



Universidade do Estado do Rio de Janeiro
Centro de Tecnologia e Ciências
Faculdade de Engenharia

Carlos Alberto Martins Júnior

**Classificação de índices de satisfação de usuários de telefonia
móvel usando aprendizado de máquinas**

Rio de Janeiro
2020

Carlos Alberto Martins Júnior

**Classificação de índices de satisfação de usuários de telefonia móvel
usando aprendizado de máquinas**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro.

Orientador: Prof. Dr. Lisandro Lovisolo

Orientador: Prof. Dr. Marcelo Gonçalves Rubinstein

Rio de Janeiro

2020

CATALOGAÇÃO NA FONTE
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

M386 Martins Júnior, Carlos Alberto.
Classificação de índices de satisfação de usuários de telefonia móvel usando aprendizado de máquinas / Carlos Alberto Martins Júnior. – 2020.
62f.

Orientadores: Lisandro Lovisolo, Marcelo Gonçalves Rubinstein.

Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.

1. Engenharia eletrônica - Teses. 2. Aprendizado do computador - Teses. 3. Redes neurais (Computação) - Teses. 4. Sistemas de telefonia celular - Teses. 5. Satisfação do consumidor - Teses. I. Lovisolo, Lisandro. II. Rubinstein, Marcelo Gonçalves. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.

CDU 004.891:621.396.61

Bibliotecária: Júlia Vieira – CRB7/6022

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta tese, desde que citada a fonte.

Assinatura

Data

Carlos Alberto Martins Júnior

**Classificação de índices de satisfação de usuários de telefonia móvel
usando aprendizado de máquinas**

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre, ao Programa de Pós-Graduação em Engenharia Eletrônica da Universidade do Estado do Rio de Janeiro.

Aprovado em:

Banca Examinadora:

Prof. Dr. Lisandro Lovisolo (Orientador)

Faculdade de Engenharia – UERJ

Prof. Dr. Marcelo Gonçalves Rubinstein (Orientador)

Faculdade de Engenharia – UERJ

Prof. Dr. Karla Figueiredo

Instituto de Matemática e Estatística – UERJ

Prof. Dr. Carlos Alberto Campos

Universidade Federal do Estado do Rio de Janeiro – UNIRIO

Rio de Janeiro

2020

DEDICATÓRIA

Dedico este trabalho à minha família, aos meus amigos e aos meus orientadores.

AGRADECIMENTOS

À empresa que disponibilizou os dados usados na pesquisa, embora não possa ser identificada;

Aos meus pais, pela motivação que sempre me deram e pela educação que recebi deles;

Aos meus orientadores, pelos conhecimentos passados, pela ajuda fornecida e pela dedicação.

RESUMO

MARTINS JR, C. A. *Classificação de índices de satisfação de usuários de telefonia móvel usando aprendizado de máquinas*. 2020. 62f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

Para manter a rentabilidade no concorrido mercado de telecomunicações, as operadoras de telefonia amparam-se em métricas de negócios, tais como a taxa de rotatividade dos clientes (*churn*) e o *Net Promoter Score* (NPS). Nos últimos anos, as telecomunicações no Brasil e no mundo todo têm usado o conceito de NPS para gerenciamento de relacionamento com o cliente. Operadoras de rede móvel visam a minimizar a degradação da qualidade da rede, a fim de melhorar a qualidade da rede e conseqüentemente a experiência do cliente. Contudo, o número de pontos de medição na rede é potencialmente massivos e é altamente desejável usar técnicas de aprendizado de máquina para extrair os recursos de rede mais importantes que provavelmente causam um serviço de rede mal percebido. Este trabalho explora técnicas de aprendizado de máquina com algoritmo de Rede Neural Artificial, Floresta Aleatória e XGBoost para prever o NPS, além de, com base no NPS, ajudar a prevenir o *churn*. Para tal, foi utilizada uma base amostral de 82.618 clientes de uma operadora do Brasil a qual inclui informações reais de uso da rede e de negócios. Os resultados mostram que é possível empregar uma ampla variedade de métricas de rede e de negócio para treinar uma máquina que permita entender a percepção dos clientes visando a mantê-los. O trabalho produziu descobertas que têm implicações vitais para as operadoras, destacando-se a apresentação de quais são os indicadores de rede e de negócio principais que afetam a experiência do cliente. Não foi encontrado nenhum outro trabalho com a mesma vertente de pesquisa para que pudéssemos realizar comparações.

Palavras-chave: Aprendizado de Máquina; RNA; Redes Neurais Artificiais; Floresta Aleatória; XGBoost; Churn; NPS; Telecomunicações; Redes Móveis.

ABSTRACT

MARTINS JR, C. A. *Classification of mobile phone users satisfaction rates with machine learning*. 2020. 62f. Dissertação (Mestrado em Engenharia Eletrônica) – Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2020.

In order to keep profitable in a competitive telecommunications market, telephone operators rely on business metrics, such as customer turnover rate (churn) and Net Promoter Score (NPS). Recently, telecommunications in Brazil and worldwide have used the NPS concept for managing customer relationship. Mobile network operators aim to minimize degradation of network quality in order to improve the overall quality of the experience. However, the number of measurement points in a network is potentially massive and it is highly desirable to use machine learning techniques to extract the most important actionable network resources that are likely to cause poorly perceived network service. This work explores machine learning techniques with Artificial Neural Network, Random Forest and XGBoost algorithms to predict NPS, and, based on NPS, help prevent churn. For this purpose, a sample base of 82,618 customers from an operator in Brazil was used, which includes real information on network and business usage. The results show that it is possible to employ a wide variety of network and business metrics to train a machine that allows to understand the perception of customers in order to maintain them. The work produced discoveries that have vital implications for operators, highlighting the presentation of what are the main network and business indicators that affect the customer experience. No other work with the same research aspect was found so that we could make comparisons.

Keywords: Machine Learning; RNA; Artificial neural networks; Random Forest; XGBoost; Churn; NPS.

LISTA DE FIGURAS

Figura 1 – Mapeamento da satisfação do cliente em sua capacidade de promover a marca, produto ou serviço.....	19
Figura 2 – Distribuição da NPS pesquisa realizada.	20
Figura 3 – Proposta de pesquisa para respostas das extremidades.....	21
Figura 4 – Arquitetura LTE considerando sistemas mais antigos [34].....	24
Figura 5 – Diferentes níveis de inteligência artificial.....	27
Figura 6 – Modelo de um neurônio.....	29
Figura 7 – Ilustração de uma rede neural artificial.....	30
Figura 8 – Comparação do XGBoost e outros métodos.....	35
Figura 9 – Sistema proposto em diagrama de blocos.	37
Figura 10 – Estudo de caso proposto.....	38
Figura 11 – Sistema de coleta dos indicadores IR e IQ Huawei Full Scale Data Collection [17].....	40
Figura 12 – Exemplo de Curva ROC.....	44
Figura 13 – Rede Neural utilizada na simulação.	46
Figura 14 – Resultados obtidos nos treinamentos da RNA considerando as duas classes.....	47
Figura 15 – Resultados obtidos nos treinamentos da RNA considerando as três classes.	48
Figura 16 – Resultados obtidos nos treinamentos da RFA considerando as duas classes.....	50
Figura 17 – Resultados obtidos nos treinamentos da RFA considerando as três classes.	50
Figura 18 – Resultados obtidos nos treinamentos do XGBoost considerando as duas classes.....	52
Figura 19 – Resultados obtidos nos treinamentos do XGBoost considerando as três classes.	52
Figura 20 – Comparação entre os classificadores de duas classes.....	53
Figura 21 – Comparação entre os classificadores de três classes.....	54

Figura 22 – Resultado das funções apresentadas pelo XGBoost para duas classes.	55
Figura 23 – Resultado das funções apresentadas pelo XGBoost para três classes.	56
Figura 24 – Índice de insatisfação da operadora ponderado.	57

LISTA DE TABELAS

Tabela 1 – Dados empregados	41
-----------------------------------	----

LISTA DE ABREVIATURAS E SIGLAS

1G	Primeira geração de dispositivos móveis sem fio
2G	Segunda geração de dispositivos móveis sem fio
3G	Terceira geração de dispositivos móveis sem fio
3GPP	Third Generation Partnership Project
4G	Quarta geração de dispositivos móveis sem fio
5G	Quinta geração de dispositivos móveis sem fio
6G	Sexta geração de dispositivos móveis sem fio
AISeL	AIS Electronic Library
AM	Aprendizado de máquinas
ANATEL	Agência Nacional de Telecomunicações
ARIB	Association of Radio Industries and Businesses
ATIS	Alliance for Telecommunications Industry Solutions
bps	Bits por segundo
CAGR	Compound Annual Growth Rate
CCSA	China Communications Standards Association
CDMA	Code Division Multiple Access
CEM	Customer Experience Management
CEM	Customer Experiencie Management
CHURN	Taxa de rotatividade dos clientes
CONF-IRM	International Conference on Information Resources Management
CRM	Customer Relationship Manager
Curva ROC	Receiver Operating Characteristic Curve
ETSI	European Telecommunications Standards Institute
FN	Taxa de Falsos Negativos, ou False Negative Rate
FP	Taxa de Falsos Positivos, ou False Positive Rate
Gbps	Gigabits por segundo
GSM	Groupe Speaciale Mobile/ Global System for Mobile Communications
IA	Inteligência artificial
IN	Indicadores de Negócio

IP	Internet Protocol
IQ	Indicadores de Qualidade
IR	Indicadores de Rede
kbps	kilobit por segundo
KPI	Key Performance Indicators
KQI	Key Quality Indicators
LTE	Long Term Evolution
MLP	Multi Layer Perceptron, ou Perceptron Multicamadas
NPM	Network Performance Management
NPM	Network Performance Management
NPS	Net Promoter Score
OTT	Over The Top
PDC	Japanese Personal Digital Cellular
QoE	Quality of Experience
ReLU	Rectified Linear Unit
FA	Floresta Aleatória
RGQ-SMP	Regulamento de Gestão da Qualidade da Prestação do Serviço Móvel Pessoal
RNA	Rede Neural Artificial
RTT	Round Trip Time
SIGKDD	Special Interest Group on Knowledge Discovery in Data
SQM	Service Quality Management
SQM	Service Quality Management
TDMA	Time Division Multiple Access
TN	Taxa de Faltos Verdadeiros, ou True Negative Rate
TP	Taxa de Verdadeiros Positivos, ou True Positive Rate
TSDSI	Telecommunications Standards Development Society
TTA	Telecommunications Technology Association
TTC	Telecommunication Technology Committee
VoLTE	Voz sobre a rede Long Term Evolution (LTE)
WWW	Wireless World Wide Web
XGBoost	eXtreme Gradient Boosting

1	INTRODUÇÃO.....	13
1.1	Estrutura da dissertação	15
2	REVISÃO DA LITERATURA.....	16
3	FUNDAMENTAÇÃO TEÓRICA	19
3.1	Net Promoter Score (NPS).....	19
3.2	Redes Móveis	21
3.3	Aprendizado de Máquina	26
3.4	Rede Neural Artificial para classificação	28
3.5	Floresta Aleatória para classificação.....	31
3.6	eXtreme Gradient Boosting (XGBoost) para classificação	33
4	SISTEMA PROPOSTO.....	35
4.1	Proposta.....	35
4.2	Dados empregados.....	37
4.3	Avaliação dos classificadores	40
5	RESULTADOS	43
5.1	RNA projetada.....	43
5.2	Resultados obtidos com RNA	45
5.3	Floresta Aleatória projetada	47
5.4	Resultados obtidos com Floresta Aleatória	48
5.5	Resultados obtidos com XGBoost.....	49
5.6	Resultados obtidos com XGBoost.....	50
5.7	Análise comparativa entre os classificadores.....	52
5.8	Indicadores de rede apontados como ofensores	54
6	CONSIDERAÇÕES FINAIS.....	57
7	REFERÊNCIAS	59

1 INTRODUÇÃO

O conhecimento associado à telefonia móvel está em constante evolução, fazendo surgir grandes inovações e trazendo novas tecnologias e ferramentas ao mercado. Essa evolução impacta fortemente a sociedade, que se torna eventualmente dependente dessas novas tecnologias. Em linha com este cenário, a Cisco estimou que o consumo de dados móveis na internet teria um *Compound Annual Growth Rate* (CAGR) de 47% entre 2016 e 2021 [1].

