

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

LUIZ GONZAGA LACERDA DE ATHAYDE NETO

**APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING PARA CLASSIFICAR A
SATISFAÇÃO DE CLIENTES DE SERVIÇOS DE TELEFONIA CELULAR**

LONDRINA

2022

LUIZ GONZAGA LACERDA DE ATHAYDE NETO

**APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING PARA CLASSIFICAR A
SATISFAÇÃO DE CLIENTES DE SERVIÇOS DE TELEFONIA CELULAR**

**Application of machine learning techniques to classify customers satisfaction
of cellular telecommunication services**

Trabalho de Conclusão de Curso apresentado no curso de Engenharia de Produção na Universidade Tecnológica Federal do Paraná (UTFPR), Campus Londrina, como requisito parcial à obtenção do título de bacharel em Engenharia de Produção.

Orientador: Prof. Dr. Rafael Henrique Palma Lima

LONDRINA

2022



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-nd/4.0/)

Esta licença permite download e compartilhamento do trabalho desde que sejam atribuídos créditos ao(s) autor(es), sem a possibilidade de alterá-lo ou utilizá-lo para fins comerciais. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

LUIZ GONZAGA LACERDA DE ATHAYDE NETO

**APLICAÇÃO DE TÉCNICAS DE MACHINE LEARNING PARA CLASSIFICAR A
SATISFAÇÃO DE CLIENTES DE SERVIÇOS DE TELEFONIA CELULAR**

Trabalho de Conclusão de Curso apresentado no curso de Engenharia de Produção na Universidade Tecnológica Federal do Paraná (UTFPR), Campus Londrina, como requisito parcial à obtenção do título de bacharel em Engenharia de Produção.

Data de aprovação: 21/novembro/2022

Rafael Henrique Palma Lima
Doutor
Universidade Tecnológica Federal do Paraná

Bruno Samways dos Santos
Doutor
Universidade Tecnológica Federal do Paraná

Pedro Rochavetz de Lara Andrade
Doutor
Universidade Tecnológica Federal do Paraná

LONDRINA

2022

AGRADECIMENTOS

Com certeza esse desafio só foi possível porque eu nunca trilhei ele sozinho, em razão disso deixo meus agradecimentos a todos que me ajudaram e me apoiaram nesse ano.

Primeiramente eu gostaria de agradecer a Deus por ter me dado todo suporte até esse momento.

Agradeço ao meu orientador Prof. Dr. Rafael Henrique Palma Lima, por ter me guiado esse ano com muita atenção, empatia e sabedoria.

Gostaria de deixar o meu reconhecimento à minha família, principalmente ao meu falecido avô que sem ele nada disso seria possível e a minha namorada que esteve ao meu lado sempre que eu precisei.

RESUMO

Medir a qualidade dos serviços de telecomunicações móveis é muito importante para operadoras de telefonia, já que existem mais celulares inteligentes do que habitantes no território brasileiro. A qualidade por vezes é medida através da satisfação que por sua vez é coletada através de questionários, com isso a utilização de técnicas de aprendizado de máquina pode ajudar a classificar a satisfação, como entender os fatores de maior impacto. Portanto, o objetivo deste trabalho é estudar e aplicar técnicas de aprendizado de máquina em uma base de dados da ANATEL (Agência Nacional de Telecomunicações), a fim de determinar quais são os fatores mais importantes no serviço de telecomunicações para a satisfação dos clientes das operadoras e qual algoritmo obtém os melhores resultados na classificação da satisfação. Foram utilizados os algoritmos *Random Forest*, *Naïve Bayes*, *Logistic Regression*, *K-Nearest Neighbors*, *Multilayer Perceptron*, *Support Vector Machine* e *Decision Tree*, sendo eles avaliados pelas métricas Acurácia, Precisão, *Recall*, *F1-score* e *AUC-score*. Os resultados da aplicação demonstraram que o *Random Forest* apresentou os melhores resultados com uma acurácia de 0,875 para o conjunto de teste após a validação cruzada. Analisando as importâncias dos atributos percebe-se que a qualidade da internet, tanto em estabilidade quanto em velocidade, tem muita importância na satisfação dos clientes.

Palavras-chave: aprendizado de máquina; qualidade em serviços; satisfação e telefonia móvel.

ABSTRACT

Measuring the quality of mobile telecommunications services is very important for telephone operators, since there are more smartphones than inhabitants in the Brazilian territory. Quality is sometimes measured through satisfaction, which in turn is collected through questionnaires, so the use of machine learning techniques can help to classify satisfaction, such as understanding the factors of greatest impact. Therefore, the objective of this work is to study and apply machine learning techniques in a database of ANATEL (National Telecommunications Agency), in order to determine which are the most important factors in the telecommunications service for the satisfaction of operators' customers and which algorithm obtains the best results in the classification of satisfaction. The Random Forest, Naïve Bayes, Logistic Regression, K-Nearest Neighbors, Multilayer Perceptron, Support Vector Machine and Decision Tree algorithms were used, and they were evaluated by the Accuracy, Precision, Recall, F1-score and AUC-score metrics. The results of the application showed that Random Forest presented the best results with an accuracy of 0.875 for the test set after cross-validation. Analyzing the importance of the attributes, it is perceived that the quality of the internet, both in stability and speed, is very important in customer satisfaction.

Keywords: machine learning; service quality; satisfaction; mobile telecommunication.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fases do KDD	17
Figura 2 – Redes neurais	22
Figura 3 – Cumprimento das metas de 2021.....	25
Figura 4 - As dimensões primárias da qualidade em serviço	26
Figura 5 – Respondentes por operadora.....	29
Figura 6 – Respondentes por estado	29
Figura 7 – Satisfação média dos serviços de pós e pré-pagos.....	31
Figura 8 – Satisfação por operadora de serviços pós-pago.....	32
Figura 9 – Satisfação por operadora de serviços pré-pago	33
Figura 10 – Fluxograma da seção de informações gerais	35
Figura 11 – Fluxograma da seção de qualidade dos canais de atendimento ao consumidor.....	36
Figura 12 – Fluxograma da seção de qualidade dos canais de atendimento ao consumidor.....	37
Figura 13 – Fluxograma da seção de qualidade do funcionamento do serviço	39
Figura 14 – Matriz de dados faltantes.....	40
Figura 15 – Matriz de dados faltantes após a retirada dos atributos.....	42
Figura 16 – Comparação dos algoritmos aplicados na base de teste do Modelo 1	45
Figura 17 – Comparação dos algoritmos aplicados na base de teste do Modelo 2	48
Figura 18 – Importância dos atributos	49
Figura 19 – Avaliação dos neutros com todos os classificadores	50
Figura 20 – Avaliação das notas 7 e 8 com todos os classificadores	51
Figura 21 – Matriz de confusão multiclasse.....	53

LISTA DE TABELAS

Tabela 1 – Parâmetros da regressão logística.....	21
Tabela 2 – Parâmetros do KNN	21
Tabela 3 – Parâmetros da árvore de decisão.....	22
Tabela 4 – Parâmetros das redes neurais	23
Tabela 5 – Indicadores de qualidade	24
Tabela 6 – Tipos de perguntas e respostas do questionário	30
Tabela 7 – Composição do questionário.....	33
Tabela 8 – Padrão de usuários.....	38
Tabela 9 – Indicadores da performance dos algoritmos	40
Tabela 10 – Atributos retirados da base de dados	41
Tabela 11 – Modelos do trabalho	42
Tabela 12 – Técnicas aplicadas ao Modelo 1 no conjunto de treino	43
Tabela 13 – Técnicas aplicadas ao Modelo 1 no conjunto de teste.....	44
Tabela 14 – Definição dos hiperparâmetros do Modelo 1.....	44
Tabela 15 – Resultados da validação cruzada no Modelo 1	45
Tabela 16 – Indicadores de performance após definição dos parâmetros no conjunto de teste.....	46
Tabela 17 – Quantidade de detratores, promotores e neutros.....	46
Tabela 18 – Técnicas aplicadas ao Modelo 2 no conjunto de treino	46
Tabela 19 – Técnicas aplicadas ao Modelo 2 no conjunto de teste.....	47
Tabela 20 – Definição dos hiperparâmetros do Modelo 2.....	47
Tabela 21 – Resultados da validação cruzada no Modelo 2	48
Tabela 22 – Importância dos atributos	49
Tabela 23 – Avaliação da Precisão no Modelo 3	52
Tabela 24 – Avaliação do <i>Recall</i> no Modelo 3.....	52
Tabela 25 – Avaliação do F1 - Score no Modelo 3.....	52

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivo geral	14
1.2	Objetivos específicos	14
1.3	Justificativa	14
1.4	Estrutura do trabalho	15
2	REFERENCIAL TEÓRICO	17
2.1	Descoberta de conhecimento em bases de dados	17
2.1.1	Seleção dos dados	17
2.1.2	Pré-processamento	18
2.1.3	Transformação dos dados	18
2.1.4	Mineração de dados	18
2.1.5	Avaliação dos resultados.....	19
2.2	<i>Machine learning</i>	19
2.3	Algoritmos de <i>machine learning</i>	20
2.3.1	Regressão logística	20
2.3.2	Vizinhos mais próximos (KNN)	21
2.3.3	Árvore de decisão.....	21
2.3.4	Redes neurais	22
2.4	Satisfação em telefonia celular	23
2.5	Aplicações de machine learning no setor de telecomunicações	26
3	MÉTODO DE PESQUISA	28
3.1	Descrição da base de dados	28
3.1.1	Composição geral dos dados	30
3.1.2	Fluxograma do questionário	33
4	RESULTADOS E DISCUSSÕES	41
4.1	Avaliação do Modelo 1	43
4.2	Avaliação do Modelo 2	46
4.2.1	Promotores e detratores	46
4.2.2	Neutros	50
4.3	Avaliação do Modelo 3	52
5	CONCLUSÃO	55
	REFERÊNCIAS	57

1 INTRODUÇÃO

Em 1983 Martin Cooper desenvolveu o primeiro celular a ser comercializado no mundo, o modelo Motorola DynaTAC 8000X, dando início ao que seria muito tempo depois conhecido como *smartphones*. Nos dias atuais, existem mais celulares do que habitantes no Brasil, o que não se reflete nas operadoras com o mercado sendo dominado por apenas quatro grandes empresas, Vivo, Claro, Tim e Oi. Existem também algumas operadoras regionais como a Sercomtel atuante na região de Londrina (PR) e a Algar no interior de MG e SP. Teixeira (2008) define que os celulares criam todo um *playground* digital para nossas vidas, onde a distância e a aparência parecem não ter mais importância.

Devido à necessidade dos clientes em estar conectado, as empresas de telecomunicações devem prestar serviços de qualidade, pois com tantas opções e a facilidade em se trocar de operadora, o consumidor tem um poder muito maior de exigência em mãos. Com isso, as empresas de telecomunicações vêm analisando como fidelizar o consumidor e para isso estão estudando cada vez mais sobre a qualidade do serviço entregue, o valor que eles agregam e a satisfação (CRONIN et al., 2000).

De acordo com Hoffman e Bateson (2003), a satisfação é entendida como uma medição, avaliando quão bom o serviço é entregue de acordo com as expectativas dos clientes. Portanto, essa avaliação pode ser vista em duas óticas: a ótica empresarial na qual é necessário definir quais são as necessidades dos clientes de uma forma clara e baseado nessas necessidades formular os requisitos de qualidade tanto em serviço como em produto e a ótica do consumidor onde se avalia o serviço ou produto por uma variedade de características, sendo ela multidimensionais (NASCIMENTO, 2018).

Para medir a satisfação de clientes na iniciativa privada é muito comum o uso de questionários, tais como o *Net Promoter Score* (NPS), *Customer Satisfaction Score* (CSAT) e o *Customer Effort Score* (CES) (SILVA et al., 2020). Alguns questionários podem ser desenvolvidos por empresas normativas como a ANATEL (Agência Nacional de Telecomunicações), que todo ano realiza uma pesquisa para que os consumidores expressem suas impressões utilizando as operadoras de serviços de telecomunicação como referência. A aplicação de aprendizado de máquina (*machine learning*) em pesquisas de satisfação pode ajudar a entender quais são os fatores

dominantes, aumentando a performance das empresas que o fazem (MARKOULIDAKIS et al., 2020). Conseqüentemente, utilizá-lo pode ajudar a prever a classificação na satisfação de clientes que utilizam serviços de telecomunicação móvel e identificar os pontos mais influentes na percepção de satisfação pelos usuários.

Algumas hipóteses foram levantadas para avaliação de acordo com os resultados da pesquisa:

- I. Os neutros são uma faixa de transição, quem deu nota 7 é mais insatisfeito e quem deu nota 8 é mais satisfeito
- II. O Modelo multiclasse terá uma eficiência menor e métricas piores para a base de dados selecionada

1.1 Objetivo geral

O objetivo deste trabalho é utilizar técnicas de aprendizado de máquina para classificar a satisfação dos clientes de serviços de telecomunicação móvel utilizando uma base de dados da ANATEL para avaliar o desempenho dos algoritmos e identificar os principais fatores que impactam a satisfação.

1.2 Objetivos específicos

- I. Implementar modelos de Aprendizado de Máquina para classificar a satisfação de clientes de operadoras de serviços de telecomunicação móvel.
- II. Comparar os resultados obtidos, definindo o modelo que oferece o melhor ajuste aos dados e que seja o mais indicado para a classificação.
- III. Compreender os principais fatores que influenciam na satisfação de consumidores no setor de serviços de telecomunicações móvel.

