CALDERON, V.; OCHOA, A. M.; NIETO, G. Y. C.; CAMARGO, J. E. Machine learning for assessing quality of service in the hospitality sector based on customer reviews. **Information Technology & Tourism**, vol. 23, no. 3, p. 351–379, 2021.

VENCOVSKÝ, F. Service Quality Evaluation Using Text Mining: A Systematic Literature Review. **Lecture Notes in Business Information Processing**, vol. 398, no. September, p. 159–173, 2020.

VIECELI, L. Setor de serviços fecha 2022 com alta de 8,3% e bate recorde no Brasil. **Folha de S.Paulo, São Paulo**, 10 de fev. de 2023. Disponível em: <https://www1.folha.uol.com.br/mercado/2023/02/setor-de-servicos-fecha-2022-com-alta-de-83-e-alcanca-patamar-recorde.shtml>. Acessado em 14 de fev de 2023.

WANG, B.; WANG, J.; HU, G. College english classroom teaching evaluation based on particle swarm optimization - extreme learning machine model. **International Journal of Emerging Technologies in Learning**, vol. 12, no. 5, p. 82–97, 2017.

XIA, M. L.; ZHANG, Y. Linear and nonlinear relationships: a hybrid SEM-neural network approach to verify the links of online experience with luxury hotel branding. **Journal Of Hospitality And Tourism Insights**, vol. 5, no. 5, 2021.

XU, Y.; WU, G.; CHEN, Y. Predicting patients' satisfaction with doctors in online medical communities: An approach based on XGBoost Algorithm. **Journal of Organizational and End User Computing**, vol. 34, no. 4, 2022.

ZHANG, C.; MOREIRA, M. R. A.; SOUSA, P. S. A. A bibliometric view on the use of total quality management in services. **Total Quality Management and Business Excellence**, vol. 32, no. 13–14, p. 1466–1493, 2021.

ZHANG, W.; QIN, S. M.; JIN, H. J.; DENG, J.; WU, L. K. An Empirical Study on Student Evaluations of Teaching Based on Data Mining. **Eurasia Journal Of Mathematics Science And Technology Education**, vol. 13, no. 8, p. 5837–5845, 2017.

ZOBAIR, K. M.; SANZOGNI, L.; HOUGHTON, L.; ISLAM, M. Z. Forecasting care seekers satisfaction with telemedicine using machine learning and structural equation modeling. **PLOS ONE**, vol. 16, no. 9, 2021.

APÊNDICE A – COLUNAS DA BASE DE DADOS

Tabela 26 – Descrição das colunas da base de dados.

Código	Descrição
Q2	Área de trabalho do entrevistado.
Q2_1	Trabalha com pesquisa de opinião, departamento de marketing, publicidade entre outros ?
Q2_2	Trabalha em operadoras, ANATEL, ou órgãos relacionados a comunicação ou defesa do consumidor?
Q3	O usuário é cliente da internet fixa da prestadora citada ?
Q4	O entrevistado é um dos principais usuários da internet fixa da prestadora citada na residência ?
Q5	O entrevistado é o responsável pelo pagamento dos gastos da internet fixa da prestadora citada ?
Q6	Pessoa física ou pessoa jurídica ? (Sim ou Não)
Q7	Pessoa física ou pessoa jurídica ? (1 para pessoa física ou 2 para pessoa jurídica).
Q8	Sexo.
J1	Nível de satisfação geral do entrevistado com a prestadora citada, levando em conta toda a experiência com esta.
B1_1	Nota atribuída com respeito à facilidade de entendimento dos planos e serviços contratados
B1_2	Nota atribuída com respeito ao comprometimento da operadora em cumprir o que foi prometido e divulgado em sua publicidade.
C1_1	Notas atribuídas à cobrança de valores na conta de acordo com o contratado
C1_2	Notas atribuídas à capacidade de manter a conexão sem quedas.
C1_3	Notas atribuídas à velocidade de navegação.