A constante evolução tecnológica obriga as operadoras de telecomunicações a acompanhar esses avanços, visando a manter a competitividade e sua base de clientes. Consequentemente, as operadoras têm buscado formas de entender a qualidade da experiência de seus usuários e estudos apresentam formas de melhorar a retenção [2]. A qualidade da experiência do usuário é medida pelo *Quality of Experience* (QoE). Existem diversas definições sobre a experiência do usuário, a União Internacional de Telecomunicações na Recomendação ITU-T P.10 define como o grau de satisfação ou aborrecimento do usuário de um aplicativo ou serviço. Resulta do cumprimento de suas expectativas com relação à utilidade ou gozo do aplicativo ou serviço à luz da personalidade do usuário e do estado atual. O QoE é uma medida subjetiva da perspectiva do usuário da qualidade geral do serviço prestado [3].

Com o objetivo de aferir a QoE empregam-se ferramentas de *Network Performance Management* (NPM), *Service Quality Management* (SQM) e *Customer Experience Management* (CEM), que possibilitam avaliar o desempenho da operadora. Busca-se com grande esforço a excelência do serviço prestado/ofertado, pois a manutenção de um cliente tem um custo inferior ao custo da conquista de um novo [4].

Operadoras de telecomunicações em todo o mundo procuram minimizar a degradação da qualidade do serviço prestado, com o objetivo de melhorar a qualidade geral da experiência dos usuários, pois uma experiência ruim poderá frustrar o usuário e resultar em alta taxa de rotatividade dos clientes (*churn*) [5].

As empresas de telecomunicações sentem a necessidade de se tornarem mais competitivas e de elevarem cada vez mais a qualidade dos seus produtos e serviços. Todavia, a adequação do desempenho da rede é um desafio para os administradores das redes de telecomunicações.

A gestão da rede e da qualidade de serviço das aplicações *Over The Top* (OTT) [6] torna-se cada dia mais complexa e desafiadora, com o surgimento frequente de novas aplicações e demandas. O acesso a novas aplicações acaba tornando o usuário final mais exigente, aumentando suas expectativas quanto à confiabilidade, qualidade e acessibilidade dos serviços utilizados, que em grande parte são unicamente associados à operadora de telecomunicações e não ao serviço OTT. Quando o cliente enfrenta um problema ao utilizar um aplicativo, o cliente associa a falha à operadora mesmo quando a falha pode ser devida a erros na rede da operadora ou no próprio aplicativo.

No Brasil, a qualidade da telefonia móvel é regulamentada e fiscalizada pela Agência Nacional de Telecomunicações (ANATEL) através do Regulamento de Gestão da Qualidade da Prestação do Serviço Móvel Pessoal (RGQ-SMP) [7] que obriga as operadoras a informar como estão os indicadores da rede. As operadoras buscam atender as exigências da Anatel e possuem o engajamento de entender melhor a experiência dos usuários.

Uma métrica popular tem sido utilizada em vários setores para avaliar a experiência dos usuários: o *Net Promoter Score* (NPS). O NPS foi introduzido como uma forma de aferir a probabilidade de um cliente indicar a empresa ou o produto para outro cliente [8]. Essa métrica traz visibilidade às reclamações dos clientes e tem trazido resultados significativos para várias empresas, mostrando informações que servem como suporte à tomada de decisões da empresa quanto às suas estratégias de longo e curto prazo [9].

Com a concorrência acirrada entre as operadoras de telefonia móvel, entender a experiência do usuário torna-se prioridade para a retenção de assinantes. Técnicas estatísticas e de aprendizado de máquina têm sido utilizadas para criar modelos de previsão do *churn* [10] [11], assim como modelos utilizando o NPS e patentes têm sido registradas [11] [12] neste objetivo.

Durante anos, as empresas concentraram-se na previsão do *churn* e propuseram maneiras de atingir os clientes de acordo com seu risco estimado de rotatividade. Apesar da popularidade dessa abordagem, estudos recentes descobriram que a classificação de clientes com base na probabilidade de rotatividade pode levar a campanhas de retenção ineficazes; em contrapartida, a análise do NPS,

combinando aprendizado de máquinas com indicadores de rede e negócio, permite entender as suposições sobre o comportamento do assinante [13].

Por isso, serão avaliados os benefícios do aprendizado de máquinas para a classificação e estimativa da experiência de usuários de uma empresa de telecomunicações do Brasil com dados reais.

1.1 Estrutura da dissertação

O Capítulo 1 revisa a literatura de experiência de usuário. O Capítulo 2 apresenta, como fundamentação teórica, os conceitos de *Net Promoter Score* (NPS), redes móveis e aprendizado de máquina, assim como as técnicas de classificação de indicadores. O Capítulo 3 discute o sistema de aprendizado proposto, e traz a modelagem pertinentes, as fontes de dados e os procedimentos. O Capítulo 4 apresenta e discute os resultados obtidos. O Capítulo 5 encerra esta dissertação com as considerações finais.

2 REVISÃO DA LITERATURA

Nesta sessão serão apresentados diversos trabalhos que visam entender a experiência do cliente de maneira geral, também são apresentados trabalhos relacionados ao NPS, o emprego de NPS no setor de telecomunicações e o objetivo deste estudo.

A experiência de um usuário pode ser definida como a lacuna entre o que um cliente esperava experimentar e o que ele de fato experimenta ao tornar-se cliente de um serviço ou produto [14]. Entretanto, também pode ser definida como a impressão formada pelo encontro do cliente com o produto ou serviço [15].

Para que uma empresa estabeleça um relacionamento de longo prazo com um cliente, é importante que ela proporcione uma experiência positiva ao cliente e crie fidelidade com a marca [16]. A lealdade do cliente é determinada pelo relacionamento da empresa com seu cliente e por quão bem as empresas entendem as necessidades e desejos dos clientes [17].

No mundo dos negócios de hoje, a experiência do usuário é um fenômeno novo e importante que tem mudado as tendências da economia de serviços [18]. Colocar o foco nas experiências dos clientes pode ajudar as empresas a reter clientes fiéis. Esses clientes tornam-se clientes geradores de receita por anos, incorporando seu caminho aos negócios [19].

O NPS indica a satisfação do usuário baseada em sua experiência. O NPS ajuda fortemente a vincular satisfação, recomendação e resultados de negócios, correlacionando-se significativamente com o crescimento da empresa e podendo ser facilmente comunicado em toda a organização. Reichheld afirma que o NPS é “o melhor indicador de crescimento” e “o único número que vocês [empresas] precisam para crescer”: as empresas que conquistam lealdade mundialmente têm um NPS entre 75 e 80% [20].

Em 2001, Reichheld, em colaboração com a *Bain Consulting* e a *Satmetrix*, realizou um estudo com 400 empresas americanas, que representavam mais de uma dezena de indústrias, sobre a relação entre taxas de crescimento e as pontuações do NPS. Os resultados indicam que o NPS parece explicar as taxas de crescimento relativo significativamente bem, e Reichheld conclui que obter clientes entusiasmados o suficiente para recomendar uma empresa parece ser crucial para o crescimento da

maioria das empresas na maioria dos setores. Com base em seus resultados, Reichheld afirma que as empresas que lideram no NPS, conseguem, em média, crescer 2,5 vezes mais rápido que seus concorrentes [19].

Diversas empresas de grande porte adotaram o NPS, como GE, Intuit, Hertz, Walmart, American Express, Microsoft. Outras empresas, além de adotarem o NPS, incluíram-no como parte de seu relatório anual. São empresas como Allianz, Aviva e Standard Chatered [21].

Mundialmente, o setor de serviços de telecomunicações se esforça para melhorar a experiência proporcionada aos usuários e sua imagem. Um estudo realizado pela *Customer Gauge* [22] mostra que o setor de telecomunicações possui NPS médio de 24. A utilização do NPS nas empresas de telecomunicações no Brasil já é uma realidade nos principais *players* do setor, como VIVO, CLARO, TIM e OI. Na VIVO, o NPS influencia a remuneração de executivos [23]. Na CLARO, as avaliações dos clientes e o NPS são utilizados para identificar os principais pontos de melhoria do negócio [24]. A TIM comenta que o NPS de operadoras é muito baixo e investiga as razões para esse baixo desempenho [25].

Um dos maiores riscos para as telecomunicações é a incapacidade de compreender os valores do cliente [26]. Para compreender os valores dos usuários/clientes do setor de telecomunicações, alguns estudos propõem a utilização do NPS. Por exemplo, encontramos o desenvolvimento de um modelo holístico para isso a partir de dados coletados de 770 usuários em [27]. Outros defendem a importância de entender a experiência do cliente e propõem identificar a influência da experiência do cliente em sua fidelidade aos serviços de telecomunicações móveis utilizando o NPS [28].

Similarmente, este trabalho propõe-se a entender os motivadores/valores de clientes de serviços móveis a partir de métricas mensuráveis de rede e de negócio usando aprendizado de máquinas. Os resultados de uma pesquisa NPS são empregados para entender o impacto de alguns desses indicadores na satisfação de clientes. As respostas da pesquisa NPS e os indicadores chave de desempenho de rede e de negócio são aplicados para projetar classificadores da satisfação de clientes. Objetiva-se investigar como empregar aprendizado de máquina para esses fins. Para tanto, são empregados algoritmos de Redes Neurais Artificiais [29], Floresta Aleatória [30] e XGBoost [31]. E, objetiva-se também, apresentar a correlação entre o

uso do serviço de telecomunicações relacionado à rede e mensurados através de *Key Performance Indicators* (KPI), *Key Quality Indicators* (KQI) com o *Net Promoter Score* (NPS). Procura-se assim correlacionar as métricas de rede e de negócio para estimar o resultado do NPS de um cliente se consultado. Isso permitiria sinalizar possíveis casos de *churn* (troca de fornecedor do serviço), e porventura estimular o emprego de contramedidas para manter o cliente.

3 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta a definição da métrica NPS, a evolução das tecnologias de telefonia celular, critérios de avaliação da qualidade de redes e aspectos básicos sobre aprendizado de máquinas.

3.1 Net Promoter Score (NPS)

Foi Frederick Reichheld quem introduziu o NPS, no artigo “*The one number you need to grow*” [8] como uma forma de aferir a probabilidade de um cliente de uma empresa ou serviço indicar essa empresa ou esse serviço para outro cliente em potencial. O NPS deriva de uma única pergunta: “De zero a dez, qual a probabilidade de você recomendar nossa empresa a um amigo ou colega?”. Dessa maneira, utiliza-se uma escala para avaliar a disposição e a intenção do cliente de recomendar a empresa a outra pessoa, como apresentado na Figura 1.

0	1	2	3	4	5	6	7	8	9	10
Detrator							Neutro		Promotor	

Figura 1 – Mapeamento da satisfação do cliente em sua capacidade de promover a marca, produto ou serviço.

Os promotores são considerados clientes que “passaram a ter uma vida melhor” após o relacionamento com a marca e oferecem *feedbacks* positivos, contribuindo para algum aumento no faturamento da empresa, direta ou indiretamente. Clientes que respondem 7 ou 8 são caracterizados como “neutros”, ou seja, não são leais à marca ou empresa. Caso uma concorrente ofereça um produto em melhores condições, o cliente facilmente pode optar pela empresa concorrente, contribuindo para um aumento do *churn* [32]. Os detratores são aqueles considerados insatisfeitos com a compra do produto ou com o serviço prestado pela empresa. Acredita-se que as classificações mais baixas estejam associadas a experiências negativas, que podem impedir uma recomendação ou inviabilizar novos clientes em potencial.

O NPS é calculado como a porcentagem de respondentes considerados “promotores”, cuja resposta foi 9 ou 10, menos a porcentagem de respondentes considerados “detratores”, cuja resposta foi de 0 a 6. De posse desses valores, é feito o cálculo do NPS.