1.3 Justificativa

Atualmente, o tema de aprendizado de máquina vem crescendo no mundo todo, cada vez mais inseridos na vida tecnológica. Algoritmos que detectam o comportamento humano perante experiências boas ou ruins são muito importantes para a melhoria dos serviços ofertados (MARKOULIDAKIS et al., 2020). Tratando-se

de serviços de telecomunicação, Tong *et al.* (2017) dizem que quanto mais tempo um cliente utiliza os serviços ou produtos de empresas de telecomunicações mais experiências terão e com isso a “fidelidade” será maior (medida na qual é baseado o NPS).

Complementando, Balachandran *et al.* (2013), propuseram que a melhor forma de lidar com dados complexos baseados em métricas de qualidade é o aprendizado de máquina orientado com dados.

Utilizando a literatura, é possível identificar os resultados obtidos através do aprendizado de máquina aplicado a bases de dados.

O trabalho de Cox e Bell (1996), aplicou o algoritmo de *Decision Tree* para a classificação, utilizando como base de dados um questionário de satisfação de clientes para entender quais eram os atributos mais importantes ao se classificar.

Na mesma linha Li *et al.* (2018) também utilizaram o *Decision Tree* para a classificação de um questionário sobre satisfação, porém adicionando alguns algoritmos para comparação como o *k-nearest neighbours*, *Naïve bayès* e Regressão Logística.

Tomando como atributo de saída o NPS, Tong *et al.* (2017) e Markoulidakis *et al.* (2020), utilizaram algoritmos de aprendizado de máquina para classificar pesquisas de satisfação. O primeiro autor utilizou *Xboost* e *Decision Tree* enquanto o segundo Redes Neurais e *Random Forest*. Ambos defenderam que um modelo bem parametrizado e adequado para a pesquisa/questionário pode melhorar a economia de recursos consumidos por amplas pesquisas de satisfação.

Portanto o aprendizado de máquina pode ser usado para identificar, quais os fatores determinantes na satisfação de clientes, ajudando a localizar onde recursos devem ser alocados, mesmo que os dados informados sejam complexos demais para a interpretação teórica dos resultados. Visto que de acordo com Jeong *et al.* 2021, as abordagens do *machine learning* tendem a uma superioridade se comparados aos métodos teóricos de análises, principalmente quando se trata de dados com grande complexidade e parâmetros de entrada vastos.

1.4 Estrutura do trabalho

Após introduzir o assunto, contextualizando-o, apresentando os objetivos gerais e específicos e a justificativa do trabalho, o restante será dividido em mais quatro partes.

O Capítulo 2 será uma revisão da literatura nos temas de aprendizado de máquina, satisfação em serviços de telecomunicação e aplicação de técnicas de aprendizado de máquina em serviços de telecomunicação. O capítulo 3, descreve a base de dados, o pré-processamento da base, a transformação e mineração dos dados. O Capítulo 4 apresenta os resultados obtidos, avaliando os modelos que foram treinados para a classificação da satisfação dos consumidores, a análise dos resultados e a discussão. O Capítulo 5, expõe as considerações finais sobre o trabalho realizado.

2 REFERENCIAL TEÓRICO

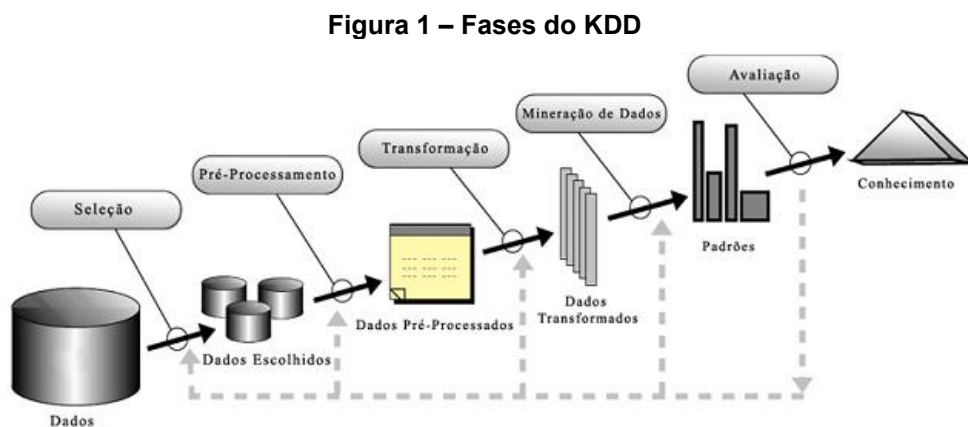
Esta seção descreve de forma sucinta os principais conceitos para o *machine learning* e a satisfação na telefonia móvel.

2.1 Descoberta de conhecimento em bases de dados

Com o crescente número de dados coletados ao passar do tempo, surgiram necessidades de se utilizar técnicas e ferramentas para a captação de informações dessas fontes. As técnicas e ferramentas, também são denominadas de descoberta de conhecimento em banco de dados (KDD) (FAYYAD *et al.*, 1996).

Essa metodologia, o KDD, contempla cinco etapas para que seja possível uma maior compreensão dos dados, são eles: a seleção dos dados, o pré-processamento, a transformação, a mineração de dados e a avaliação dos resultados.

A implementação das etapas do KDD, segundo Fayyad *et al.* (1996) são essenciais para garantir que a extração de conhecimento útil seja possível. Veja a Figura 1, que demonstra quais as fases do KDD:



Fonte: Fayyad *et al.* (1996).

2.1.1 Seleção dos dados

Rosa (2017), esclarece que a seleção de dados pode ser denominada como “redução de dados” no qual, além da grande importância na geração de informação, é onde ocorre a definição da base de dados, aqui tem-se os atributos (variáveis) e as instâncias que se busca analisar.

O processo de seleção, além de definidor, é muito teórico, se faz necessário ser designado um especialista no assunto em questão.

2.1.2 Pré-processamento

O pré-processamento inclui tarefas onde dados inconsistentes e redundantes serão retirados de sua base de dados, além de recuperar alguns dados incompletos e ser avaliada as discrepâncias (ANUMALLA, 2007). É neste momento, em que deve ser compreendido, quais as informações farão parte do KDD, em busca de otimizar os algoritmos que farão a análise dos dados (PADHY *et al.*, 2012).

2.1.3 Transformação dos dados

Esta etapa é implementada através de um processamento dos dados, no qual busca-se organizá-los para auxiliar o trabalho sucedido pelas fases posteriores do processo. Esta transformação se refere à aplicação a todos os valores de um determinado atributo. No entanto, não existe um critério único de transformação e diversas técnicas podem ser usadas de acordo com os objetivos pretendidos (ROSA, 2017).

O principal objetivo da transformação dos dados é padronizá-los, ou seja, lapidar o conjunto bruto escolhido nas fases anteriores (GOLDSCHMIDT; PASSOS, 2005).

2.1.4 Mineração de dados

A mineração de dados é um campo interdisciplinar que abrange as técnicas de reconhecimento de padrões, estatísticas, banco de dados e visualização para a extração de informações com alto volume de informações (XIAO; FAN, 2014).

Complementando, Witten *et al.*, (2011), a mineração de dados é a extração automatizada ou conveniente de padrões, que gerem conhecimento implícito contidos em bases de dados, *data warehouses* (armazéns de dados) e repositórios de informações.

Como a mineração de dados visa detectar padrões de conhecimento a partir de dados brutos, um conjunto maior pode melhor representar um problema, incluindo mais diversidade de ocorrências (MORO, 2020).

Nessa etapa, fica a critério do analista qual algoritmo se utilizar, dado que existe uma boa quantidade deles, mas deve-se levar em conta que dependendo do tipo da tarefa necessária, um algoritmo específico pode ser mais eficiente que outro.

2.1.5 Avaliação dos resultados

Existem muitas formas para a avaliação dos resultados do KDD por isso é muito importante avaliar se o modelo está de acordo com o objetivo do negócio. É necessário aplicar testes e critérios, identificando se há necessidade de refazer alguma etapa passada (ROSA, 2017). O objetivo é garantir um bom grau de compreensão do conhecimento descoberto pelo algoritmo minerador, validando-o por meio de medidas de qualidade da solução e da percepção de um analista de dados (NGAI *et al.*, 2011).

2.2 *Machine learning*

Desde 1970 existe de fato uma disseminação de técnicas de Inteligência Artificial. Muito disso é pelo fato do grande número de dados gerados por diferentes setores, surgindo uma busca por um programa computacional que solucionasse problemas a partir do mesmo, sem uso da interferência humana. (CARVALHO *et al.*, 2011).

Para tal, é necessário que o programa computacional aprenda com uma base de dados, resolvendo problemas apenas utilizando fatos que já aconteceram.

Graças à aprendizagem o ser-humano é capaz de realizar tarefas repetindo-as várias vezes para evoluir o desempenho individual. Quando empregamos a habilidade de aprender e reconhecer padrões em programas de computador, nasce o que chamamos de *machine learning* (ML) (KONAR, 1999).

O ML é um algoritmo que aprende as relações (não lineares) entre variáveis, utilizando técnicas do que chamamos de mineração de dados (SIROOSI *et al.*, 2019). Para Fayyad *et al.*, (1996), a mineração de dados foca em implementar o processo de análise de dados, modelando, avaliando, extraíndo e compreendendo-a.

A mineração de dados, contempla uma área chamada de análise de dados, incluindo todas as tarefas que buscam derivar padrões de conhecimento de grandes conjuntos de dados traduzindo-os em *insights* úteis para alavancar a tomada de decisões (TYAGI, 2003).

No entanto, deve-se notar que, em contraste com a IA tradicional, o aprendizado de máquina não tem por objetivo único automatizar uma tarefa que o ser humano faria de forma repetitiva ou demorada, mas usar os pontos fortes e habilidades especiais dos computadores para complementar a inteligência humana.

Por exemplo, a capacidade de digitalizar e processar enormes bancos de dados permitindo que programas de aprendizado de máquina detectem padrões que estão fora do escopo da percepção humana (SHALEV-SCHWARTZ; BEN-DAVID, 2014).

Do ponto de vista computacional, ML caracteriza-se como algoritmos de computador que através da experiência vão aprendendo e melhorando (ERTEL, 2017). Na mesma via, Li *et al.* (2019) sustenta que, em ML os computadores aprendem com experiências passadas usando da indução para obter conclusões através de um exemplo. Esses exemplos, podem conter atributos como: nome, idade, peso, altura. Um desses atributos será considerado o atributo de saída (classe ou rótulo), cujos valores podem ser estimados ou classificados utilizando os valores dos demais atributos, que são chamados de atributos de entrada (atributos preditores) (CARVALHO *et al.*, 2011).

2.3 Algoritmos de *machine learning*

Esta seção descreve os modelos de algoritmos de ML retratando quais foram os principais pontos e entendimentos. Busca-se definir como os algoritmos de ML atuam, quais suas vantagens e como utilizá-los de maneira coerente.

2.3.1 Regressão logística

Regressão logística (*logistic regression*), é uma técnica de mineração de dados importante para análise e classificação de bases de dados binárias e proporcionais. Suas vantagens são fornecer probabilidades e problemas de classificação em várias classes, naturalmente (HASTIE *et al.*, 2009).

A *logistic regression* é um modelo estatístico que em sua forma básica utiliza uma função logística para modelar uma variável dependente binária. Matematicamente, um modelo logístico binário possui uma variável dependente com dois valores possíveis, como passa/falha, que é representada por uma variável indicadora, onde os dois valores são rotulados como 0 e 1. A característica definidora do modelo logístico é que uma das variáveis independentes escala exponencialmente as chances do resultado dado a uma taxa constante, com cada variável independente tendo seu próprio parâmetro (MARKOULIDAKIS *et al.* 2020). A Tabela 1 mostra os principais parâmetros usados na regressão logística.

Tabela 1 – Parâmetros da regressão logística

Parâmetros	Descrição dos parâmetros
Número máximo de iterações	O parâmetro retratado, é o maior número de iterações percebidas ao aplicar o modelo.
Algoritmo para otimização	Esse parâmetro, serve para entender qual algoritmo será utilizada para melhorar o desempenho do modelo.
Peso associado às classes	No caso, está se expondo o peso dado às classes pertencentes ao modelo.

Fonte: Adaptado de Markoulidakis et al. (2020)

2.3.2 Vizinhos mais próximos (KNN)

O algoritmo dos vizinhos mais próximos (*k-nearest neighbours* - KNN) é um método não paramétrico usado para classificação e regressão. Um voto majoritário de seus vizinhos classifica um objeto, com o objeto sendo atribuído à classe mais comum entre seus *k* vizinhos mais próximos; é, portanto, um tipo de aprendizado baseado em instâncias, onde a função é apenas aproximada localmente e toda a computação é adiada até a classificação. Frequentemente uma variação do algoritmo K-NN é usada para diminuir a variação do valor *K*, tornando-o mais estável a essa variação (MARKOULIDAKIS et al. 2020), como mostrado na Tabela 2.

O KNN, por ser um modelo de alto custo na classificação de suas novas instâncias, tem uma eficiência preguiçosa quando aplicado em áreas onde a classificação dinâmica gera grandes repositórios (GUO et al., 2004).

Tabela 2 – Parâmetros do KNN

Parâmetros	Descrição dos parâmetros
Número de vizinhos	Esse parâmetro serve para ilustrar qual a quantidade de <i>K</i> ou vizinhos que se é percebido no problema.
Métrica de distância	Esse parâmetro é utilizado, para definir qual será a regra de métrica de distância utilizada para o problema de K-NN.
Peso das funções	Serve para ilustrar que as funções entendidas do caso, terão peso uniforme.