-
- D1_1 Notas atribuídas à cobrança dos valores na conta de acordo com o contratado.
- D1_2 Notas atribuídas à clareza das informações na conta.
- A1_1 O entrevistado utilizou o Atendimento Telefônico da prestadora nos 6 meses anteriores à pesquisa?
- A1_2 O entrevistado utilizou o Atendimento pela Internet da prestadora nos 6 meses anteriores à pesquisa?
- A1_3 O entrevistado utilizou o Atendimento na Loja da prestadora nos 6 meses anteriores à pesquisa?
- A1_4 O entrevistado não utilizou os canais da prestadora citados anteriormente nos 6 meses anteriores à pesquisa?
- A2_1 Notas atribuídas ao tempo de espera para falar com o atendente, ocorre somente em caso de Atendimento telefônico ter sido escolhido na pergunta anterior (A1_1).
- A2_2 Notas atribuídas à necessidade de repetir a demanda, ocorre somente em caso de Atendimento telefônico ter sido escolhido na pergunta anterior (A1_1).
- A2_3 Notas atribuídas à capacidade de esclarecimento por parte dos atendentes, ocorre somente em caso de Atendimento telefônico ter sido escolhido na pergunta anterior (A1_1).
- A3 Notas atribuídas à qualidade do Atendimento Telefônico da operadora, ocorre somente em caso de Atendimento telefônico ter sido escolhido na variável (A1_1).
- A4 Notas atribuídas à qualidade do Atendimento pela Internet da operadora, ocorre somente em caso de Atendimento pela internet ter sido escolhido na variável (A1_2)
- E1 Descreve se o entrevistado entrou em contato com a operadora para falar sobre algum problema de cobrança nos 6 meses anteriores à pesquisa
- E2 Ocorre somente em caso de SIM ter sido escolhido em (E1). Nota atribuída à resolução do problema de cobrança da prestadora citada.
- E3 Descreve se o usuário entrou em contato com a prestadora citada para alterar o plano ou alguma condição comercial nos 6 meses anteriores à pesquisa.
- E4 Ocorre somente em caso de SIM ter sido escolhido em (E3). Nota atribuída à resolução da alteração do plano ou condição comercial.

-
- E5 Descreve se o entrevistado entrou em contato com a operadora para cancelar serviços ou pacotes.
- E6 Ocorre somente em caso de SIM ter sido escolhido em (E5). Nota atribuída à resolução do pedido de cancelamento de serviços ou pacotes.
- E7 Descreve se o entrevistado entrou em contato com a operadora para falar sobre problemas de funcionamento da internet fixa.
- E8 Ocorre somente em caso de SIM ter sido escolhido em (E7). Nota atribuída à resolução do problema de funcionamento da internet fixa.
- F1 Descreve se o usuário solicitou instalação de internet fixa em seu endereço atual nos 6 meses anteriores à pesquisa.
- F2_1 Notas atribuídas ao tempo de espera entre a solicitação de instalação e a visita do técnico
- F2_2 Cumprimento do prazo acordado para instalação.
- F2_3 Qualidade da instalação do serviço.
- F3 Descreve se o usuário solicitou algum tipo de reparo na sua internet fixa nos 6 meses anteriores à pesquisa .
- F4_1 Notas atribuídas ao tempo de espera entre a solicitação de reparo e a visita do técnico.
- F4_2 Cumprimento do prazo acordado para reparo.
- F4_3 Qualidade do reparo do serviço.
- G1 Existência de outra operadora que ofereça o mesmo serviço da atual, no local onde o entrevistado mora.
- G2_1 Contrato inclui TV por assinatura, dados a partir de 2019.
- G2_2 Contrato inclui Telefonia Móvel, dados a partir de 2019.
- G2_3 Contrato inclui Telefonia Fixa, dados a partir de 2019.
- H1 Quantidade de pessoas residentes que contribuem com a renda total do domicílio: o entrevistador anota o valor conforme informado pelo entrevistado.
- H2 Renda mensal familiar: o entrevistador anota o valor conforme informado pelo entrevistado.
- H2a Depois de respondida a questão H2 ou em caso de recusa de identificação correta da renda, apresentam-se as opções por faixas de renda.
- I1 Autorização para identificação das respostas para a empresa que solicitou a pesquisa (2015) ou para a Anatel (a partir de 2016).

PESO	Peso do estrato (UF x prestadora) na amostra.
H0	Município de residência do entrevistado: o entrevistador anota o município conforme informado pelo entrevistado.
I2	Autorização para identificação das respostas para a operadora citada.

Fonte: Extraído de ANATEL (2022).