Os valores do NPS utilizados nesta dissertação advêm de uma pesquisa NPS realizada por uma operadora de serviços de telecomunicações no Brasil. Para isso foi enviado *Short Message Service* (SMS) para 800 mil clientes da operadora de telefonia móvel com a pergunta do NPS, houve respostas de 82.618 clientes, durante o mês junho de 2019, que foram coletadas. A operadora permitiu o uso das informações nesta dissertação, sob condição de anonimato. A Figura 2 apresenta a distribuição das respostas da pesquisa NPS. Vale observar que nessa amostra o valor do NPS é negativo, o que significa uma percepção ruim por parte dos usuários sobre os serviços prestados.

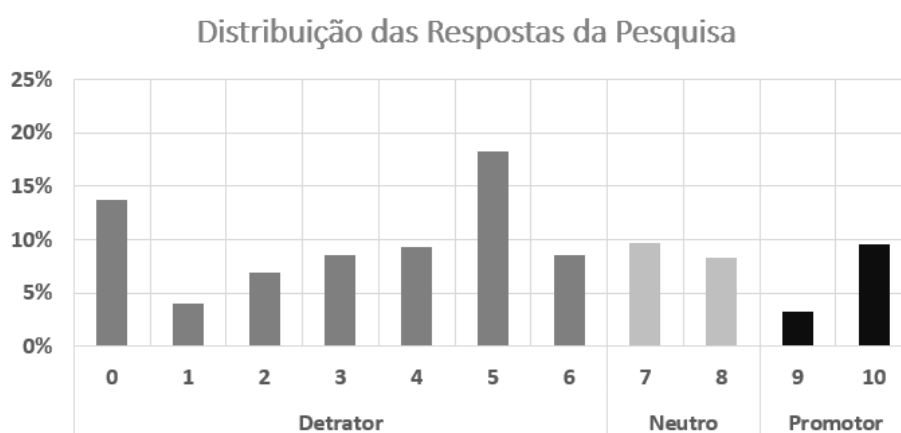


Figura 2 – Distribuição da NPS pesquisa realizada.

Observa-se que aproximadamente 54% dos clientes responderam valores entre 3 e 7. Clientes que respondem 0, 1 ou 2 são aqueles com pior percepção de experiência da empresa, sendo possíveis fontes de *churn*, e as respostas 8, 9 e 10 correspondem aos clientes com menores chances de *churn*. Considerando esse cenário, tem-se 38.945 respostas nesses dois grupos extremos. A partir deles, tem-se a distribuição de classes de clientes apresentada na Figura 3. Essa visão dos extremos das respostas da pesquisa também é utilizada neste trabalho no projeto de classificadores de duas classes (além do de três classes). Com certa liberdade nos referimos a essas classes como (possível) *churn* e *no-churn*. Em ambos os casos,

observa-se o desbalanceamento de classes (grandes diferenças entre as quantidades ocorrência de cada classe) e utilizou-se o balanceamento pela menor quantidade.

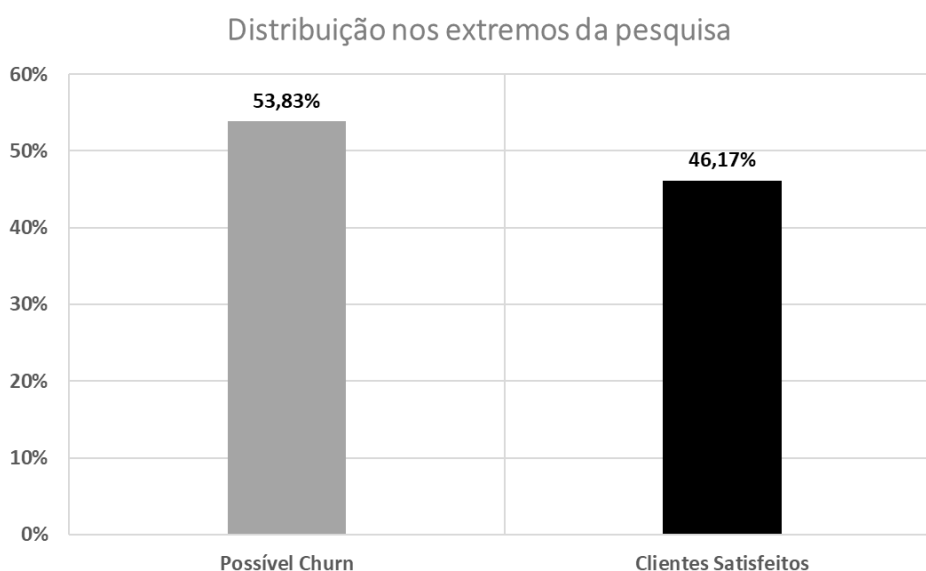


Figura 3 – Proposta de pesquisa para respostas das extremidades.

3.2 Redes Móveis

As facilidades conhecidas e utilizadas atualmente para enviar mensagens de celular, fazer videochamadas, solicitar motoristas por aplicativos, pedir entrega de comida e ouvir música, mudaram a vida das pessoas. A internet móvel hoje nos fornece um mundo de possibilidades com conectividade praticamente em qualquer lugar. Nem sempre foi assim, houve um tempo que era difícil fazer uma ligação. A evolução da telefonia móvel começou com o 1G em 1970, inventado por um engenheiro da Motorola, chamado Martin Cooper, e atualmente há estudos apontando para o 6G.

As gerações de celulares diferem em quatro aspectos principais: tecnologia de acesso via rádio, taxas de dados, largura de banda e tecnologias de comutação [33]. Os primeiros telefones móveis, chamados de primeira geração ou 1G, eram analógicos e podiam ser usados apenas para comunicação por voz. O 1G começou a ser usado em 1980, mas a qualidade da chamada de voz era péssima e os primeiros aparelhos pesavam cerca de 1 kg.

Acompanhando o avanço da tecnologia em geral, surgiram as tecnologias de segunda geração, chamadas 2G: *Group Special Mobile & Global System for Mobile Communications* (GSM), na Europa; o sistema *Time Division Multiple Access* (TDMA) e *Code Division Multiple Access* (CDMA), nos EUA; e o *Japanese Personal Digital Cellular* (PDC), no Japão, entre outros. As tecnologias 2G eram digitais e alcançavam taxas de pico pouco maiores que 300Kbps com largura de banda de até 200 KHz. O sistema 2G utilizado desde 1990 ainda está ativo no Brasil.

No final da primeira década do século vinte, iniciou-se o uso da terceira geração (3G) de redes sem fio para dispositivos móveis. A conexão provida pelo 3G aliada à produção de dispositivos integrando múltiplas interfaces possibilitou a transformação de celulares em *smartphones*. A terceira geração de telefônica móvel atinge taxas de transferência de pico de 50 Mbps com uma largura de banda de 5 MHz. As redes 3G possibilitaram a mudança no uso da telefonia móvel. Se hoje a vida pode ser difícil sem um celular, isso se deve à rede 3G, pois essa rede possibilitou:

- a) alcançar maiores taxas de transferência de dados;
- b) dispor de maior segurança, atender mais número de usuários e aumentar a cobertura;
- c) suportar para aplicativos móveis;
- d) fornecer serviços de geolocalização e mapas;
- e) melhorar a experiência de navegação na web;
- f) enviar e receber mensagens de e-mail grandes;
- g) acessar a web a alta velocidade, com mais segurança, permitindo videoconferências e jogos tridimensionais;
- h) realizar *streaming* de TV, TV móvel e chamadas telefônicas.

A quarta geração de redes de comunicações móveis, a 4G, foi anunciada em 2010 e é totalmente baseada em *Internet Protocol* (IP). A 4G é capaz de prover taxas de transferência de dados de pico que começam em 100 Mbps e teoricamente podem alcançar mais de 1 Gbps no *downlink* com largura de banda variável de 20, 40 ou 70 MHz. As principais características do 4G são:

- a) taxa de dados muito maior até 1 Gbps;

- b) maior segurança e mobilidade;
- c) latência reduzida para aplicativos;
- d) *streaming* e jogos de vídeo de alta definição;
- e) VoLTE de voz sobre a rede Long Term Evolution (LTE) (uso de pacotes IP para voz).

A quinta geração tecnologia de comunicação sem fio, o 5G, ainda se encontra em estágio inicial. A tecnologia começou a ser implementada em alguns países em 2020 e promete revolucionar novamente as telecomunicações. Suas principais características são:

- a) suporte para a WWW (Wireless World Wide Web);
- b) alta velocidade;
- c) transmissão ampla de dados em Gbps;
- d) jornais multimídia;
- e) transmissão de dados mais rápida que da geração anterior;
- f) multimídia interativa, voz, *streaming* de vídeo, internet e outros;
- g) maior eficácia;
- h) suporte a classe de serviços para carros autônomos;
- i) suporte a classe de serviços para cidades inteligentes.

As tecnologias 2G, 3G e 4G usadas atualmente possuem interoperabilidade, permitindo que sistemas evoluídos conversem com sistemas legados. Essa arquitetura está apresentada na Figura 4 [34].

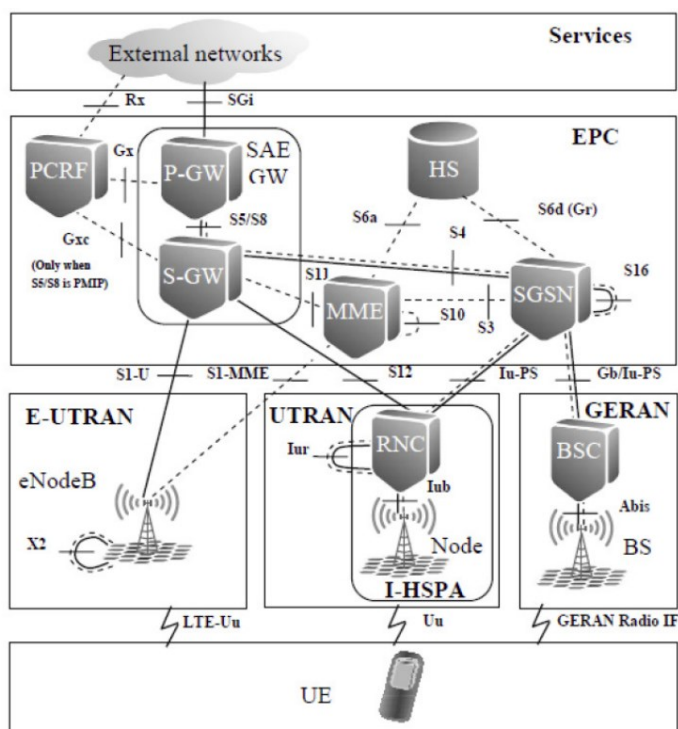


Figura 4 – Arquitetura LTE considerando sistemas mais antigos [34].

Todos os equipamentos, as interfaces e as funções são padronizadas e definidas pelo *3rd Generation Partnership Project* (3GPP) [35] [36] [37]. O 3GPP engloba as tecnologias de telecomunicações celulares, incluindo acesso de rádio, rede central, capacidades de serviço, e fornece uma descrição completa do sistema para telecomunicações móveis. O 3GPP é formado pela *Association of Radio Industries and Businesses* (ARIB), do Japão; a *Alliance for Telecommunications Industry Solutions* (ATIS), dos Estados Unidos; a *China Communications Standards Association* (CCSA), da China; o *European Telecommunications Standards Institute* (ETSI), da Europa; a *Telecommunications Standards Development Society* (TSDSI), da Índia; a *Telecommunications Technology Association* (TTA), da Coreia do Sul; e o *Telecommunication Technology Committee* (TTC), também do Japão. Essas entidades são conhecidas como *parceiros organizacionais* e são elas que desenvolvem os padrões de telecomunicações.