Fonte: Adaptado de Markoulidakis et al. (2020)

2.3.3 Árvore de decisão

A técnica de árvore de decisão ou *decision tree* (DT), é um modelo onde cada nó irá ser a representação da decisão que utilizará as entradas como uma folha, até que a previsão seja alcançada (MORO,2020).

O modelo de DT é uma das abordagens de modelagem preditiva usadas em estatística, mineração de dados e ML. Ele usa uma árvore de decisão para ir de observações sobre um item a conclusões sobre o valor alvo do item. Nessas estruturas de árvore, “folhas” representam rótulos de classe e os “ramos” representam conjunções de características que levam a esses rótulos de classe. As árvores de

decisão em que a variável de destino pode receber valores contínuos, geralmente números reais, são chamadas de árvores de regressão (MARKOULIDAKIS *et al.* 2020). Para melhor entendimento dos parâmetros, vide Tabela 3.

Tabela 3 – Parâmetros da árvore de decisão


Parâmetros	Descrição dos parâmetros
Impureza dos nós	Critério utilizado para verificar quais variáveis irão fazer parte do nó.
Profundidade máxima	Para aplicação de DT, é necessário entender a profundidade que será atingida.
Peso associado às classes	No caso, está se expondo o peso dado às classes pertencentes ao modelo.

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

2.3.4 Redes neurais

As redes neurais (*neural network*), são um grupo de nós comparados a imensa rede neural de um cérebro, ou seja, um modelo de várias camadas de entradas que resultam em uma saída, sendo assim, é como se cada nó fosse um neurônio. As redes neurais são divididas em 3 camadas: Camada de entrada, camada oculta e camada de saída, sendo a oculta, a camada que se encontra entre a de entrada e saída (Vide a Fig. 2) (GUPTA;MISHRA, 2017).

Figura 2 – Redes neurais



Fonte: Adaptado de Gupta e Mishra (2017)

Para entender se o modelo utilizado está coerente é necessário avaliar os parâmetros que compõe as redes neurais e otimizá-los em busca de uma performance melhor, vide Tabela 4.

Tabela 4 – Parâmetros das redes neurais

Parâmetros	Descrição dos parâmetros
Função de ativação	Qual função será escolhida para definir qual neurônio será ativado.
Neurônios na camada oculta	Número de neurônios na camada oculta.
Número de camadas ocultas	Quantas camadas ocultas terá o modelo.
Número de iterações	Quantas iterações serão feitas pelo modelo.
Taxa de aprendizagem	À qual taxa o algoritmo irá aprender.
Época	Quantas vezes serão apresentados os dados para o modelo.

Fonte: Adaptado de Markoulidakis et al. (2020)

2.4 Satisfação em telefonia celular

A telefonia celular, é um serviço, que movimentava bilhões todos os anos. As companhias que o oferecem, estão muito ligadas à satisfação muito porque se manter conectado é uma prioridade hoje em dia. Ao passar do tempo e com o avanço da tecnologia, os celulares se tornaram mais acessíveis fazendo com que as operadoras abrangessem todos os tipos de clientes com percepções de qualidade diferentes.

Apesar de certas restrições quanto ao custo, disponibilidade, padrões universais e segurança, as tecnologias de informação móveis e sem fio se propagam mundialmente e, da mesma forma, no mercado brasileiro (SACCOL; REINHARD, 2007).

Constantemente tentando acompanhar a demanda por serviços de dados, provedores de serviços móveis investem significativamente em tecnologia de comunicação (PENG *et al.*, 2014). Como tal, a indústria de telecomunicações móveis engloba características das indústrias de alta tecnologia e serviços colaborando ao desenvolvimento da informação e comunicação tecnológica que influencia profundamente todas as fases da vida moderna, o que favorece para a eficiência e eficácia com que organizações e indivíduos realizam suas atividades diárias. (BOAKYE *et al.*, 2012).

A fim de atrair novos assinantes, bem como manter os atuais clientes, as operadoras de serviços móveis precisam entender qual o peso do valor percebido de seus produtos, da satisfação e fidelização na utilização de serviços móveis (KUMAR; LIM, 2008). Cronin *et al.* (2000) diz que as percepções do consumidor sobre a qualidade do serviço, valor e satisfação têm sido extensivamente estudadas como antecedentes de intenção de fidelidade.

A literatura de marketing há muito tempo reconhece a importância da qualidade de serviço para o desenvolvimento empresarial. As diferenças entre

aspectos tangíveis (por exemplo, produto, construção) das empresas estão se tornando menos importantes enquanto o papel diferenciador se torna a qualidade do serviço (LU *et al.* 2009). A satisfação do cliente é um fator determinante para um relacionamento de longo prazo entre uma empresa e um cliente (ANDERSON; SRINIVASAN, 2003).

A Tabela 5 mostra quais são os indicadores mais utilizados para qualidade em serviços de telecomunicações:


Tabela 5 – Indicadores de qualidade

Indicadores de qualidade	Meta
Taxa de alocação de canal de tráfego	>95%
Taxa de queda de ligação	< 2%
Taxa de conexões de dados	>98%
Taxa de queda das conexões de dados	< 5%
Garantia de taxa de transmissão média contratada	>80%
Taxa de atendimento pela telefonista/ atendente em sistemas de autoatendimento	>90%
Garantia de taxa de transmissão média contratada	>80%
Taxa de atendimento pela telefonista/ atendente em sistemas de autoatendimento	>90%

Fonte: Adaptado de ANATEL (2022)

Para Rodrigues, Silva e Andrade (2011), todas empresas devem ter ciência de que os investimentos em práticas para melhor desempenho no pós-venda geram resultados na diminuição de inadimplentes, redução do custo para se vender, lucros maiores e criação de perfil de cliente.

A ANATEL (2022) monitora a quantidade e o motivo das reclamações contra cada operadora, o tempo que elas levam para responder e a qualidade das respostas para cobrar delas um nível de atendimento cada vez melhor. Entre outros pontos, a reclamação, somada às reclamações de outros consumidores ajuda a agência a calcular e divulgar o *Ranking* das Operadoras, possibilitando conhecer e comparar quais atendem melhor as demandas do consumidor. Também auxilia a identificar os principais problemas para atuar de forma preventiva ou mesmo aprimorar as regras existentes e a realizar, quando necessário, ações de fiscalização, de acompanhamento e controle, que podem resultar em multas contra as operadoras e medidas cautelares. A Figura 3 mostra os cumprimentos de metas em 2021.

Figura 3 – Cumprimento das metas de 2021

Fonte: Adaptado de ANATEL (2022)

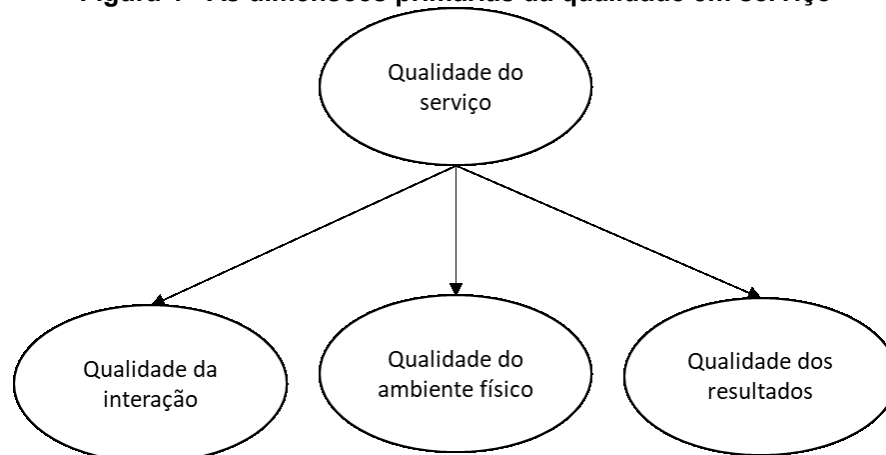
Do ponto de vista do usuário, um dispositivo móvel não é apenas uma ferramenta para comunicação, mas também é utilizado como ferramenta de comércio. Nesse contexto, o objetivo das operadoras mudou do serviço de telecomunicações tradicional para o *m-commerce* de valor agregado a serviço (LU *et al.*, 2009).

Como consequência, oferecer um serviço de alta qualidade é cada vez mais classificado como um fator crítico para o sucesso (MARTÍNEZ CARO; MARTÍNEZ GARCÍA, 2007).

Além das definições de qualidade de serviço, os pesquisadores também sugerem maneiras para medir a qualidade (LU *et al.*, 2009). A escala de medição mais utilizada é a SERVQUAL, que mede a qualidade do serviço por meio de cinco dimensões (PARASURAMAN *et al.*, 1985).

Portanto, a análise mais aprofundada entre todos os aspectos avaliados em serviço, evidenciaram três dimensões primárias (Fig. 4) que mostram a qualidade de forma a entender os panoramas da satisfação celular móvel (LU *et al.*, 2009).

Figura 4 - As dimensões primárias da qualidade em serviço



Fonte: Adaptado de Brady; Cronin (2001)

2.5 Aplicações de machine learning no setor de telecomunicações

Com a aplicação do ML nas pesquisas de NPS, pode se entender quais são os fatores determinantes na satisfação dos clientes, aumentando o desempenho de acerto na classificação analisando os promotores e detratores, comparado ao uso comum do NPS (MARKOULIDAKIS *et al.*, 2020).

O ML aplicado à satisfação de telecomunicações, causa uma reflexão aos negócios, no qual se localiza os fatores centrais para a composição de objetivos por parte das empresas, como as variáveis ainda não exploradas, que se relacionam com a satisfação, e uma gama nova de oportunidades, gerando um uso preditivo de seus impactos na satisfação e quais fatores causam muito impacto para mudanças no serviço de telecomunicações (COX; BELL, 1996).

Para Markoulidakis (2020), o método de análise com ML para aplicação do NPS, pode apoiar decisões estratégicas, visto que diversos atributos contribuem na mesma, como política tarifária, satisfação de serviços móveis e online. A pesquisa ainda assim, mostra que o NPS, por ser uma métrica única, pode ser trocado por um índice multidimensional, contribuindo para aumentar o desempenho das decisões tomadas a partir da análise da base de dados.

Djatna e Kusuma (2017) avaliaram a satisfação de serviços de telecomunicação com diversas técnicas de ML e concluíram que o método mais assertivo foi o *Naïve Bayes* multinominal, pelo fato de usarem a classificação a partir de palavras.

Na mesma linha, Burhanuddin *et al.* (2018), diz que a interpretação das palavras contidas em texto, dá mais força para combater a concorrência, no qual a

interação de dados dos usuários e a própria informação, é possível gerar gráficos de desempenho dos serviços, auxiliando na tomada de decisão, gradualmente aumentando a satisfação e melhoria contínua do sistema.

De acordo com Li et al. (2018), com os dados já apresentados das empresas de telecomunicações com o NPS, é possível criar uma clusterização, subdivida em grupos, resultando em um mapa NPS-ARPU, que busca alcançar quais os fatores chaves da melhoria da experiência, e fornecer recomendações operacionais, aumentando a satisfação dos clientes.

3 MÉTODO DE PESQUISA

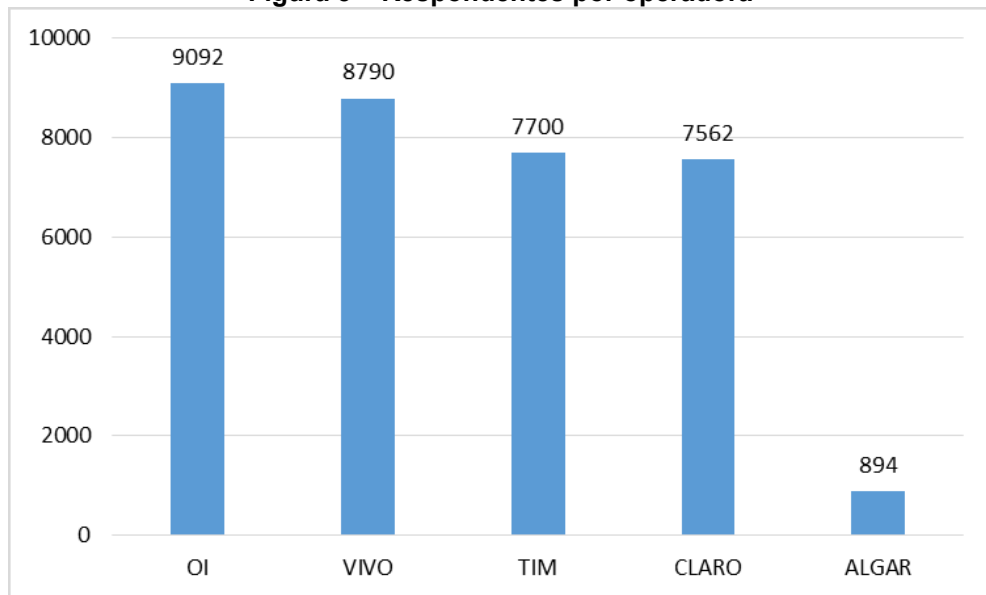
Esta seção descreve como se desenvolveu o método da pesquisa, descrevendo a base de dados, os processos de KDD e a aplicação das técnicas de ML.

3.1 Descrição da base de dados

Para esta pesquisa foi selecionada a base de dados com as respostas da pesquisa de satisfação do consumidor realizada pela ANATEL (disponível em: <https://informacoes.anatel.gov.br/paineis/consumidor/pesquisa-de-satisfacao-e-qualidade-ranking>), aplicada desde 2015 para o setor de serviços de telecomunicação móvel.


A base de dados antes dos métodos de pré-processamento é constituída de 34.038 linhas e 85 colunas para respondentes que utilizam serviços de telecomunicação celular pré ou pós-pagos, sendo cada linha um respondente da pesquisa de satisfação. Em 2015, a ANATEL disponibilizou na internet o “Manual de aplicação da pesquisa para aferição do grau de satisfação e da qualidade percebida junto aos usuários de serviços de telecomunicações”, sendo alterado pela última vez em 2021. O manual informa que a coleta se dá da seguinte forma: a empresa que faz a pesquisa recebe da ANATEL os lotes contendo telefone de contato das amostras (sorteadas aleatoriamente), contendo uma relação de até 40 vezes a amostra, sendo que caso necessário podem ser enviados lotes extras. Antes da coleta a base de dados recebida é randomizada novamente, porém agora pela empresa pesquisadora para, na sequência, iniciar as coletas.

Para se ter um panorama geral da base de dados, foram montados alguns gráficos para descrever a base. A Figura 5, mostra qual foi o número de respondentes dentre as operadoras que participaram da pesquisa.

Figura 5 – Respondentes por operadora

Fonte: Autoria própria

A Figura 6, apresenta a quantidade de respondentes por estado. De acordo, com o manual da ANATEL, todos os estados brasileiros participam da pesquisa.

Figura 6 – Respondentes por estado

Fonte: Autoria própria

De acordo com a Figura 6, os estados com mais respondentes são de Goiás, Minas Gerais e São Paulo, com 1.659, 1.650 e 1.566 participantes respectivamente e os com menor número de respondentes são Amapá, Roraima e Rio Grande do Sul com 1.104, 1.104 e 1.101 participantes respectivamente. Porém nota-se que o número de respondentes não é proporcional à população dos estados, sugerindo que há uma tentativa de usar uma quantidade igual de respondentes por estado.

3.1.1 Composição geral dos dados

As 78 colunas de perguntas são preenchidas de acordo com a Tabela 6, baseada no manual de aplicação da ANATEL. As respostas possuem 4 tipos de entrada dos dados, sendo variáveis “livres” ou de “seleção”, na quais se misturam textos e números. Os outros dois tipos são binários ou escala *Likert*. Quando binário o valor pode assumir apenas duas opções “1” ou “2”, sendo “1” igual a “sim” e “2” igual a “não” e na escala *Likert* o valor assumido vai de 0 a 10, representando o nível de satisfação do respondente à determinada pergunta.


Tabela 6 – Tipos de perguntas e respostas do questionário

Tipo	Descrição dos parâmetros
Livre	Campo de livre preenchimento com perguntas pessoais, como quantidade de pessoas na família
Seleção	Seleção com lista suspensa de opções, onde o respondente marca uma delas, podendo seguir o exemplo, Estado, sexo e faixa de idade.
Sim ou não	Perguntas objetivas sobre a execução de uma ação por parte do entrevistado, exemplo, se o consumidor solicitou atendimento pelo canal eletrônico da operadora.
Escala Likert	Nível de satisfação com algum serviço prestado, variando de 0 a 10.
Seleção	Seleção com lista suspensa de opções, onde o respondente marca uma delas, podendo seguir o exemplo, Estado, sexo e faixa de idade.

Fonte: Autoria própria

A Figura 7 mostra a evolução da satisfação média dos clientes por ano dos clientes de serviço pré e pós-pago.


Figura 7 – Satisfação média dos serviços de pós e pré-pagos



Fonte: Autoria própria

É notório que a satisfação média dos últimos anos, tanto para serviços pós como pré, vem aumentando de acordo com o índice de satisfação da ANATEL, com dois saltos perceptíveis entre 2017 e 2018, 2019 e 2020 onde a diferença chega a ser maior de que 0,2 ponto na nota. Já a figura 8 mostra a satisfação média de cada operadora por ano com serviços pós pagos.


Figura 8 – Satisfação por operadora de serviços pós-pago



Fonte: Autoria própria

Com a observação das curvas das operadoras, percebemos que a Oi, operadora que obteve mais respondentes, ficou com uma nota bem abaixo das demais com 6,87 o destaque fica com a Claro que obteve 7,75 de nota. Para uma visualização similar, a Figura 9, mostra a satisfação por ano de operadoras com serviços pré-pagos.

Figura 9 – Satisfação por operadora de serviços pré-pago



Fonte: Autoria própria

Quando se trata de serviço pré, a Oi novamente aparece com a nota mais baixa de 7,29 mesmo tendo um maior número de respondentes. A Claro que tem a maior nota em serviços pós, manteve a constância e aparece como segunda maior nota 7,66 logo atrás da Algar que teve nota de 7,79.

3.1.2 Fluxograma do questionário

O questionário da pesquisa é dividido entre dois tipos de formato nas etapas do fluxo, umas em que o respondente passa por todas as perguntas e responde-as e outras em que ele responde condicionado a perguntas anteriores, sendo assim passível de não responder todas elas. As perguntas do questionário, são nomeadas conforme um código igual as colunas da base, vide Tabela 7.

Tabela 7 – Composição do questionário

(continua)

Seção do questionário	Descrição da seção
Informações gerais	Identificação, tipo, operadora, estado, data, ano, área de trabalho, tipo do usuário, pessoa física ou jurídica, idade e sexo.
Satisfação geral do consumidor	Nível de satisfação do cliente em formato de NPS.
Qualidade da informação ao consumidor	Nível de satisfação com o funcionamento do serviço e cobrança em escala Likert.

Fonte: Autoria própria

Tabela 7 – Composição do questionário

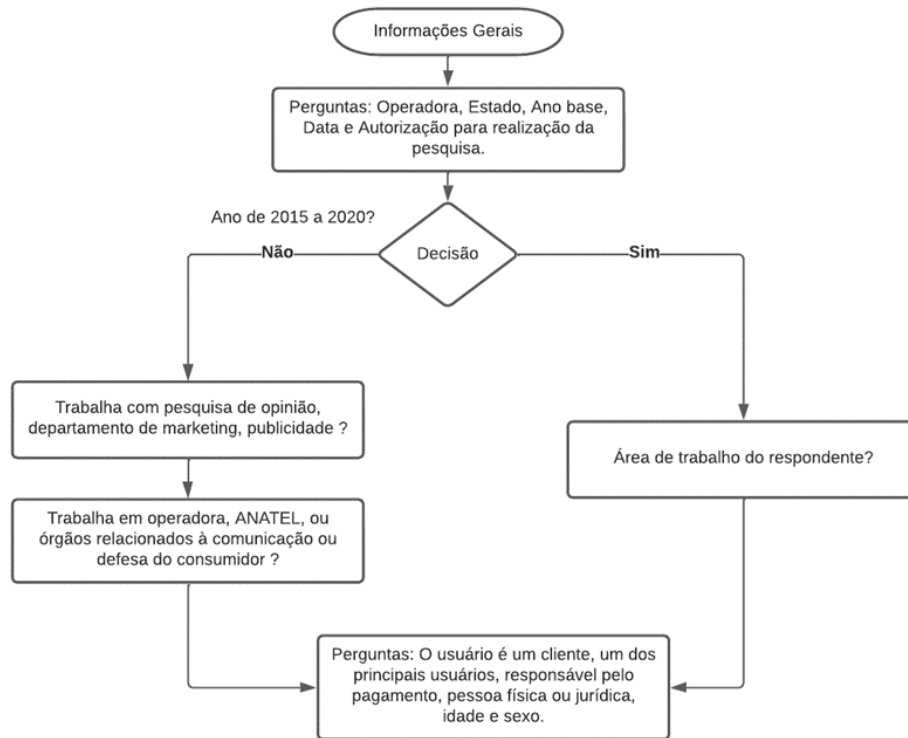
(conclusão)

Seção do questionário	Descrição da seção
Qualidade do canal de atendimento ao consumidor	Perguntas de sim ou não caso o cliente já tenha entrado em contato pelos canais de atendimento, se fez contato para solucionar problemas, se solicitou alteração no plano, se solicitou cancelamento, alguma instalação ou reparos. Para cada pergunta respondida com um sim, o respondente deverá indicar o seu nível de satisfação com o serviço. Subdividido em duas partes.
Padrão de usuário	Perguntas de sim ou não se o cliente assiste vídeos em plataformas de stream, se acessa sites em geral, redes sociais, envio de fotos e vídeos por aplicativos, faz chamadas de vídeos ou joga online.
Qualidade do funcionamento	Avalia a qualidade dos serviços de acordo com as respostas do Padrão de usuário em escala Likert, subdividido em duas partes.
Qualidade da cobrança ou recarga	Avalia a qualidade da cobrança e recarga referentes a faturas de serviços, em escala Likert.

Fonte: Autoria própria

O fluxo da primeira parte do questionário está representado na Figura 10. São constituídos de perguntas sequenciais, na qual o entrevistado deverá responder uma sequência de acordo com o fluxo descrito na Figura 10.

Figura 10 – Fluxograma da seção de informações gerais



Fonte: Autoria própria

A segunda parte do questionário é constituída de 3 perguntas sequenciais em formato de NPS, para medir a satisfação geral com serviços da operadora, são elas:

- O quão satisfeito (a) você está com o seu serviço da operadora?
- O quanto você pretende continuar sendo cliente de telefonia móvel da operadora?
- O quanto você recomendaria o serviço de telecomunicação móvel da operadora para amigos ou familiares?

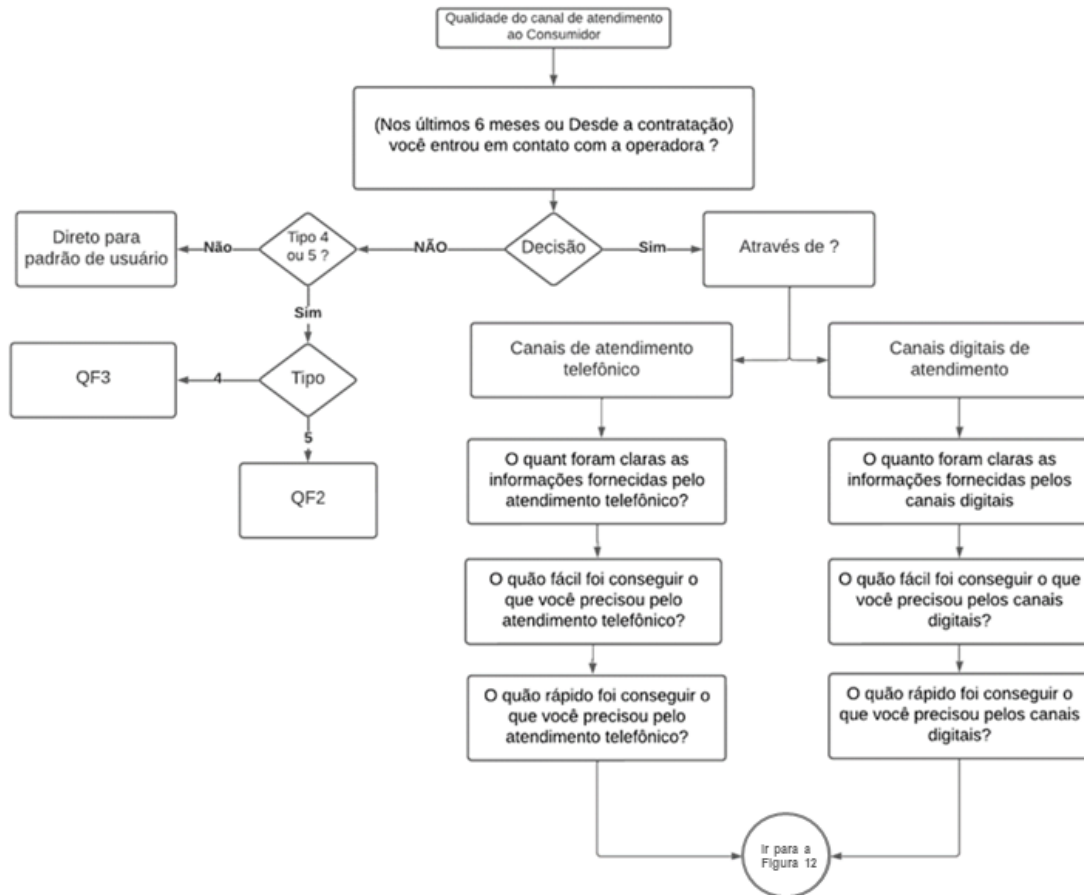
Após esse tópico breve, o respondente segue para mais um tópico em escala *Likert*, respondendo duas perguntas que podem variar seus enunciados devido ao rodízio da pesquisa, sobre os seguintes temas:

- Sobre funcionamento dos serviços ofertados pela operadora.
- Sobre as regras do contrato dos serviços ofertados pela operadora.

Seguindo o fluxo do questionário, o entrevistado chega à parte da qualidade dos canais de atendimento ao consumidor, com um fluxo dividido em duas partes sendo a primeira expressa na Figura 11 e a segunda pela Figura 12.