Como apresentado na Figura 4 existem diversas interfaces entre os equipamentos. A primeira interface é entre o dispositivo móvel (UE) e as redes (2G, 3G e 4G) – essa é uma interface sem fio, conhecida como interface aérea. As outras interfaces ficam entre os equipamentos e são em geral conectadas por cabo/fibra. Todas as interfaces possuem seu protocolo próprio e são divididas em plano de

controle e plano do usuário. O plano de controle consiste em protocolos para controle e suporte das funções do plano do usuário [35] [36] [37] como:

- a) controlar as conexões de acesso à rede 2G, 3G ou 4G, registrar e desconectar da rede;
- b) controlar os atributos de uma conexão a uma rede externa de comutação de pacotes;
- c) controlar o caminho de roteamento de uma conexão de rede estabelecida para suportar a mobilidade do usuário; e
- d) controlar a atribuição de recursos de rede para atender às mudanças nas demandas dos usuários.

O plano do usuário consiste em uma estrutura de protocolos em camadas que fornece transferência de informações do/ao usuário, incluindo procedimentos de controle de transferência de informações associados, tais como controle de fluxo, detecção de erro, correção de erro e recuperação de erro) [35] [36] [37].

Com os protocolos é possível mensurar o funcionamento da rede através do plano de controle e do plano de usuário, identificando falhas e problemas. As cinco categorias de classificação das KPI definidas pelo 3GPP estão listadas a seguir:

- a) acessibilidade: é o estabelecimento da conexão entre o usuário e a rede;
- b) retenção: é o tempo conectado de utilização dos serviços sem falha;
- c) disponibilidade: mede a indisponibilidade do serviço;
- d) mobilidade: mede a qualidade da rede e dos serviços perante a mobilidade do usuário;
- e) integridade: permite avaliar a qualidade do serviço de chamadas e dados.

Dentre os diversos indicadores dessas diferentes categorias, os comumente utilizados pelas operadoras de telecomunicações para aferir a experiência do usuário são:

- a) tráfego: medida da capacidade solicitada ou utilizada de uma rede de telecomunicações;

- b) tempo de registro nas redes 3G e 4G: tempo durante o qual o cliente permanece com o terminal acampado em cada uma destas tecnologias, 3G ou 4G, ou em ambas;
- c) *Round Trip Time* (RTT) ou latência: tempo total necessário para um serviço específico encaminhar e receber a resposta a um pacote através de uma rede de dados;
- d) perda de pacotes: taxa na qual os pacotes que trafegam pela rede falham em alcançar seus destinos;
- e) *throughput*: taxa em que os dados são transmitidos, também definida como a quantidade de bits movidos com êxito de um lugar a outro em determinado período, medida em bits por segundo (bps).

Os indicadores de rede utilizados neste trabalho foram divididos em dois grupos – Indicadores de Rede e Indicadores de Qualidade – e serão descritos na Seção 3.2.

3.3 Aprendizado de Máquina

Nesta seção, serão descritos os métodos de aprendizados de máquinas utilizados nesta dissertação e os conceitos básicos dessas técnicas.

O Aprendizado de Máquina (AM) é uma subárea da Inteligência Artificial (IA) como apresenta a Figura 5. O AM de máquina usa métodos computacionais que, com um mínimo de intervenção humana, aprendem a partir dos dados, reconhecem padrões, memorizam padrões, reproduzem padrões e auxiliam na tomada de decisões.



Figura 5 – Diferentes níveis de inteligência artificial.

Dentre os níveis de inteligência artificial apresentados na Figura 5, o AM emprega modelos matemáticos para a criação de algoritmos com o intuito de realizar previsões.

No estudo de AM, os algoritmos tipicamente são classificados em três categorias:

- a) algoritmos de aprendizagem supervisionado;
- b) algoritmos de aprendizagem não supervisionados;
- c) algoritmos de aprendizagem por reforço.

Algoritmos supervisionados ajustam modelos que mapeiam características observadas a rótulos (um rótulo é um marcador que indica a pertinência do objeto a uma classe). Existem dois tipos de tarefas comumente implementadas nas técnicas de aprendizado de supervisionado: a classificação, que pode ser definida como a identificação da categoria de um objeto, e a regressão, que busca estimar um valor numérico específico. Neste trabalho, serão utilizados os algoritmos de classificação com aprendizado supervisionado.

Um classificador é um algoritmo capaz de generalizar as informações aprendidas durante o treinamento, com a finalidade de posteriormente classificar entre

as classes – previamente conhecidas no conjunto de treinamento – objetos cujas classes sejam desconhecidas. Algoritmos de classificação associam padrões de entrada a classes na saída, visando indicar o grupo de pertinência mais provável para uma entrada a partir de seus atributos. Esse mapeamento entre entradas e saídas é aprendido durante o treinamento. Alguns exemplos de aplicação de classificadores são: filtragem de spam, detecção de idioma, pesquisa por documentos semelhantes, análise de sentimentos, reconhecimento de caracteres e números manuscritos, detecção de fraude, risco de crédito, reconhecimento facial ou vocal, biometria, assinatura cognitiva e diagnóstico médico antecipado [38].

Neste trabalho foram projetados classificadores usando Rede Neural Artificial, XGBoost e *Random Forest*. (RF). As RNs são técnicas computacionais que oferecem um modelo matemático inspirado em células neuronais e que adquirem conhecimento através da experiência. O RF é um algoritmo de aprendizagem de máquina flexível, pois trata-se de um modelo baseado em comitê, em que diversas árvores de decisão são utilizadas para tomarem, em conjunto, uma decisão. O XGBoost é um algoritmo de aprendizado de máquina, que se baseia em árvore de decisão e utiliza uma estrutura de *Gradient Boosting*, onde cada pequena árvore criada é produzida para resolver os erros da árvore anteriormente criada.

3.4 Rede Neural Artificial para classificação

As Redes Neurais Artificiais (RNA) são muito empregadas por serem aproximadores universais [39]. Uma RNA pode ser definida como um processador massivo e paralelamente distribuído, modelado com base no funcionamento simplificado de um neurônio. RNAs têm como elemento base o neurônio artificial, exemplificado na Figura 6. O neurônio artificial recebe sinais de entrada e realiza uma soma ponderada por pesos (que são as variáveis que devem ser ajustadas durante o treinamento) e que são submetidos a função de ativação. A função de ativação não linear introduz um componente não lineares, permitindo que nas redes neurais (compostas por múltiplos neurônios artificiais interconectados) possam aprender de forma mais eficaz comportamentos não lineares. As funções de ativação mais utilizadas incluem a função linear, sigmoide, a tangente hiperbólica, *softsign*, ReLU (unidade linear retificada) e *SoftMax*.




Figura 6 – Modelo de um neurônio.

Na entrada do modelo da Figura 6 (que é a RNA mais simples, contendo apenas um Perceptron [40]), tem-se os sinais de entrada (x_1 até x_n), cada sinal de entrada é multiplicado por um peso (w_1 até w_n) que indica a influência de cada entrada na composição do valor z do modelo. Somam-se, então, os sinais, obtendo

$$z = \sum_{i=1}^N x_i w_i + b. \quad (1)$$

Nessa equação, b provê um grau de liberdade a mais, através de um viés. O valor intermediário z é aplicado a uma função de ativação σ_1 , resultando no valor de saída do neurônio y .

Para problemas mais complexos, são necessários diversos neurônios dispostos e conectados em camadas. RNA de múltiplas camadas são estruturas constituídas por uma entrada, uma ou n camadas ocultas e uma camada de saída. Cada camada pode ter um número diferente de neurônios, formando uma rede neural denominada Multicamadas de Perceptrons (*Multi Layer Perceptron*, MLP [41]). As camadas de neurônios são ligadas entre si por sinapses com pesos (que realizam a combinação linear das entradas de um neurônio). As redes MLP são utilizadas para solução de diversos problemas complexos, tais como reconhecimento de padrões em vídeos e textos [41].

O aprendizado em uma rede emprega o algoritmo de retropropagação do erro (*Backpropagation*), que corrige os pesos em todas as camadas, processando e corrigindo os pesos na direção oposta, atualizando os pesos da saída para a entrada [42]. Para realizar o treinamento de uma rede neural para classificação supervisionada, é necessário fornecer os rótulos associados a cada registro, que se

pretende que a rede reconheça. Assim, um par definido pelo padrão x_i (atributos de entradas), correspondente à classe y_i é aplicado à rede, produzindo uma saída \hat{y}_i . A partir disso, obtém-se o erro

$$E(y, y') = \sum_{i=1}^N (y_i - \hat{y}_i)^2. \quad (2)$$

A Figura 7 apresenta a propagação do erro numa MLP entre camadas sucessivas.

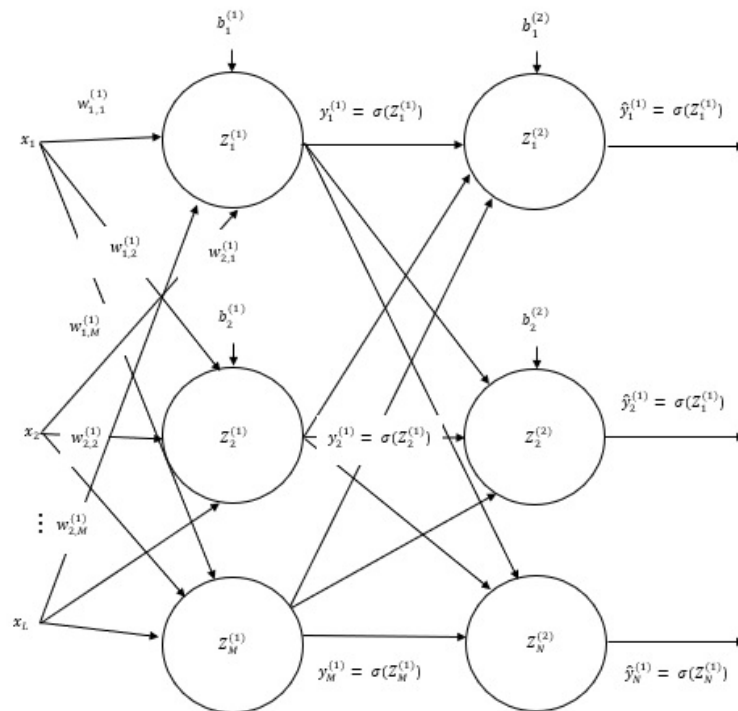


Figura 7 – Ilustração de uma rede neural artificial com uma camada escondida

O algoritmo de *Backpropagation* treina os pesos da RNA a partir do erro na saída da rede neural. Conforme a equação 2, calcula-se o erro entre o valor que a rede produziu e o que deveria ter sido gerado. A partir dele, ajustam-se os pesos do vetor w da última camada de neurônios e repete-se o processo em direção às camadas anteriores, de trás para a frente. Assim, atualizam-se todos os pesos da camada de saída até a de entrada da rede, realizando uma retropropagação do erro. A partir disso, a atualização dos pesos é definida como [43]:

$$w \leftarrow w - \eta \partial E / \partial w. \quad (3)$$

Das expressões (2) e (3), tem-se a derivada parcial do erro em relação à camada de saída \hat{y}_i . O procedimento de cálculo das derivadas parciais é realizado em cada camada, para retro propagar os erros até a camada de entrada da rede. Dessa maneira, pode-se definir o pseudocódigo do Algoritmo 1 para o treinamento de uma RNA MPL.

Algoritmo 1: Pseudocódigo Backpropagation

1. Inicializar pesos (w) e bias (b);
 2. Apresentar padrão de entrada com respectiva saída; $x_1, x_2, x_3, \dots, x_n$
 3. Propagar padrão de entrada de camada para camada de forma que calcule a saída de cada nó da rede (expressão matemática 2);
 4. Comparar a saída gerada pela rede com a saída target e calcular o erro para todos os nós da camada de saída (expressões matemáticas 2 e 3);
 5. Atualizar os pesos dos nós (expressão matemática 3)
 6. Para a camada de saída até a de entrada:
 7. Calcular o erro dos nós da camada intermediária baseada nos erros cometidos pelos nós imediatamente anteriores ponderando pelos pesos entre os nós da camada atual e o nós imediatamente seguintes (expressões matemáticas 2 e 3);
 8. Repetir os passos 2 a 5 até obter um erro mínimo ou até obter o número de iterações desejadas
-

3.5 Floresta Aleatória para classificação

“Floresta Aleatória” (FA) é um algoritmo de aprendizado supervisionado que pode ser utilizado para classificação e regressão. O algoritmo é baseado em uma coleção de árvores de decisão [46].