A Figura 11 é baseada em qual tipo de canal o usuário utilizou para fazer contato com a operadora e a segunda, Figura 12, para avaliar e dar uma nota de 0 a 10 referente ao porquê ter precisado entrar em contato

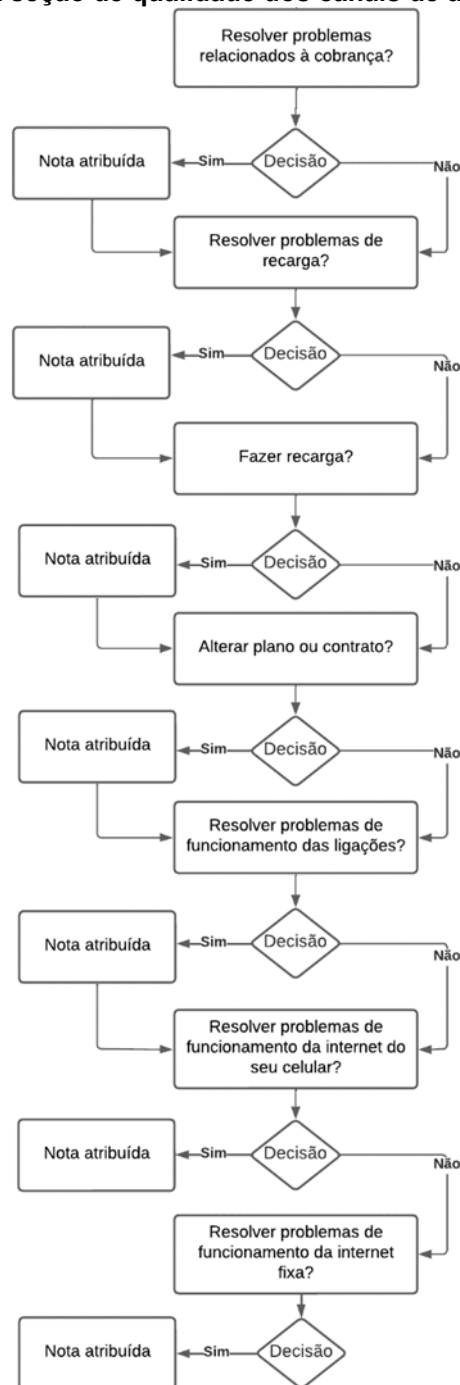
Figura 11 – Fluxograma da seção de qualidade dos canais de atendimento ao consumidor



Fonte: Autoria própria

A primeira parte é um questionário para entender se o cliente já entrou em contato com canais de atendimento da operadora, caso isso não tenha acontecido ele será redirecionado ao Padrão de usuário ou Qualidade do funcionamento, dependendo se o seu perfil é de tipo 4, 5 ou não. Caso o entrevistado tenha acessado canais de atendimento, ele deverá informar se foi por canais telefônicos ou digitais e avaliar assim, o serviço prestado.

Figura 12 – Fluxograma da seção de qualidade dos canais de atendimento ao consumidor



Fonte: Autoria própria

Para a segunda parte, o cliente deve avaliar, de acordo com o motivo do contato aos canais de atendimento, se foram atendidos de forma satisfatório, atribuindo uma nota aos mesmos.

No tópico de Padrão de usuário o respondente deverá responder a 8 perguntas como descreve a Tabela 8, para identificar quais serviços da internet são utilizados pelo entrevistado.

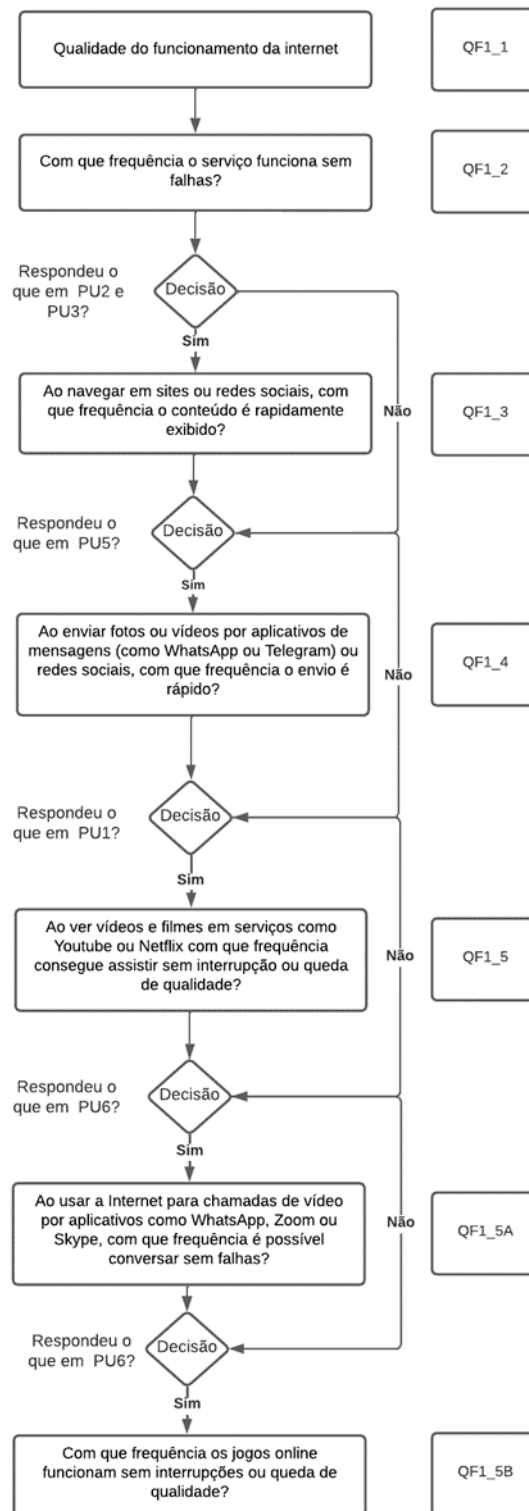
Tabela 8 – Padrão de usuários

Pergunta	Código
Você assiste vídeos e filmes por aplicativos como Youtube ou Netflix?	PU1
Você navega na internet em sites em geral?	PU2
Você acessa redes sociais como Facebook, Instagram ou Twitter?	PU3
Você troca mensagens de texto por meio de aplicativos como WhatsApp ou Telegram?	PU4
Você envia fotos e vídeos por aplicativos de mensagens ou redes sociais?	PU5
Você faz chamadas de vídeo usando aplicativos (como Whatsapp, Skype, Zoom e outros)?	PU6
Você faz chamadas de vídeo usando aplicativos como Zoom ou Skype?	PU6_A
Você joga online?	PU7

Fonte: Autoria própria

De acordo com o que foi respondido no padrão de usuário, o entrevistado atribuirá notas para a qualidade do funcionamento desses serviços que ele utiliza, de acordo com a Figura 13.

Figura 13 – Fluxograma da seção de qualidade do funcionamento do serviço



Fonte: Autoria própria

A segunda parte do tópico de qualidade do funcionamento é constituída por três questões sequenciais:

- É possível conversar sem falhas no som?
- É possível fazer e receber ligações?


- É possível permanecer na chamada, sem queda da ligação?

A partir das perguntas desse tópico serem finalizadas, será respondido o tópico de Qualidade na cobrança ou recarga, com perguntas sequenciais:

- Você é um dos responsáveis pelo pagamento da conta, da operadora?
- Os valores são cobrados corretamente na conta?
- Seu consumo de créditos é fácil de entender?

Assim que responder as questões acima, o questionário é finalizado e as respostas armazenadas.

Por se tratar de um questionário com questões opcionais a Figura 14 irá representar uma matriz dos dados faltantes. Mostrando as condições de cada pergunta, por exemplo, se for necessário ter utilizado um serviço para o avaliar, os consumidores que responderam “sim” irão avaliar e os que responderam “não” pularão essa pergunta e serão direcionadas a outra.



Fonte: Autoria própria

Para a avaliação dos algoritmos de ML são utilizados alguns indicadores a fim de definir quais são melhores em cada tipo de utilização que irá ser feita a partir dos classificadores utilizados. Na Tabela 9 está descrito quais indicadores serão utilizados.

Tabela 9 – Indicadores da performance dos algoritmos

Indicadores	Definição
<i>Recall</i>	Quantas situações de classe positiva estão corretas, dentre todas instâncias
Acurácia	Quantas classificações foram corretas, dentre todas as instâncias
Precisão	Quantas situações estão corretas, dentre todas as instâncias positivas
F1 - Score	Média harmônica entre precisão e recall
<i>AUC - Score</i>	Representa a área do <i>ROC</i> , avaliando quantas classificações foram corretas contra quantas classificações foram incorretas

Fonte: Autoria própria

4 RESULTADOS E DISCUSSÕES

Esta seção apresenta e discute os resultados obtidos a partir da implementação das técnicas de ML, bem como explica esse processo, na base de dados da ANATEL.

Inicialmente a base de dados foi analisada para buscar variáveis que poderiam ser removidas por não estarem relacionadas com a satisfação do cliente, tais como perguntas nas quais eram dependentes de respostas anteriores, gerando um número muito baixo de respostas, colunas que representavam a satisfação do serviço geral (SG1 e SG2) no qual criou-se um viés muito alto aos modelos ou perguntas que fugiam do âmbito da satisfação. A Tabela 10 descreve as questões removidas da base.

Tabela 10 – Atributos retirados da base de dados


Indicadores	Definição	Motivo da retirada
SG (1,2,3*)	Satisfação Geral	Alto viés nos modelos de ML, utilizada como variável de saída
QA	Qualidade no atendimento	Menos de 15.000 respondentes
QCR (1, 1.1, 1.2, 2, 2.1, 2.2)	Qualidade na cobrança ou recarga	Menos de 13.000 respondentes
QF (1.1, 1.4, 1.6, 2.2, 2.3, 3.1, 3.2)	Qualidade do funcionamento	Menos de 14.000 respondentes
QIC (2, 3.A, 3.B)	Qualidade da informação ao consumidor	Menos de 12.000 respondentes
P2	Idade	Foi mantida a coluna de faixa etária (P2a)
P3	Renda	Foi mantida a coluna de faixa de renda (ID3a)
P5	Serviço em nome de pessoa física ou jurídica	Sem relação com a variável de saída.
P7	Serviço de internet por fibra ótica	Sem relação com a variável de saída
PU (4,5,6,7)	Padrões de uso do serviço	Menos de 13.000 respondentes e sem relação com a variável de saída
E	Outras experiências do consumidor	Menos de 12.000 respondentes
A1 e Peso	Autorização para operadora utilizar os dados e o peso dado aos respondentes	Sem relação com a variável de saída

Fonte: Autoria própria

Conforme estudou-se a base de dados, algumas perguntas do questionário entraram em uma espécie de análise para verificar se faria sentido mantê-las no estudo ou não, verificando sua relação com o atributo de saída e se o seu número de respondentes era menor que 15.000, criando assim o critério para a exclusão de alguns atributos de entrada. Após isso, a matriz de valores faltantes foi avaliada, percebendo-se que muitas colunas não teriam relevância para a implantação dos modelos de ML, pois haveriam poucos dados para se analisar deteriorando assim os

algoritmos. Foram retiradas as colunas da Tabela 10 e excluídas qualquer linha que tivesse ao menos um dado faltante, o resultado é uma base de dados em que todas as linhas e colunas tem os dados completos, como pode ser visto na Figura 15.

Figura 15 – Matriz de dados faltantes após a retirada dos atributos



Fonte: Autoria própria

Com isso obteve-se os atributos necessários para a implementação dos modelos de ML na base de dados. Outras duas mudanças foram feitas, transferindo o atributo “ESTADO” para compreender regiões do Brasil (Norte, Nordeste, Centro-oeste, Sul e Sudeste) e binarizando as colunas “ESTADO” e “MARCA”.

Após as mudanças obteve-se 28 atributos e 9.220 instâncias para avaliação da classificação dos modelos de ML.

A variável de saída considerada no modelo foi a “SG3”, que tem como base a pergunta clássica do NPS e por isso ela foi escolhida como definidora da nota de satisfação geral para os modelos de classificação.

Neste trabalho, foram definidos três modelos de avaliação para verificar os resultados obtidos, conforme mostra a Tabela 11.

Tabela 11 – Modelos do trabalho

Modelo	Separação das instâncias	Avaliação da nota do NPS
1	Satisfeitos e insatisfeitos	Promotores acima de 7, detratores menores ou iguais a 7
2	Promotores e detratores, com avaliação posterior dos neutros	Promotores 10 e 9, neutros 8 e 7 e detratores menores ou iguais a 6
3	Promotores, neutros e detratores	Promotores 10 e 9, neutros 8 e 7 e detratores menores ou iguais a 6

Fonte: Autoria própria

O primeiro modelo classifica os respondentes em satisfeitos ou insatisfeitos com a inserção dos neutros nos conjuntos. No segundo modelo, foram avaliadas as

classificações de acordo com a métrica do NPS sendo promotores (notas 10 e 9), detratores (notas menores ou iguais a 6) e neutros (notas 7 e 8) com uma primeira avaliação somente com promotores e detratores e após, uma segunda avaliação apenas com os neutros para verificar onde eles estariam classificados. O terceiro modelo utilizou três classes possíveis de saída também chamado de multiclasse, conforme a classificação do NPS.

4.1 Avaliação do Modelo 1

Inicialmente foi utilizada a coluna “SG3” como variável de saída, sendo a mesma estratificada em dois conjuntos (i) promotores e (ii) detratores, conforme visto na Tabela 11. O conjunto foi separada em outros dois, teste (25% da base) e treino (75% da base). A implantação dos modelos no conjunto de treino gerou os seguintes resultados, avaliando a Precisão e o desvio padrão médio. A precisão identifica a taxa de acertos do modelo, sendo uma relação entre quantas classificações foram corretas pelo número de instâncias que o modelo classificou como tendo a característica avaliada da base de dados. O desvio padrão médio foi utilizado pelo fato de ser implementado uma técnica chamada de validação cruzada no treino dos algoritmos, que consiste em pegar o conjunto de dados e dividi-lo em k novos conjuntos do mesmo tamanho para que seja possível a avaliação dos parâmetros em todo o conjunto de acordo com suas variações, como a precisão é uma média desses resultados o desvio padrão médio identifica a diferença dos resultados com a média da precisão.

Para o treinamento, os algoritmos de ML utilizados foram *Logistic Regression* (LR), KNN, *Decision Tree* (DT), *Naïve Bayes* (NB), *Support Vector Machine* (SVM), *Random Forest* (RF) e Redes neurais (MLP) com um *k-fold* igual a 10, os resultados para o treinamento foram dispostos conforme a tabela 12.

Tabela 12 – Técnicas aplicadas ao Modelo 1 no conjunto de treino

Indicadores	LR	KNN	DT	NB	SVM	RF	MLP
Precisão (satisfeitos)	0,7772	0,7662	0,7674	0,7668	0,7844	0,8269	0,7738
Desvio Padrão Médio	0,0277	0,0155	0,0782	0,0276	0,0254	0,0580	0,0318

Fonte: Autoria própria

Com o treino realizado na base de dados, implementou-se os mesmos modelos de ML para o conjunto de teste, obtendo os seguintes resultados com as métricas de Precisão, *Recall*, *F1-Score* e Acurácia, vide Tabela 13.

Tabela 13 – Técnicas aplicadas ao Modelo 1 no conjunto de teste

Métricas	Precisão		Recall		F1-Score		Acurácia
	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	
LR	0,75	0,77	0,66	0,84	0,70	0,81	0,76
KNN	0,72	0,78	0,68	0,81	0,70	0,79	0,75
DT	0,64	0,75	0,67	0,73	0,65	0,74	0,71
NB	0,74	0,77	0,58	0,87	0,65	0,82	0,76
SVM	0,77	0,78	0,65	0,86	0,71	0,81	0,77
RF	0,74	0,79	0,70	0,83	0,72	0,81	0,77
MLP	0,73	0,79	0,70	0,81	0,71	0,80	0,77

Fonte: Autoria própria

Para melhorar o desempenho das técnicas, foram avaliados os hiperparâmetros dos métodos utilizando o GridSearchCV, com CV igual a 5, sendo testados os parâmetros listados na Tabela 14.

Tabela 14 – Definição dos hiperparâmetros do Modelo 1

Modelos	Parâmetros Testados	AUC	Precisão
LR	penalty: l2; none , tol: 1e-6 ; 1e-2, fit_intercept: True ; False, max_iter: 10000 .	0.855	0.772
KNN	n_neighbors: 1; 2; 4; 6; 7; 10 , weights: uniform; distance .	0.836	0.788
DT	splitter: best ; random, criterion : gini; entropy , max_depth: 6 ; 12; 16; 24, min_samples_leaf: 2; 4 , min_samples_split: 2; 4 .	0.843	0.789
SVM	C: 0.1; 1; 10; 100; 1000 , gamma: 1 ; 0.1; 0.01; 0.001, kernel: rbf ; poly; sigmoid, probability: True .	0.847	0.778
RF	n_estimators: 200 , 400, max_depth: 6; 12 ; 24, min_samples_split: 2 ; 4, min_samples_leaf: 2; 4 , criterion : gini; entropy .	0.859	0.790
MLP	hidden_layer_sizes: (10,30,10);(20 ,), activation: tanh; relu , solver: sgd; adam , alpha: 0.0001; 0.05 , learning_rate: constant; adaptive	0.853	0.823


Fonte: Autoria própria

Os resultados mostram que os algoritmos tiveram uma melhora tanto em *Recall* quanto a Precisão indicando que os parâmetros escolhidos foram suficientes para suprir os modelos aumentando a chance de a classificação ser correta baseada nos conjuntos de satisfeitos e insatisfeitos.

Os métodos de *Logistic Regression* e *Support Vector Machine* foram melhores em Precisão, quando trata-se do AUC junta-se a esses dois algoritmos o *Random Forest* e quando se trata de classificação a métrica AUC é muito importante pois

identifica a qualidade das previsões do modelo, independentemente do limiar de classificação. Para uma melhor visualização foi utilizado um gráfico comparando os resultados, vide Figura 16.

Figura 16 – Comparação dos algoritmos aplicados na base de teste do Modelo 1



Fonte: Autoria própria

Sabe-se que a cada vez executado um algoritmo, os resultados são dispostos de maneiras diferentes, pois o conjunto de teste varia a cada análise, para chegar no melhor desempenho do classificador foi utilizado uma validação cruzada com o *k-fold* de parâmetro *k* igual a 5. Utilizando-se do *k-fold* 5 testes foram feitos por cada tipo de técnica, chegando ao final com um número médio de Acurácia, conforme visto na tabela 15.

Tabela 15 – Resultados da validação cruzada no Modelo 1

Indicadores	LR	KNN	DT	SVM	RF	MLP
Acurácia	0.7644	0.7674	0.7626	0.7718	0.7722	0.7718

Fonte: Autoria própria

Pode-se notar que a incorporação dos respondentes neutros dificulta a classificação em promotores ou detratores e as dificuldades do algoritmo em classificar as instâncias de acordo com seus atributos de entrada aumentam, isso se dá pelo fato de que o NPS julga notas 7 e 8 como neutros exatamente porque esse conjunto tem uma similaridade, eles não são nem satisfeitos e nem insatisfeitos e a classificação se torna deficitária logicamente. Para se ter uma melhor visualização foi feito uma tabela, ver Tabela 16, para explicitar o resultado desse modelo.

Tabela 16 – Indicadores de performance após definição dos parâmetros no conjunto de teste

Métricas	Precisão		Recall		F1-Score		Acurácia
	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	
LR	0,75	0,77	0,65	0,84	0,70	0,81	0,76
KNN	0,74	0,79	0,69	0,82	0,71	0,80	0,77
DT	0,72	0,79	0,70	0,81	0,71	0,80	0,76
NB	0,74	0,77	0,58	0,87	0,65	0,82	0,76
SVM	0,76	0,78	0,66	0,85	0,71	0,81	0,77
RF	0,75	0,79	0,69	0,83	0,72	0,81	0,77
MLP	0,78	0,76	0,63	0,87	0,69	0,81	0,77

Fonte: Autoria própria

Com os hiperparâmetros, os algoritmos de KNN e *Decision Tree* obtiveram melhoras em todos os indicadores e o MLP apresentou melhora significativa no *Recall* para satisfeitos passando de 0,81 para 0,87, porém os outros algoritmos não apresentaram melhorias significativas mesmo com os parâmetros ajustados.

4.2 Avaliação do Modelo 2

Inicialmente foi utilizada a coluna “SG3” para separar os conjuntos (i) promotores, (ii) neutros e (iii) detratores. A regra utilizada foi que notas 10 e 9 entrariam como promotores, neutros teriam notas 8 e 7 e detratores notas menores ou iguais a 6. O agrupamento pode ser entendido melhor pela Tabela 17.

Tabela 17 – Quantidade de detratores, promotores e neutros

Classificação de acordo com NPS	Quantidade
Promotores	3564
Neutros	2887
Detratores	2769

Fonte: Autoria própria

Esse modelo, têm duas avaliações, uma de promotores e detratores para entender os atributos responsáveis na satisfação dos clientes e uma avaliação dos neutros verificando se são satisfeitos ou insatisfeitos.

4.2.1 Promotores e detratores

Após análise das classes, foi composto um conjunto de dados separando apenas promotores e detratores. Com os conjuntos definidos em (25%) teste e (75%) treino, os resultados dos modelos foram de acordo com a Tabela 18 e 19.

Tabela 18 – Técnicas aplicadas ao Modelo 2 no conjunto de treino

Indicadores	LR	KNN	DT	NB	SVM	RF	MLP
Precisão (promotores)	0,8732	0,8696	0,8003	0,8534	0,8793	0,8757	0,8622
Desvio Padrão Médio	0,0101	0,0165	0,0191	0,0110	0,0113	0,0108	0,0141

Fonte: Autoria própria

Com o treino realizado na base de dados, implementou-se os mesmos modelos de ML para o conjunto de teste, obtendo os seguintes resultados com as métricas de Precisão, *Recall*, *F1-Score* e Acurácia vide tabela 19.

Tabela 19 – Técnicas aplicadas ao Modelo 2 no conjunto de teste

Métricas	Precisão		Recall		F1-Score		Acurácia
	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	Insatisfeito	Satisfeito	
LR	0,88	0,90	0,86	0,91	0,87	0,90	0,89
KNN	0,85	0,89	0,85	0,89	0,85	0,89	0,88
DT	0,78	0,84	0,78	0,84	0,78	0,84	0,81
NB	0,86	0,88	0,83	0,90	0,84	0,89	0,87
SVM	0,87	0,90	0,87	0,90	0,87	0,90	0,89
RF	0,86	0,90	0,87	0,90	0,86	0,90	0,88
MLP	0,88	0,87	0,81	0,92	0,85	0,89	0,87

Fonte: Autoria própria

Para melhorar o desempenho das técnicas, foram avaliados os hiperparâmetros dos métodos utilizando o GridSearchCV, com CV igual a 5, sendo eles representados na Tabela 20.

Tabela 20 – Definição dos hiperparâmetros do Modelo 2

Modelos	Parâmetros Testados	AUC	Precisão
LR	penalty: l2; none , tol: 1e-6 ; 1e-2, fit_intercept: True ; False, max_iter: 10000 .	0,887	0,880
KNN	n_neighbors: 1; 2; 4; 6; 7; 10 , weights: uniform; distance .	0,970	0,975
DT	splitter: best; random , criterion : gini; entropy , max_depth: 6 ; 12; 16; 24, min_samples_leaf: 2; 4 , min_samples_split: 2; 4 .	0,874	0,878
SVM	C: 0.1; 1 ; 10; 100; 1000, gamma: 1 ; 0.1; 0.01; 0.001, kernel: rbf ; poly; sigmoid, probability: True .	0,877	0,896
RF	n_estimators: 200, 400 , max_depth: 6; 12 ; 24, min_samples_split: 2; 4 , min_samples_leaf: 2; 4 , criterion : gini; entropy .	0,910	0,931
MLP	hidden_layer_sizes: (10,30,10);(20), activation: tanh ; relu, solver: sgd; adam , alpha: 0.0001; 0.05 , learning_rate: constant; adaptive	0,892	0,887


Fonte: Autoria própria

Os resultados mostram que os algoritmos tiveram uma melhora tanto em *Recall* quanto a Precisão indicando que os parâmetros escolhidos foram suficientes

para suprir os modelos aumentando a chance de a classificação ser correta baseada nos conjuntos de detratores e promotores.

O algoritmo de *Random Forest* e KNN se mostraram melhores em Precisão, o *Random Forest* faz parte dos algoritmos de árvores e *ensemble* que em sua maioria mostra melhores resultados para classificação. Quando se trata do *Recall* os melhores algoritmos são o *Random Forest*, KNN e o MLP. O *Recall* é muito importante quando se trata de classificação, pois é utilizado para indicar a relação entre as previsões positivas realizadas corretamente e todas as previsões que realmente são positivas. Para uma melhor visualização foi plotado um gráfico comparando os resultados, ver Figura 17.

Figura 17 – Comparação dos algoritmos aplicados na base de teste do Modelo 2



Fonte: Autoria própria

Utilizando o *k-fold* igual a 5, obtém-se um número médio de Acurácia dos algoritmos de ML, visto na Tabela 21.

Tabela 21 – Resultados da validação cruzada no Modelo 2

Indicadores	LR	KNN	DT	SVM	RF	MLP
Acurácia	0.864	0.869	0.850	0.872	0.871	0.855

Fonte: Autoria própria


Após a validação cruzada os números médios de Acurácia foram diferentes, isso se dá pelo fato de que o algoritmo utilizado pode criar um viés no conjunto de teste selecionado e quando recebe outros conjuntos para classificar acaba por diminuir a taxa de acerto. Com a validação cruzada os conjuntos de teste e treino são

compostos por dados diferentes que variam de acordo com o parâmetro inserido no método de validação, nesse caso o *k-fold* com parâmetro *k* igual a 5 o que obriga os algoritmos a classificarem 5 conjuntos de teste diferentes gerando valores distintos e calculando uma média conforme a Tabela 19.

Com a base de dados separada em dois conjuntos de detratores e promotores e retirando os neutros é perceptível que o modelo responde muito melhor, com valores de métricas melhores e um nível de Precisão e Acurácia maiores.

O *Random Forest* é um modelo que tem em média bons resultados quando aplicados à base de dados, e oferece um método em que se pode entender quais foram os atributos mais importantes para a classificação em satisfeito e insatisfeito. A Figura 18 mostra quais foram esses atributos.

Figura 18 – Importância dos atributos



Fonte: Autoria própria

Na Tabela 22 é descrito o que cada atributo traz em seu conteúdo para verificar quais são os principais pontos na classificação da satisfação do modelo de ML.

Tabela 22 – Importância dos atributos

Dimensões	Conteúdo	Valor
1	Qualidade no atendimento e transparência	0,41
2	Qualidade dos serviços contratados	0,38
3	Dados Demográficos	0,17
4	Padrão de uso	0,04

Fonte: Autoria própria

Com a análise dos atributos mais importantes é perceptível que a qualidade da informação passada ao colaborador, velocidade na internet e sua área de cobertura


são os aspectos mais importantes para definir se um cliente está ou não satisfeito, o que implica em ajustar os processos de contratação por parte das operadoras com o seu cliente.