Uma árvore de decisão é representada por uma árvore invertida, composta por nós, representado por atributos, e ramos, representado pelos valores dos atributos, e folhas, representando os rótulos ou classes. A partir do nó principal ou raiz, percorre-se os ramos até chegar às folhas. Isto é, é uma representação do fluxo de um processo de decisão. A comunidade de AM desenvolveu métodos para aprender árvores de decisão, tanto para classificação como para regressão.

Assim, uma FA é composta por um conjunto de árvores de decisão; as árvores são construídas durante o treinamento da FA. A FA resultante, classifica a entrada como a moda (a classe de maior frequência) observada nas saídas das árvores de decisão que a compõe. No caso do uso de regressão, pondera-se as saídas das árvores. As árvores que compõem a floresta são obtidas a partir da escolha aleatória de um conjunto de atributos que poderá ser usado para construir cada árvore.

Uma FA envolve as técnicas *bootstrap aggregating* ou *bagging*. O *bootstrap* é um método de reamostragem. O *bagging* é o emprego de reamostragem para gerar conjuntos de dados aleatórios com substituição, isto é, com elementos diferentes. Esses são usados no aprendizado de árvores de decisão.

De outra forma, o *bagging* é usado para gerar diferentes conjuntos de amostras *bootstrap*, a partir do conjunto original de dados de treinamento. Cada amostra gera um modelo de classificação ou regressão diferente, e uma árvore distinta é aprendida – cada uma é treinada de forma independente. A FA resulta do emprego combinado das árvores.

Seja o conjunto de dados $D = (X, Y)_{1:n}$, sendo X e Y vetores com as entradas e as saídas e há n pares (X, Y) ; sorteia-se aleatoriamente B conjuntos de $m < n$ amostras do conjunto de instâncias original, que indicados por Z_1, Z_2, \dots, Z_B . Cada um deles é usado para aprender um modelo (árvore de decisão), essas são potencialmente diferentes. Ou seja, para cada amostra *bootstrap* $Z_{b,b=1,2,\dots,B}$ um preditor $\hat{y}_i^b = f^b(x_i)$ é ajustado. O Algoritmo 2 sintetiza este procedimento.

A predição da FA é dada por:

$$\hat{y}_i = f_{bag}(X_i) = \frac{1}{B} \sum_{b=1}^B f^b(X_i). \quad (4)$$

No caso de classificação, a soma na equação acima é substituída pela classe mais frequente, a moda dentre os $f^b(X_i)$.

Algoritmo 2: Pseudocódigo FA

1. Definições:
 2. D : um conjunto de dados com p atributos
 3. Q_m : métrica de pureza
 4. d_{max} : profundidade máxima de um nó
 5. B : número de árvores
 6. m : quantidade de atributos para split
 7. Entrada: Q_m, B, d_{max}, D
 8. para $b = 1$ até B faça
 9. Amostre os dados de treinamento utilizando o mecanismo de Bootstrap a partir de D
 10. Cresça a árvore utilizando o conjunto amostrado, repetindo até que
 11. Selecione aleatoriamente m atributos do total de p existentes
 12. Maximize o split do nó
 13. Divida o nó em dois filhos nós
 14. fim para
 15. Saída: o modelo de Floresta Aleatória f_{bag}
-

3.6 eXtreme Gradient Boosting (XGBoost) para classificação

O *eXtreme Gradient Boosting* (XGBoost) é baseado na técnica de *gradient boosting machine* (GBM). O método é um conjunto de algoritmos reunidos na forma de biblioteca implementada para extrair o máximo de performance das arquiteturas computacionais existentes [48].

O termo *boosting* se refere ao uso de um conjunto de classificadores fracos (superiores a uma decisão aleatória, mas fracamente correlacionados com a entrada) pode ser capaz de prover um classificador forte. O algoritmo de *Gradient boosting* visa então obter um modelo preditor (classificador ou regressor, o que muda entre eles é como as saídas são interpretadas) formado por uma amostra de modelos (em geral, também árvores de decisão). Similarmente, o XGBoost é também aderente a uma ampla variedade de aplicações (que demandem regressão ou classificação) utilizando o aprendizado supervisionado.

O XGBoost é um método em que um conjunto de modelos é treinado sequencialmente, sendo que o modelo obtido na iteração t tem como objetivo corrigir os erros do modelo $t - 1$, por meio da combinação de técnicas que produzem resultados superiores com menos recursos de computação e em menor período, tal como mostra a Figura 8 [49].




Figura 8 – Comparação do XGBoost e outros métodos.

Seja o valor alvo como y_i e \hat{y}_i^t sua predição pelo t -ésimo modelo em função da entrada x_i . Seja l uma função de erro e n é o número total de amostras avaliadas, o erro do modelo na iteração t é dado por:

$$L^t = \sum_{i=1}^n l(y_i, \hat{y}_i^t). \quad (5)$$

No XGBoost constroem-se modelos iterativamente, onde a predição obtida na iteração t é igual à da iteração $t - 1$ somada à fornecida pelo novo modelo f^t . Isso é obtido usando o gradiente de L^t . No processo, emprega-se um termo de regularização $\Omega(F^t)$, sendo F^t o conjunto de modelos na iteração t , para controlar a complexidade do modelo, que opera removendo árvores ou *ramos* com pouca importância no resultado obtido [31] [50].

Resumidamente, se f^t é o modelo incluído na iteração t tem-se

$$\hat{y}_i^t = \hat{y}_i^{t-1} + f^t(x_i) \quad (6)$$

$$L^t = \sum_{i=1}^n \hat{y}_i^{t-1} + f^t(x_i); \quad (7)$$

$$L^t = \sum_{i=1}^n \hat{y}_i^{t-1} + f^t(x_i) + \Omega(F^t), . \quad (8)$$

O XGBoost busca que cada árvore adicionada ao modelo torne o conjunto mais assertivo [48]. Para isso, emprega-se a minimização da equação 11.

4 SISTEMA PROPOSTO

Nesta sessão serão apresentados os dados de entrada para o classificador desenvolvido e como serão avaliados os classificadores obtidos.

4.1 Proposta

Este trabalho propõem um sistema de classificação que pode ser desmembrado, para fins explicativos, nas três partes apresentadas na Figura 9: entrada dos dados, classificador, target e a aferição dos modelos. Os dados de entrada são compostos por Indicadores de Rede (IR), Indicadores de Qualidade (IQ) e Indicadores de Negócio (IN), e no treinamento tem-se como parte do modelo de classificação os dados da pesquisa NPS de cada cliente, que serão utilizados como rótulo no treinamento supervisionado; o classificador deve produzir uma estimativa da classe a que um dado cliente pertence.

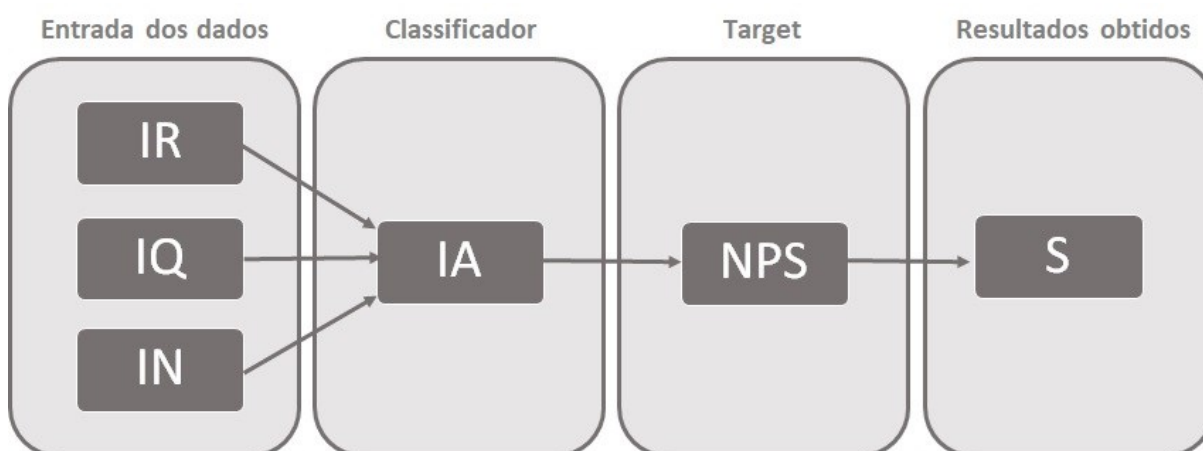


Figura 9 – Sistema proposto em diagrama de blocos.

Neste trabalho, foram avaliadas três abordagens de classificadores para classificar o NPS de clientes a partir dos indicadores: RNA MLP, Floresta Aleatória e XGBoost. Os dados (indicadores) de entrada empregados estão detalhados na Tabela 1, apresentada na Seção 37.

Para projeto e avaliação de cada um dos classificadores, seguiu-se os passos apresentados na Figura 10, havendo diferenças nos algoritmos e nas classificações de clientes a partir do NPS (sua separação em duas ou três classes).

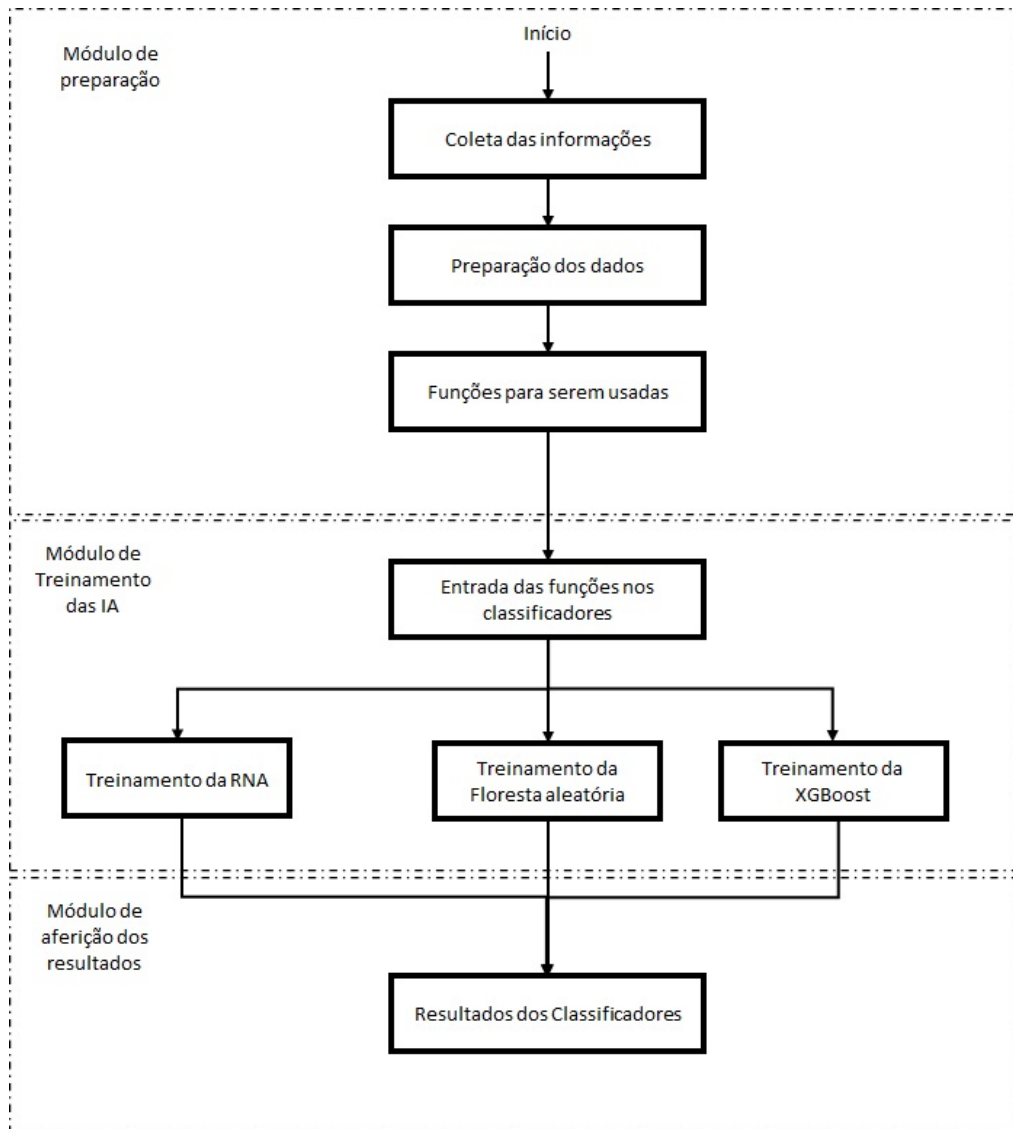


Figura 10 – Estudo de caso proposto

Neste trabalho a coleta das informações são realizadas através de ferramenta que monitora a rede fim a fim apresentado com detalhes na Seção 3.2. A preparação dos dados e a definição das funções para serem usadas são feitas em um *data lake*. Um *Data Lake* é definido como um grande repositório que armazena imenso volume de dados em sua forma bruta, que contém dados de forma não estruturada e não há uma hierarquia ou organização entre os dados individuais [51]. Todos os indicadores IR e IQ foram coletados do sistema apresentado na Figura 11, ver a discussão na Seção 3.2.

4.2 Dados empregados

O conjunto de dados de entrada dos classificadores é composto por indicadores e os dados de saída correspondentes são os da pesquisa NPS, apresentados na Seção 19. Os indicadores são:

- a) Indicadores de Rede: aferem o funcionamento dos elementos de rede;
- b) Indicadores de Qualidade: aferem a qualidade no uso das aplicações;
- c) Indicadores de Negócio: aferem questões de negócio, tais como quantos dias faltam para terminar o plano de fidelização de um cliente.

O conjunto composto por IR e IQ foram coletados a partir de uma ferramenta que monitora a rede fim a fim, sendo composto de *Network Performance Management* (NPM), de *Service Quality Management* (SQM) e *Customer Experience Management* (CEM). Existem diversas ferramentas de monitoramento fim a fim de rede providos por diferentes empresas – como Ericsson, Huawei e Nokia, utilizadas em operadoras em todo o globo.

A ferramenta utilizada pela operadora permite a pesquisa multidimensional de indicadores e analisa as causas principais de falhas de serviço com base nos fluxos de mensagens de sinalização por usuário, garantindo, assim, a rápida coleta das informações para compor os indicadores como apresentado na Figura 11.

A ferramenta adota a arquitetura de modelagem de serviço e visualização de dados mostrada na Figura 11. Essa modelagem foi apresentada pela Huawei [52]. A primeira camada do sistema apresentado na Figura 11 é composta pelos pontos de coleta das informações: as interfaces entre os equipamentos da rede móvel; posteriormente, a segunda camada do sistema, os dados são armazenados em tempo real. A terceira camada é a mediação que realiza o processamento dos dados e sua disponibilização nas bases de dados a que aplicações NPM, SQM e CEM acessam.

Os indicadores de Negócio foram selecionados do sistema de *Customer Relationship Manager* (CRM) da empresa. O CRM é um sistema informatizado de gestão de relacionamento com os clientes e é um dos principais tópicos da tecnologia em gestão comercial de operadoras. No CRM, ficam armazenados dados de contatos,

de clientes, de *prospects*, de contratos, *leads*, *muitos deles com informações pessoais dos clientes*.

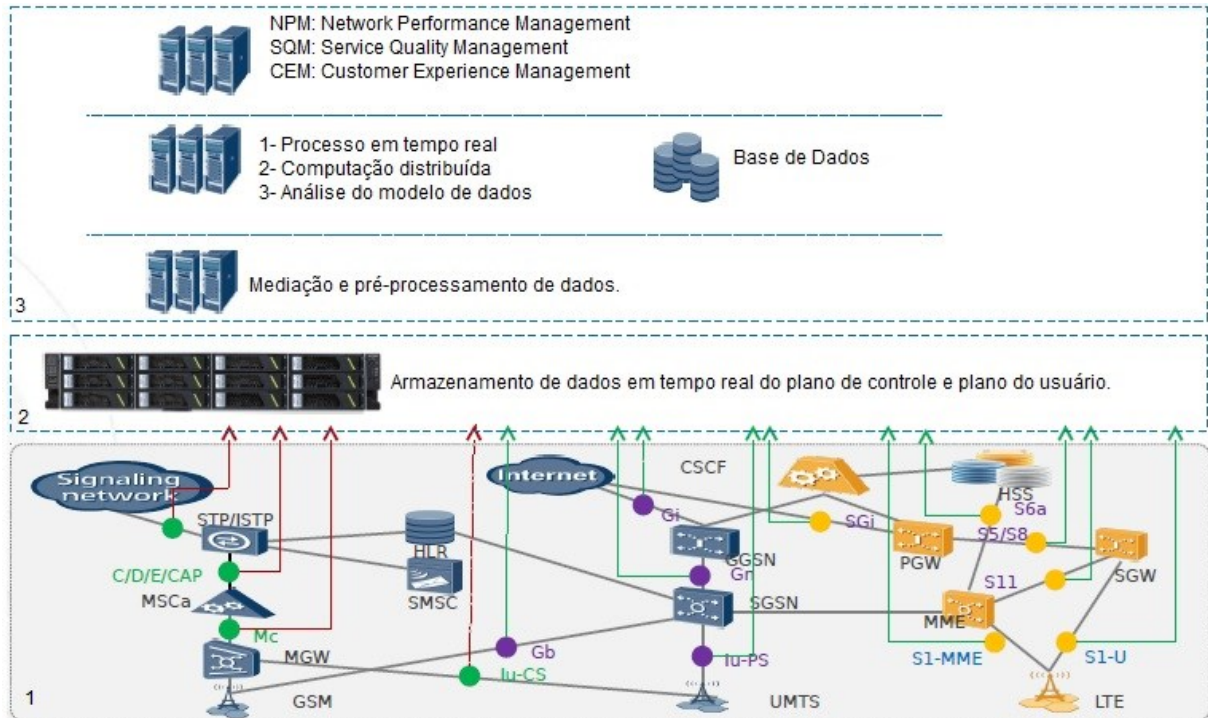


Figura 11 – Sistema de coleta dos indicadores IR e IQ Huawei Full Scale Data Collection [52]

O período de coleta de dados durou um mês, o mês de realização da pesquisa NPS. Em total, dispunha-se de 190 funções/indicadores. Consequentemente, realizou-se um processo de seleção de variáveis com o objetivo de selecionar aquelas que a princípio possibilitariam projetar classificadores melhores. Para isso, foi treinado um classificador XGBoost que é capaz de avaliar *feature importance*. Com essa foram selecionados 27 indicadores que são os utilizados nos três modelos.

Os indicadores utilizados neste trabalho constam na Tabela 1. A Tabela 1 contém a quantidade de amostras e os nomes de cada indicador utilizado nos projetos dos classificadores; além disso, para cada um, ela traz a média (*mean*), o desvio padrão (*std*), o valor mínimo (*min*) e o máximo (*max*), além dos percentil 25 (25%), 50 (50%) e (75%).

Tabela 1 – Dados empregados

Índice	Função	Tipo	mean	std	min	25%	50%	75%	max
1	qt_dias_restante_fidelizacao	IN	131,23	147,39	-778,00	0,00	123,00	259,00	603,00
2	trafego_ransharing_sem_cota	IN	194.620.064,60	744.688.996,64	0,00	0,00	515.960,50	83.433.475,00	27.093.160.487,00
3	rend_percap_mensal	IN	0,04	0,07	0,00	0,00	0,01	0,04	0,60
4	vl_pag_sum_3m_tt	IN	128,57	171,10	0,00	0,00	70,00	208,58	3.658,38
5	vl_atr_sum_3m_tt	IN	16,73	119,90	0,00	0,00	0,00	0,00	6.029,85
6	mean_worst_rtt_operadora_3g	IQ	510,43	509,35	0,00	250,50	385,84	615,28	41.173,70
7	mean_worst_rtt_operadora_4g	IQ	106,86	253,02	0,00	0,00	0,00	137,36	14.171,88
8	mean_worst_rtt_ransharing_2g	IQ	227,03	1.446,49	0,00	0,00	0,00	0,00	82.500,00
9	mean_worst_rtt_ransharing_3g	IQ	196,72	729,57	0,00	0,00	0,00	0,00	30.604,66
10	mean_worst_rtt_ransharing_4g	IQ	47,71	250,28	0,00	0,00	0,00	0,00	16.363,67
11	pct_video_0_400	IQ	0,18	0,24	0,00	0,00	0,08	0,25	1,00
12	pct_video_400_700	IQ	0,07	0,11	0,00	0,00	0,03	0,11	1,00
13	pct_video_700_1000	IQ	0,06	0,10	0,00	0,00	0,03	0,09	1,00
14	pct_video_1000_2000	IQ	0,13	0,15	0,00	0,00	0,10	0,20	1,00
15	pct_video_2000_plus	IQ	0,45	0,32	0,00	0,14	0,47	0,72	1,00
16	worst_tp_mean	IQ	1.373,44	2.240,42	0,00	127,49	614,16	1.620,46	59.839,50
17	avg_changes_3g_4g	IR	30,81	29,48	0,00	8,26	25,40	44,78	607,26
18	avg_changes_operadora_ransharing	IR	5,44	13,79	0,00	0,00	0,41	5,26	1.058,00
19	total_pct_airtime	IR	0,04	0,08	0,00	0,00	0,01	0,03	1,00
20	trafego_total	IR	6.703.511.059,48	6.594.081.141,24	1.523,00	2.338.076.513,75	4.805.202.241,00	8.862.737.651,75	154.649.066.154,00
21	pct_uso_4g_operadora	IR	0,52	0,36	0,00	0,09	0,64	0,84	1,00
22	pct_uso_2g_ransharing	IR	0,00	0,01	0,00	0,00	0,00	0,00	1,00
23	pct_uso_3g_ransharing	IR	0,02	0,08	0,00	0,00	0,00	0,00	1,00
24	pct_uso_4g_ransharing	IR	0,03	0,09	0,00	0,00	0,00	0,01	1,00
25	pct_uso_3g_operadora	IR	0,43	0,35	0,00	0,13	0,30	0,77	1,00
26	traffic_volume_3g	IR	2.163.243.926,46	3.620.499.610,30	0,00	72.685.291,00	895.216.540,00	2.604.115.440,75	94.991.296.653,00
27	traffic_volume_4g	IR	2.810.684.054,39	4.614.125.546,60	0,00	0,00	792.459.646,50	3.945.031.733,00	119.351.430.243,00
28	classe	NPS	0,43	0,71	0,00	0,00	0,00	1,00	2,00

O IN *qt_dias_restante_fidelizacao* apresenta a quantidade de dias restantes para o término do período contratual. O indicador igual ou inferior a zero significa que o cliente não se encontrava mais em período de fidelização e podia cancelar o plano sem cobrança de multa. O indicador maior que zero significa que o cliente ainda se encontrava em período de fidelização e pagaria multa caso cancelasse o pacote contratado.

O IN *trafego_ransharing_sem_cota* afere o tráfego utilizado pelo cliente na rede compartilhada de outra operadora, após o cliente ter consumido todo o pacote que havia contratado.

O IN *rend_percap_mensal* mostra a renda mensal do cliente informada no sistema de CRM da operadora.

O IN *valor_pag_sum_tt* é o valor faturado do cliente durante o período de coleta.

O IN *valor_atr_sum_tt* é o valor a faturar pelo cliente durante o período de coleta.

Os IQs designados *mean_worst_rtt* representam a média dos piores RTT mapeados dos clientes que utilizaram a rede da operadora ou a rede compartilhada nas diferentes gerações da telefonia celular durante o período de coleta.