4.2.2 Neutros

Para a avaliação dos neutros, a mesma base de dados foi disposta em apenas um conjunto, para isso utilizou-se da coluna “SG3” e agrupou apenas os respondentes que deram nota 8 e 7 para essa questão. Com isso, foram avaliadas 5.264 instâncias.

Utilizando os classificadores, treinados e parametrizados, esses respondentes considerados “neutros” *a priori* foram classificados em satisfeitos (classificação igual a 1) ou insatisfeitos (classificação igual a 0). A Figura 19 mostra a classificação obtida.

Figura 19 – Avaliação dos neutros com todos os classificadores

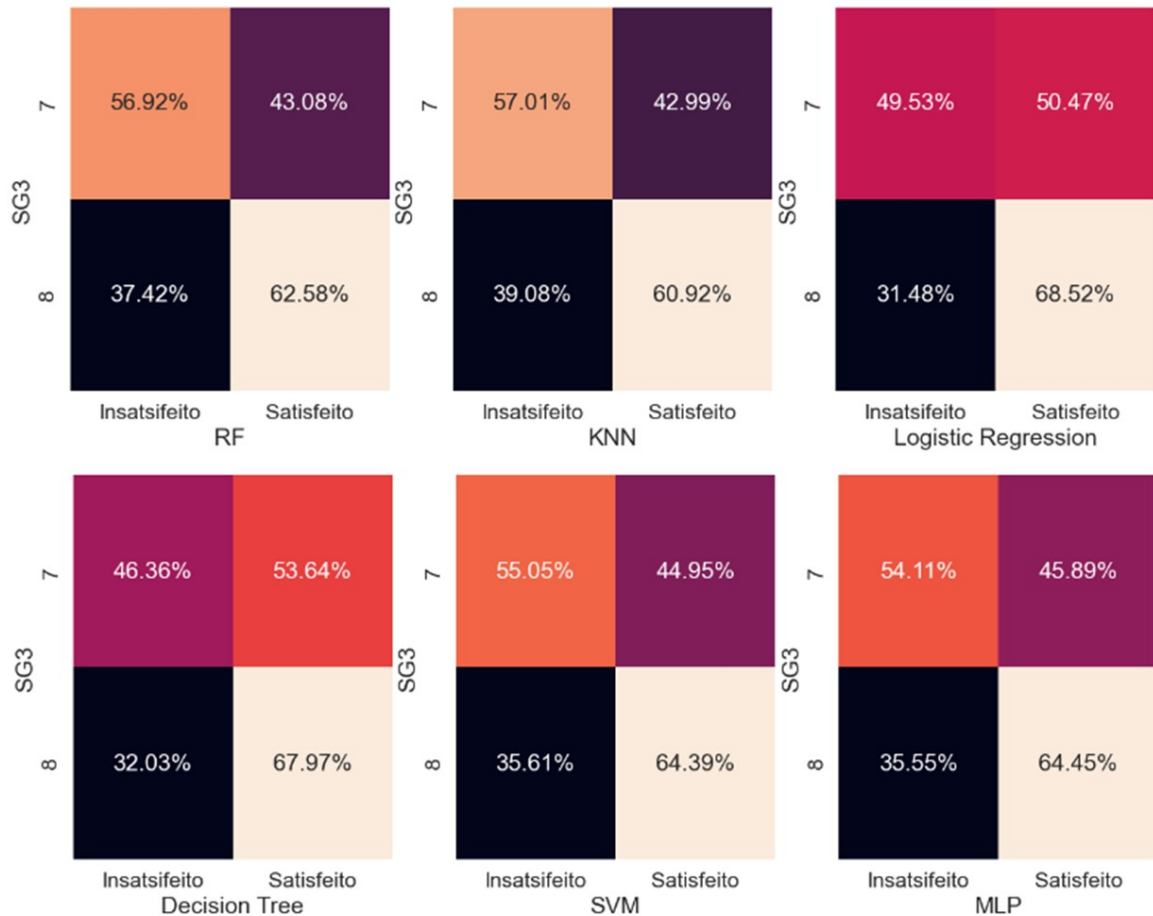


Fonte: Autoria própria

Após a avaliação percebeu-se que no conjunto de neutros houve mais insatisfeitos do que satisfeitos, porém esse conjunto é estratificado em duas notas e

levantou-se a discussão de que as percepções por cada uma poderiam ser diferentes. Para ilustrar esse pensamento foram utilizados alguns gráficos, vide Figura 20.

Figura 20 – Avaliação das notas 7 e 8 com todos os classificadores



Fonte: Autoria própria

Em média os clientes que atribuíram uma nota 8 para a questão “SG3”, tendem a ser mais satisfeitos do que insatisfeitos, todavia os que atribuíram nota 7 são bem divididos entre satisfeitos e insatisfeitos. É possível concluir que a nota 8 é uma faixa com proporção maior de satisfeitos não sendo tão “neutros”, já na nota 7 observa-se uma faixa cinzenta não podendo afirmar se tendem mais a satisfeitos ou insatisfeitos.

As importâncias dos atributos de entrada para o classificador no Modelo 2 sugerem a qualidade da informação passada aos seus clientes, a velocidade e estabilidade da internet são fatores preferenciais para que operadoras os satisfaçam com seus serviços, além de estabilidade em chamadas de voz com cobertura de sinal boa.

Comparando os Modelos 1 e 2 é possível perceber que os classificadores atuam de forma mais assertiva no Modelo 2. Isso era esperado já que a não

incorporação dos neutros na classificação deixa os promotores e detratores menos poluídos e com uma lógica melhor ao algoritmo para que encontre um padrão nas respostas dos clientes.

4.3 Avaliação do Modelo 3

Para o Modelo 3, foram classificadas todas as instâncias da coluna em formato NPS (promotor, detratador e neutro), vide Tabela 14.

Os modelos multiclasse de forma geral têm menor eficiência do que modelos nos quais a classificação é entre duas classes de saída apenas.

Os modelos foram avaliados a partir das métricas Acurácia, Precisão, *Recall* e F1-Score, conforme visto nas Tabelas 23, 24 e 25.

Tabela 23 – Avaliação da Precisão no Modelo 3

Métricas	Precisão			Acurácia
	Promotor	Neutro	Detratador	
LR	0,685742	0,515807	0,70208	0,646204
KNN	0,744114	0,497241	0,635188	0,629935
DT	0,639528	0,421905	0,598397	0,554447
SVM	0,749296	0,546632	0,739737	0,678742
RF	0,735196	0,547033	0,704451	0,669197
MLP	0,7	0,5	0,759152	0,639913

Fonte: Autoria própria

Tabela 24 – Avaliação do Recall no Modelo 3

Métricas	Precisão			Acurácia
	Promotor	Neutro	Detratador	
LR	0,793936	0,429066	0,682803	0,646204
KNN	0,67434	0,498962	0,709538	0,629935
DT	0,608647	0,450519	0,593208	0,554447
SVM	0,746771	0,584083	0,690029	0,678742
RF	0,738911	0,523183	0,731936	0,669197
MLP	0,738911	0,585467	0,569364	0,639913

Fonte: Autoria própria

Tabela 25 – Avaliação do F1 - Score no Modelo 3

Métricas	Precisão			Acurácia
	Promotor	Neutro	Detratador	
LR	0,735883	0,468455	0,692308	0,646204
KNN	0,707511	0,4981	0,670307	0,629935
DT	0,623705	0,435743	0,595791	0,554447
SVM	0,748031	0,564737	0,714019	0,678742
RF	0,737048	0,534843	0,717931	0,669197
MLP	0,718929	0,539369	0,650702	0,639913

Fonte: Autoria própria

Conforme previsto, os modelos se saíram pior quando implementados em multiclasse, piorando todas as métricas e a Acurácia. Isso se deu pelo fato de que as

regiões das fronteiras de decisões são mais complexas para o algoritmo determinar a classe.

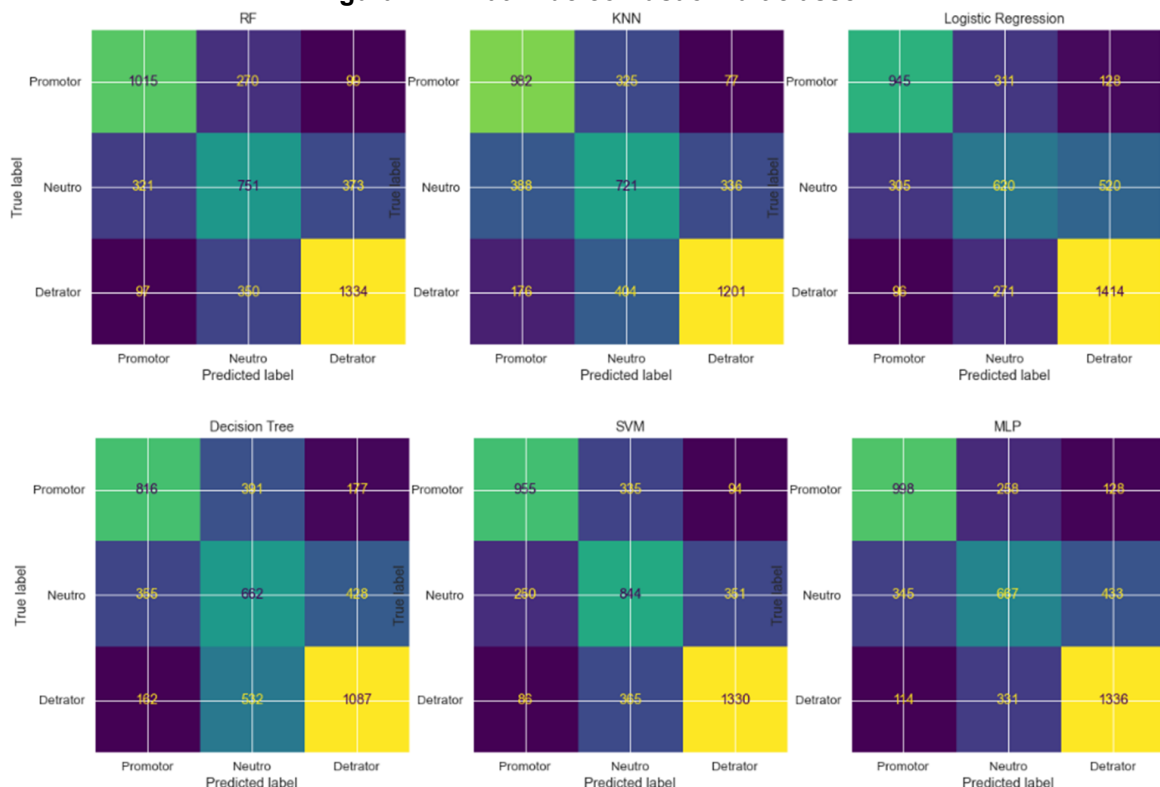
De acordo com Hameed *et al.* (2019) utilizar o método multiclasse tem performances melhores quando aplicado em vários passos e quando utilizado técnicas híbridas ao invés de técnicas únicas.

Complementando Ozkan e Koklu (2020) dizem que as técnicas multiclasse são mais eficazes quando se tratam de imagens e texto, sendo menos assertivas em outros tipos de *dataset*.

Ao avaliar a literatura, pode-se entender que para o tipo de dado existente na base da pesquisa, os modelos multiclasse não trariam uma performance interessante, o que foi comprovado pelas métricas após os resultados.

Buscando-se entender como os algoritmos classificaram cada classe do Modelo foi utilizado a matriz de confusão de cada um, vide Figura 21.

Figura 21 – Matriz de confusão multiclasse



Fonte: Autoria própria

Ao avaliar a Figura 21, percebe-se que os detratores e promotores não confundem os algoritmos, visto que a taxa de falsos positivos e falsos negativos são baixas se correlacionarem entre si, porém os neutros criam uma dificuldade no

algoritmo, afetam diretamente todas as classes dificultando as classificações tanto em promotores e detratores quanto a neutros também.

Analisando os resultados, e as taxas de positivos e negativos, o Modelo 3 mostra que a faixa dos neutros é nebulosa e que ela é responsável pela baixa acurácia do modelo individualmente, dificultando a classificação e a lógica da busca por padrões dos algoritmos.

5 CONCLUSÃO

Neste trabalho foram implementados modelos de ML para solucionar problemas de classificação em um questionário de satisfação aplicado pela ANATEL utilizando 3 modelos referentes aos atributos de saída da coluna SG3, que mede a satisfação geral dos clientes das operadoras.

A classificação dos respondentes desse questionário usando técnicas de ML teve também como finalidade determinar quais são os atributos mais importantes na satisfação em serviços de telecomunicação móvel e após, analisar se os neutros são mais insatisfeitos e satisfeitos.

Os experimentos mostraram que os algoritmos RF, SVM, MLP e LR tiveram resultados bons sendo implementados nessa base de dados e que poderiam classificar respondentes com uma acurácia de 86% em média.

Com relação aos clientes neutros, foi perceptível que há mais insatisfeitos do que satisfeitos, porém com uma distância pequena entre as classes. Isso indica que a classe neutra do NPS realmente é uma faixa de transição entre satisfeitos e insatisfeitos, porém os resultados obtidos mostraram que a proporção de clientes insatisfeitos foi superior por uma margem de 10 a 15 pontos percentuais dependendo do algoritmo.

De acordo com Brady e Cronin (2001) as dimensões primárias da qualidade em serviço se pautam em três pilares a qualidade da interação, do ambiente físico e dos resultados.

Com a avaliação dos atributos mais importantes o trabalho mostrou que dentre elas a qualidade da interação que é o atendimento ao público é a mais importante pois os atributos com maior valor na pesquisa foram da seção de qualidade da informação ao consumidor (QIC), seguidas pela qualidade do funcionamento (QF) que é a qualidade dos resultados. Portanto, a pesquisa deixa claro que esses aspectos das dimensões da qualidade em serviço estão muito atrelados à satisfação mesmo que indiretamente.

Utilizando o NPS foi possível identificar atributos coerentes com as dimensões da qualidade, porém pode ser que utilizando outro tipo de questionário a precisão dos algoritmos melhore e também mostre outros atributos mais importantes para a satisfação geral do consumidor.

De acordo com Tong *et al.* (2017) a entrega de valor e satisfação gera a fidelidade do cliente com a operadora e essas percepções têm sido estudadas com alguma frequência para aumentar vendas e qualidade.

É apresentado no trabalho que esforços para aumento da qualidade devem focar nas informações passadas aos consumidores com ênfase na internet, garantir a estabilidade e velocidade além de ter uma cobertura maior para que a mudança de local não seja um definidor na hora de escolher uma operadora.

Após todos os resultados ambas hipóteses apresentadas no início da pesquisa foram validadas sendo elas:

- Os neutros são uma faixa de transição, quem deu nota 7 é mais insatisfeito e quem deu nota 8 é mais satisfeito
- O Modelo multiclasse terá uma eficiência menor e métricas piores para a base de dados selecionada

Outras ideias de trabalhos futuros:

1) Aplicar o mesmo método deste trabalho em outras bases de satisfação disponibilizada por empresas e pelo governo;

2) Acompanhar anualmente os resultados desta pesquisa da ANATEL usando este mesmo método para identificar mudanças no perfil de satisfação dos clientes;

REFERÊNCIAS

ANATEL. Anatel - Pesquisa de Satisfação e Qualidade - Ranking. Disponível em: <https://informacoes.anatel.gov.br/paineis/consumidor/pesquisa-de-satisfacao-e-qualidade-ranking>. Acesso em: 21/05/2022.

ANATEL. Manual de Aplicação da Pesquisa para Aferição do Grau de Satisfação e da Qualidade Percebida Junto aos Usuários de Serviços de Telecomunicações. Disponível em: <https://sistemas.anatel.gov.br/anexar-api/publico/anexos/download/bdc4f57d8623aa3fc19850360f3ac240>. Acesso em: 20/06/2022.

ANATEL. Banco de Dados da Pesquisa – Serviço de Telecomunicação Móvel Pós e Pré. 2021. Disponível em: <https://informacoes.anatel.gov.br/paineis/consumidor/pesquisa-de-satisfacao-e-qualidade-ranking>. Acesso em: 19/05/2022.

ANATEL. **Resolução CD-ANATEL n. 575, de 28 de outubro de 2011**. Aprova o Regulamento de Gestão da Qualidade da Prestação do Serviço Móvel Pessoal - RGQ-SMP e altera o Regulamento do Serviço Móvel Pessoal – SMP. Brasília: Diário Oficial da União, 2011. Disponível em: <https://www.diariodasleis.com.br/busca/exibmlink.php?numlink=218655>. Acesso em: 15/05/2022.

ANDERSON, E.W.; SULLIVAN, M.W. The Antecedents and Consequences of Customer Satisfaction for Firms. **Marketing Science**, v. 12, 125-143, 1993.

ANDERSON, R.; SRINIVASAN, K. E-Satisfaction and E-Loyalty: A Contingency Framework. **Psychology and Marketing**, v. 20, p. 123 – 138, 2003.

ANUMALLA, K. **Sistema de Gestão da Pré-Processamento de Dados**. 2007. (Dissertação de Mestrado). USA: Universidade de Akron, 2007.

BALACHANDRAN, A.; SEKAR, V.; AKELLA, A.; et al. **Developing a predictive model of quality of experience for internet video**. In: Proceedings of the ACM SIGCOMM 2013 conference on SIGCOMM. 2013. Nova York. **Anais[...]** Nova York: Association for Computing Machinery, 2013. p. 339-350. Disponível em: <https://dl.acm.org/doi/10.1145/2486001.2486025>. Acesso em: 31/10/2022.

BOAKYE, K. G.; PRYBUTOK, V. R.; RYAN, S. D. The intention of continued web-enabled phone service usage: A quality perspective. **Operations Management Research**, v. 5, n. (1–2), p. 14–24, 2012.

BRADY, M. K.; CRONIN, J. J. Some New Thoughts on Conceptualizing Perceived Service Quality: A Hierarchical Approach. **Journal of Marketing**, v. 65, n. 3, p. 34–49, 2001.

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**, v. 8, n. 6, p. 5153–5161, 2018.

CARVALHO, A. C. P. L. F.; ALMEIDA, T. A.; GAMA, J.; LORENA, A. C.; FACELI, K. **Inteligência Artificial: Uma abordagem de Aprendizado de Máquina**. 1. ed. Rio de Janeiro: Ltc, 2011.

CLERCQ, D. D.; JALOTA, D.; SHANG, R.; NI, K.; ZHANG, Z.; KHAN, A.; WEN, Z.; CAICEDO, L.; YUAN, K. Machine learning powered software for accurate prediction of biogas production: a case study on industrial-scale Chinese production data. **Elsevier**, v. 218, p. 390-399, maio, 2019.

COX, T.; BELL, G. A machine learning approach to process improvement in a telecommunications company. **Annals of Operations Research**, v. 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**, v. 4, n. 3, p. 217–227, 1995.

CRONIN, J.; BRADY, M. K.; HULT, T. M. Assessing the effects of quality, value, and customer satisfaction on consumer behavioral intentions in in service environments. **Journal of Retailing**, v. 76, p. 193-218, 2000.

DJATNA, T.; KUSUMA, W. A. Twitter's Sentiment Analysis on Gsm Services using Multinomial Naïve Bayes. **Telkomnika (Telecommunication, Computing, Electronics and Control)**, v. 15, p. 1354-1361, 2017.

DO CNN BUSINESS. Brasil tem mais smartphones que habitantes, aponta FGV. Disponível em: <https://www.cnnbrasil.com.br/business/brasil-tem-mais-smartphones-que-habitantes-aponta-fgv/#:~:text=S%C3%A3o%20242%20milh%C3%B5es%20de%20celulares,a%201%2C6%20por%20pessoa>. Acesso em: 26/6/2022.

ERTEL, W. (2017). **Introduction to Artificial Intelligence**. 2. ed. London: Springer.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P. **Advances in Knowledge Discovery & Data Mining**. California: American Association for Artificial Intelligence, 1996.

GUO, G.; WANG, H.; BELL, D.; BI, Y.; GREER, K. KNN Model-Based Approach in Classification. **Lect Notes Comput Sci**, v. 2888, p. 986-996, 2003.

HAMID SIROOSI; HESHMATI, G.; ABDOLRASSOUL SALMAN MAHINY. **Can empirically based model results be fed into mathematical models?** MCE for neural network and logistic regression in tourism landscape planning. Disponível em: <<https://www.researchgate.net/publication/332778729> Can empirically based mod

[el results be fed into mathematical models MCE for neural network and logistic regression in tourism landscape planning](#)>

HAMEED, N.; SHABUT, A.; GHOSH, M.; HOSSAIN, A. Multi-Class Multi-Level Classification Algorithm for Skin Lesions Classification using Machine Learning Techniques. **Expert Systems with Applications**, v. 141, n. 112961, set. 2019.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The Elements of Statistical Learning. **SpringerLink**, 2022. Springer New York.

HOFFMAN, K. D.; BATESON, J. E. G. **Princípios de Marketing de Serviços**. Trad. Brasil Ramos Fernandes. Revisão Técnica Tânia Maria Vidigal Limeira – São Paulo: Pioneira Thomson Learning, 2003.

JEONG, K.; ABBAS, A.; SHIN, J.; SON, M.; KIM, Y. M.; CHO, K. H. Prediction of biogas production in anaerobic co-digestion of organic wastes using deep learning models. **Water Research**, v. 205, out. 2021.

KONAR, A. **Artificial Intelligence and Soft Computing Behavioral and Cognitive, Modeling of the Human Brain**. Boca Raton, Florida: CRC Press LLC, p. 788, 1999.

KUMAR, A.; LIM, H. Age differences in mobile service perceptions: Comparison of Generation Y and baby boomers. **Journal of Services Marketing**, v. 22, p. 568-577, 2008.

LI, W. 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**. v. 142, p. 194–207, 2018.

LU, H.; LEUNG, H.T.; WANG, N., PAK, W.L.; SHIEH, B.H. Role of Ca²⁺/calmodulin-dependent protein kinase II in Drosophila photoreceptors. **Journal of Biology Chemicals**, v. 284, n. 17, p. 11100-11109, 2009.

MARTÍNEZ CARO, L.; MARTÍNEZ, J. Measuring perceived service quality in urgent transport service. **Journal of Retailing and Consumer Services**, v. 14, p. 60-72, 2007.

MARKOULIDAKIS, I.; RALLIS, I.; GEORGOULAS, I.; KOPSIAFTIS, G.; DOULAMIS, A.; DOULAMIS, N. A Machine Learning Based Classification Method for Customer Experience Survey Analysis. **Technologies**, v. 8, n. 4, p. 76, 7 Dec. 2020.

MISHRA, C.; GUPTA, D. L. Deep Machine Learning and Neural Networks: An Overview. **International Journal of Artificial Intelligence**, v. 6, n. 2, p. 66-73, junho, 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**, v. 45, n. 4, p. 539–548, 2020.

NGAI, E.W.T., HU, Y., WONG, Y.H., CHEN. Y., SUN, X. The application of data mining techniques in financial fraud detection: A classification framework and an academic review of literature. **Decision Support Systems**, v. 50, p. 559-569, 2011.

NASCIMENTO, C. A. N. **Avaliação da capacidade do serviço de atendimento de companhias de telefonia móvel no estado do paran  por meio da qualidade percebida**. Trabalho de conclus o de curso. Universidade Tecnol gica Federal Do Paran  Departamento Acad mico De Engenharia De Produ o, Ponta Grossa, 2017.

OZKLAN, I.; KOKLU, M. Multiclass classification of dry beans using computer vision and machine learning techniques. **Computers and Electronics in Agriculture**, v. 174, n. 105507, jul. 2020.

PADHY, N., MISHRA, P., PANIGRAHI. R. The Survey of Data Mining Applications and Feature Scope. **International Journal of Computer Science**, Engineering and Information Technology, v. 2, n. 3, p. 43-58, 2012.

PENG, K.F.; CHEN, Y.; WEN, K.W. Brand relationship, consumption values and branded app adoption. **Industry Management Data Systems**, v. 114, n. 8, p. 1131-1143, 2014.

PARASURAMAN, A; ZEITHAML, V. A; BERRY, L. L. A conceptual model of service quality of and its implication for future reserch. **Jornal of Marketing**, 1985.

RODRIGUES, Kelly Poliana; SILVA, Leandro Cesar Diniz da; ANDRADE, Alexandre Pires de. UMA AN LISE DAS A OES DE P S-VENDA COMO ESTRAT GIA DE FIDELIZA O. In: CONGRESSO VIRTUAL BRASILEIRO DE ADMINISTRA O, 8, 2013, S o Paulo. **Anais[...]** . S o Paulo: Convibra, 2013. p. 1 - 12.

ROSA, C.R.M. **Uma metodologia para a descoberta de conhecimento em bases de dados visando a classifica o de padr es**. Tese (Doutorado) – Programa de P s-Gradua o em Engenharia de Produ o e Sistemas, Pontif cia Universidade Cat lica do Paran , Curitiba, 2017.

SACCOL, A. Z.; REINHARD, N. Tecnologias de informa o m veis, sem fio e ub guas: defini es, estado-da-arte e oportunidades de pesquisa. **Revista de Administra o Contempor nea**, v. 11, n. 4, p. 175-198, 2007.

SHALEV-SHWARTZ, S.; BEN-DAVID, S.. **Understanding machine learning. From theory to algorithms**, Waterloo: Cambridge University Press, 2013.

SILVA, W. C. P. DA; PEDROSA, G. V.; GOMES, M. M. F. **PROPOSTA DE MODELO DE AVALIA O DA SATISFA O DE USU RIOS DE SERVI OS P BLICOS**. 2020.

SILVA; W. C. P.; PEDROSA, G. V.; GOMES, M. M. F. **Proposta de modelo de avalia o da satisfa o de usu rios de servi os p blicos**. Bras lia: Universidade de Bras lia, Faculdade Gama, 2020.

TEIXEIRA, G. M. **Compromisso com a educação: humanismo, paixão e êxito** / Geraldo Magela Teixeira. – 1.ed. – Belo Horizonte: Veredas & Cenários, 2008.

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, Nov. 2017. DOI 10.1109/CC.2017.8233665. Available at: <http://ieeexplore.ieee.org/document/8233665/>.

TYAGI, S. Using data analytics for greater profits. **Journal of Business Strategy**, v. 24, p. 12-14, 2003.

XIAO, F., FAN, C. Data mining in building automation system for improving building operational performance. **Energy and Buildings**, v. 75, p. 109-118, 2014.

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**, v. 32, n. 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**, v. 13, n. 8, p. 5837–5845, 2017.