Os IQs designados *pct_video* têm valores normalizados e aferem o throughput dos clientes que utilizaram os serviços de vídeo no YouTube separados por cinco

faixas: 0 a 400 kbps, 400 a 700 kbps, 700 a 1000 kbps, 1000 a 2000 kbps e acima de 2000 kbps.

O IR *avg_changes_3g_4g* afere as mudanças dos clientes entre as tecnologias 3G e 4G. Quando esse indicador tem um valor muito alto para um cliente, é possível inferir que o cliente teve problemas de cobertura.

O IR *avg_changes_operadora_ransharing* afere a quantidade de vezes que o cliente mudou entre a rede da operadora e o *Ran Sharing*, que é o compartilhamento de redes entre operadoras. Um baixo valor significa que o cliente utilizou pouco a rede compartilhada.

O IR *total_pct_airtime* representa o tempo que cada cliente ficou conectado à rede móvel. Com essa função, é possível identificar em quais células o cliente fica mais conectado, assim como quais são os pontos de maior interesse do cliente, como sua casa e seu trabalho, por exemplo.

O IR *trafego_total* representa o tráfego total utilizado pelo cliente durante o período de coleta.

Os IRs *pct_uso* medem as porcentagens de uso do cliente em cada tecnologia e na rede compartilhada. Por exemplo: se o valor do *pct_uso_4G* for o maior, significa que o cliente acessou a rede com a tecnologia 4G e, teoricamente, deveria ter tido uma melhor experiência de uso.

Os IRs indicador *traffic_volume* representam os volumes de tráfego enviado e recebido nas redes 4G e 3G da operadora.

A proposição deste trabalho é avaliar se aprendizado de máquinas pode ser usado para a avaliação da satisfação de clientes de operadoras de telecomunicação por meio de indicadores de rede, indicadores de qualidade e indicadores de negócio.

4.3 Avaliação dos classificadores

Para a avaliação do desempenho dos classificadores, neste trabalho foram utilizadas as métricas *Acurácia*, *Recall*, *Precisão*, *F1-Score* e *Receiver Operating Characteristic Curve* (Curva ROC), pois estas métricas são descritas como as mais utilizadas algoritmos de classificação conforme observado em [45]. A matriz de confusão apresenta as frequências de classificação para cada classe do modelo, comparando as classes efetivas com as classes previstas pelo modelo.

A acurácia mostra o quanto o modelo acertou, considerando todas as classes envolvidas. É definida pela razão entre o somatório das previsões corretas (verdadeiros positivos e verdadeiros negativos) sobre o somatório das previsões solicitadas ao classificador, conforme:

$$Acurácia = \frac{\text{previsões corretas}}{\text{todas as previsões}} = \frac{TP+TN}{TP+FP+TN+FN}. \quad (9)$$

Na expressão matemática 9, TP é o número de verdadeiros positivos, TN é o número de verdadeiros negativos, FN são os falsos negativos e FP são os falsos positivos.

O índice conhecido como *recall* indica qual proporção de positivos foi identificada corretamente e é definido como a razão entre a quantidade de verdadeiros positivos sobre a soma de verdadeiros positivos e falsos negativos

$$Recall = \frac{TP}{TP+FN}. \quad (10)$$

A precisão é definida como a taxa de acertos positivos dentre os classificados como positivos, é assim dada por

$$Precisão = \frac{TP}{TP+FP}. \quad (11)$$

O índice F_score é a média harmônica entre recall e precisão:

$$F_{SCORE} = 2 \times \frac{Precisão \times Recall}{Precisão + Recall}. \quad (12)$$

A Curva ROC, ilustrada na Figura 12, exhibe o desempenho de um sistema classificador e indica o quanto o modelo é capaz de distinguir ou discriminar as classes. Ela contrapõe a Taxa de Verdadeiro Positivo (TPR) e a Taxa de Falso Positivo (FPR), nos eixos x e y , como mostra a Figura 12. O gráfico ROC é denominado gráfico de sensibilidade vs (1 -especificidade). A sensibilidade é definida como a taxa de acertos positivos dentre todos os positivos. A especificidade considera a fração de classes negativas corretamente identificadas e é usada para medir a fração de padrões negativos que são classificados corretamente.

Um modelo de classificação pode ser representado por um ponto no espaço ROC. Para se obter o ponto no espaço ROC correspondente a um modelo de

classificação, calcula-se a taxa de verdadeiros e falsos positivos desse modelo. O melhor classificador é aquele mais próximo do canto superior esquerdo (1,1). Nesse ponto, têm-se 100% de sensibilidade e 100% de especificidade. A Curva ROC foi obtida utilizando Python.




Figura 12 – Exemplo de Curva ROC.

5 RESULTADOS

Nesta dissertação, são considerados dois cenários: i) três classes clientes: Promotor, Detrator e Neutro e ii) possível *churn* ou *no-churn*; eles são obtidos a partir da pesquisa NPS, conforme descrito na Seção 2.1. Os classificadores projetados empregam os dados descritos na Seção 3.2 para classificar os clientes da operadora usando esses dois cenários. Os índices definidos na Seção 3.3 são empregados para comparar os desempenhos dos classificadores obtidos.

Metodologicamente, de forma a prover resultados mais confiáveis, para todas as técnicas e cenários, projetam-se e aferem-se 10 classificadores. Assim, os gráficos que apresentam os resultados trazem: a) os valores pontuais de cada uma das 10 rodadas, b) as médias correspondentes, e c) os intervalos de confiança usando barras horizontais. Essa forma de apresentação é empregada para cada uma das métricas de avaliação de desempenho consideradas.

5.1 RNA projetada

Neste trabalho, uma RNA foi usada para implementar um classificador, com três classes, em que uma das classes será associada à resposta coletada na pesquisa NPS, conforme apresentada na Figura 2 e outra para o classificador de duas classes (os grupos extremos da pesquisa apresentados na Figura 3). Os dois classificadores treinados possuem as mesmas características, porém diferentes quantidades de classes de saída (duas ou três). O classificador de duas classes classifica os clientes entre *churn* ou *no-churn*, enquanto o classificador de três classes enquanto o classificador de três classes o faz entre detratores, neutros ou promotores.

Entre as funções de ativação mais frequentemente utilizadas nos últimos anos, destaca-se a função de ativação linear retificada *Rectified Linear Unit* (ReLU) e foi utilizada neste trabalho conforme apresentador na Figura 13. A função de ativação ReLU é representada respectivamente, pelas equações (4) e (5), por [44].

$$ReLu(x) = \max(0, x); \quad (13)$$

$$ReLu(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{c. c.} \end{cases} \quad (14)$$

Toda RNA com função de ativação ReLU tem vantagem no desempenho computacional devido à facilidade de cálculos computacionais [44], pois proporciona um aprendizado rápido e um custo operacional mais baixo [44].

A função *SoftMax* é muito útil em casos com problemas de classificação, pois transforma as saídas em valores entre 0 e 1 e foi utilizada neste trabalho conforme apresentador na Figura 13. A função *SoftMax* é descrita por [35]:

$$\text{SoftMax}(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}. \quad (15)$$

A função *SoftMax* descrita acima foi utilizada na saída. O resultado é um vetor que pode ser interpretado como a distribuição de probabilidade de a entrada pertencer a cada uma das classes representadas pelas saídas correspondentes. Pode-se observar que a função *SoftMax* gera uma única classe para cada elemento de entrada.

A RNA utilizada nesta dissertação foi projetada recebe todos os indicadores apresentados na Tabela 1 na entrada do modelo. Possui duas camadas ocultas com a função de ativação ReLU com quatro neurônios. A camada de saída é utilizada a função de ativação *SoftMax*, como apresentado na Figura 13. A RNA foi programada em *Python* [51] com importação das bibliotecas básicas *pandas* [53] e *numpy* [54], além das as bibliotecas de visualização de dados *matplotlib* [55] e *seaborn* [56] utilizando a biblioteca *keras*. Para chegar ao modelo 4-4-1 da RNA, foram-se acrescentando neurônios nas camadas até que o resultado aferido não tivesse alterações positivas nos resultados do modelo. Neste trabalho, é utilizado o modelo sequencial para construção da RNA. Para criar as camadas de entrada, a camada oculta e a camada de saída da RNA é utilizada a biblioteca *dense*.

O conjunto de dados de teste é composto por 30% de todo o conjunto de dados, detalhado no código em *Python*.

Posteriormente, na saída da RNA tem-se um vetor que pode ser interpretado como a probabilidade de a entrada pertencer a cada uma das classes representadas pelas saídas correspondentes.




Figura 13 – Rede Neural utilizada na simulação.

Os conjuntos de amostras de treinamento são os apresentados na Figura 9 e na Figura 10 e a proporção de treino foi de 70% da base de dados e 30% com testes. A quantidade de épocas usadas para separar o treinamento em fases distintas também é a mesma para os dois classificadores. Os classificadores utilizam a entropia cruzada que é usada para quantificar a diferença entre duas distribuições de probabilidade. Vale ressaltar que na fase de validação de uma RNA é utilizado o critério da parada antecipada para, durante a escolha dos hiperparâmetros, prevenir a ocorrência do *overfitting*. Para aferir os resultados da RNA utilizada, foram calculados os resultados das métricas apresentadas no sistema proposto na Seção 40.

5.2 Resultados obtidos com RNA

A Figura 14 e a Figura 15 mostram os resultados obtidos com a RNA; os pontos em cinza correspondem os resultados individuais de cada um dos 10 modelos para cada critério de avaliação, os círculos azuis correspondem à média e as barras azuis delimitam o intervalo de confiança.

O modelo de duas classes obteve desempenho melhores, no conjunto de métricas avaliadas. Esse resultado é explicado por ser mais simples ao ter que distinguir entre clientes nos extremos de possível detração ou não.

Contudo, percebe-se que o classificador de três classes alcança maior acurácia; isso se deve à grande parcela de amostras de detratores, que representam 69,15% de todos os pesquisados. Para a RNA a tabela que está na figura apresenta a matriz de confusão com a mediana dos 10 modelos treinados:




Figura 14 – Resultados obtidos nos treinamentos da RNA considerando as duas classes (possível detração ou não).

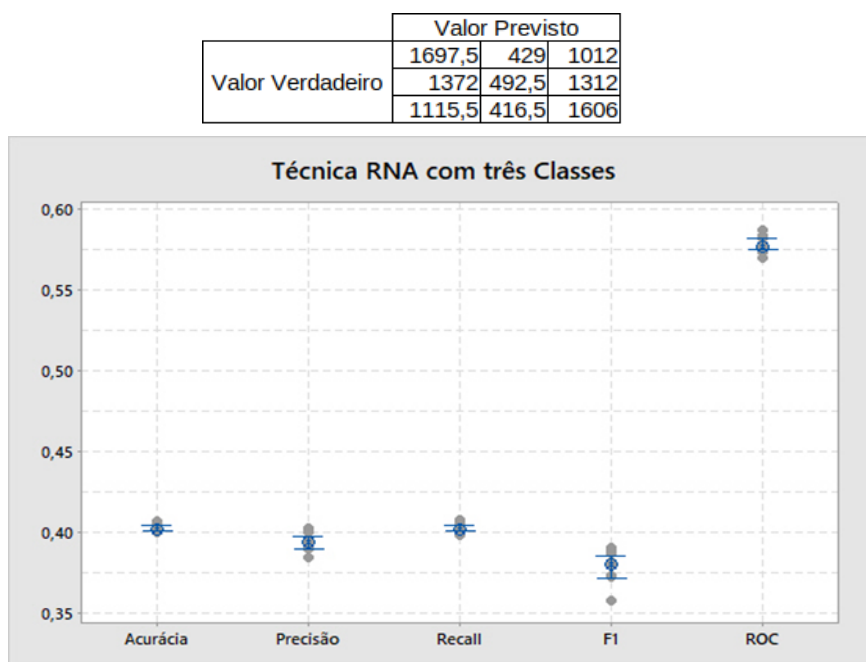


Figura 15 – Resultados obtidos nos treinamentos da RNA considerando as três classes (detrator, neutro e promotor).

5.3 Floresta Aleatória projetada

A Floresta Aleatória utilizada nesta dissertação foi projetada com 100 árvores e todos os parâmetros estão detalhados abaixo. Ela foi programada em *Python*; para isso, foram importadas as bibliotecas básicas *pandas* [53] e *numpy* [54], além das as bibliotecas de visualização de dados *matplotlib* [55] e *seaborn* [56].

Após a preparação dos dados, foi construída a Rede Floresta Aleatória utilizando o *Sklearn Ensemble* [49]. Foi importada a biblioteca *keras* para criar as camadas da rede neural. Durante o treinamento foram testadas diferentes profundidades máximas para as árvores Os hiperparâmetros usados na RFA foram:

- a) bootstrap=False
- b) ccp_alpha=0.0
- c) class_weight=None
- d) criterion='gini'
- e) max_depth=20
- f) max_features='sqrt'
- g) max_leaf_nodes=None

- h) max_samples=None
- i) min_impurity_decrease=0.0
- j) min_impurity_split=None
- k) min_samples_leaf=1, min_samples_split=2
- l) min_weight_fraction_leaf=0.0
- m) n_estimators=100
- n) n_jobs=None, oob_score=False
- o) random_state=None
- p) verbose=1
- q) warm_start=False

5.4 Resultados obtidos com Floresta Aleatória

Os valores encontrados após o treinamento da Floresta Aleatória constam na Figura 16 e na Figura 17. Essas figuras apresentam os resultados das métricas Acurácia, Precisão, *Recall*, *F1-Score* e Curva ROC com os valores dos resultados dos dez treinamentos e com o intervalo de confiança. O modelo de duas classes apresentou os melhores resultados em todas as métricas. Para a FA a tabela que está na figura apresenta a matriz de confusão com a mediana dos 10 modelos treinados:




Figura 16 – Resultados obtidos nos treinamentos da RFA considerando as duas classes (possível detração ou não).




Figura 17 – Resultados obtidos nos treinamentos da RFA considerando as três classes (detrator, neutro e promotor).

5.5 Resultados obtidos com XGBoost

O classificador XGBoost utilizado nesta dissertação foi desenvolvido em *Python*; para isso, foram importadas as bibliotecas básicas *pandas* [53] e *numpy* [54], além das bibliotecas de visualização de dados *matplotlib* [55] e *seaborn* [56]. Após a importação das bibliotecas, foi necessário importar o *dataframe*, que é o arquivo com todos os dados dos indicadores utilizados para treinamento do modelo, apresentados na Tabela 1. Após a preparação dos dados, o XGBoost foi construído com *keras*. Durante o treinamento, foram testados diferentes níveis da profundidade máxima da árvore: após realizar diversos treinamentos com o parâmetro *max_depth* igual a dez, foi possível obter os melhores resultados. Todos os hiperparâmetros usados na RFA são:

- a) *base_score*=0.5
- b) *booster*='gbtree'
- c) *colsample_bylevel*=1
- d) *colsample_bynode*=1

- e) `colsample_bytree=1`
- f) `gamma=0`
- g) `learning_rate=0.1`
- h) `max_delta_step=0`
- i) `max_depth=10`
- j) `min_child_weight=1`
- k) `missing=None`
- l) `n_estimators=100`
- m) `n_jobs=1`
- n) `nthread=None`
- o) `num_class=2`
- p) `objective='multi:softmax'`
- q) `random_state=0`
- r) `reg_alpha=0`
- s) `reg_lambda=1`
- t) `scale_pos_weight=1`
- u) `seed=None`
- v) `silent=None`
- w) `subsample=1`
- x) `verbosity=1`

5.6 Resultados obtidos com XGBoost

As métricas dos classificadores obtidos constam na Figura 18 e na Figura 19, que apresentam os resultados das métricas Acurácia, Precisão, *Recall*, *F1-Score* e Curva ROC. O modelo de duas classes apresentou os melhores resultados. Para a XGBoost a tabela que está na figura apresenta a matriz de confusão com a mediana dos 10 modelos treinados:




Figura 18 – Resultados obtidos nos treinamentos do XGBoost considerando as duas classes (possível detração ou não).




Figura 19 – Resultados obtidos nos treinamentos do XGBoost considerando as três classes (detrador, neutro e promotor).

5.7 Análise comparativa entre os classificadores

A Figura 20 compara os resultados obtidos com os classificadores de clientes possíveis *churn* ou não (duas classes); enquanto a Figura 21 compara os resultados obtidos com os classificadores de três classes (promotor, neutro e detrato).

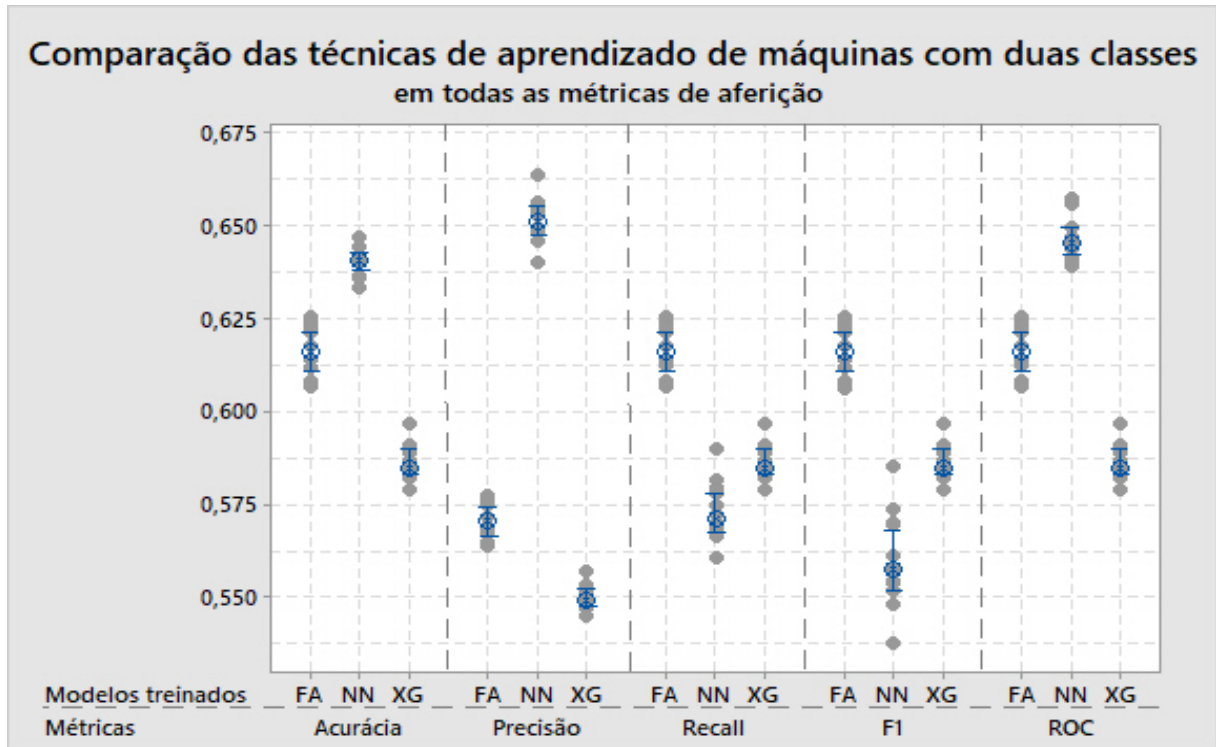


Figura 20 – Comparação entre os classificadores de duas classes (possível detração ou não).




Figura 21 – Comparação entre os classificadores de três classes (detrator, neutro e promotor).

Comparando os modelos para duas classes, o XGBoost apresenta o melhor resultado em praticamente todas as métricas utilizadas para verificar a qualidade dos modelos.

Contrapondo os modelos para três classes, XGBoost e RNA apresentam bons resultados em diferentes métricas. Contudo, a RNA apresenta o melhor resultado nas métricas *Acurácia* e *Recall* utilizadas para verificar a qualidade do modelo. Sendo assim, para três classes, a RNA apresenta-se como o melhor modelo a ser utilizado.

Usando qualquer um dos modelos pode-se ajudar uma operadora a melhorar a percepção dos clientes a partir do entendimento que eles conferem sobre a satisfação dos clientes e da possibilidade de prever mudanças na satisfação/percepção do cliente que pode advir de alterações de alguns indicadores chave. Porém, a RNA, embora proporcione bons resultados, não permite saber diretamente quais os indicadores que acarretam maior impacto no resultado. Isto é, quais dos parâmetros avaliados tem maior influência na saída do classificador. Por outro lado, as metodologias em árvore possuem essa funcionalidade. Ela pode orientar as decisões das empresas de telecomunicações.

5.8 Indicadores de rede apontados como ofensores

O XGBoost e a Floresta Aleatória que possuem o *feature importance* foram treinados por diversas vezes para aferir quais funções afetam diretamente a experiência do cliente. A Figura 22 apresenta os indicadores que mais afetam os clientes entre possível *churn* ou não e a Figura 23 apresenta os indicadores que mais afetam o NPS.




Figura 22 – Resultado das funções apresentadas pelo XGBoost para duas classes (possível detração ou não).




Figura 23 – Resultado das funções apresentadas pelo XGBoost para três classes (detrator, neutro e promotor).

As funções apontadas pelos modelos foram efetivamente utilizadas pela operadora para investigação de problemas na rede. Foi possível realizar um trabalho de ajuste na rede considerando as funções apontadas pelos modelos. O trabalho realizado na rede está fora do escopo desse trabalho. Porém, cumpre apresentar quais os indicadores foram alvo dos ajustes:

- a) avg_changes_3g_4g;
- b) mean_worst_rtt_3g;
- c) trafego_ransharing_sem_cota;
- d) avg_changes_operadora_ransharing.

Conseqüentemente, estudou-se como ajustar a rede de forma a melhorar cada indicador. Da função *avg_changes_3g_4g*, que afere a frequência de mudanças dos clientes entre as tecnologias 3G e 4G, foram alterados parâmetros na rede para que fosse diminuído o efeito *ping pong*. Para o IR *mean_worst_rtt_3g*, foi realizada alteração no *CORE* da Rede Móvel para melhorar o RTT na rede 3G, foram realizados ajustes no tamanho do pacote TCP e alterações no compressor de vídeo. Para mexer

no IR *trafego_ransharing_sem_cota*, foram alterados os parâmetros de controle empregados no *ransharing*. Para o IR *avg_changes_operadora_ransharing*, alterou-se a migração para a rede parceira, realizando o *ransharing* somente em último caso.

A partir disso, foi possível obter melhoria no indicador de insatisfação dos clientes da operadora, como apresentado na Figura 24. O índice de insatisfação é calculado através da resposta do NPS utilizando a métrica detratores (promotor + neutro + detrator) da seguinte maneira: $insatisfeitos = \frac{Detrator}{Detrator+Promotor+Neutro}$. A Figura 24 apresenta o Índice de Insatisfação dos clientes de maneira ponderada. O mês 06/19 corresponde a um período anterior ao trabalho de modelagem apresentado e a consequente otimização da rede; já, no mês 09/19, após essa otimização, o índice de insatisfação apresenta melhor resultado. Vale destacar que, nesta dissertação, não são mencionados os valores anteriores ao mês 06/19 e posteriores ao mês 09/19 porque não houve acesso a essas informações.




Figura 24 – Índice de insatisfação da operadora ponderado.

6 CONSIDERAÇÕES FINAIS

A indústria de telecomunicações passa por um movimento transformador, a tecnologia 5G está abrindo um campo de atuação novo para ofertas lucrativas de serviços digitais com distintos modelos de negócios para consumidores e clientes empresariais. A nova era das telecomunicações permitirá que as operadoras de telecomunicações ofereçam novos serviços digitais como entretenimento imersivo de Realidade Aumentada e Realidade Virtual, jogos multijogador com latência ultrabaixa, fábricas inteligentes robotizadas e gerenciamento autônomo automotivo [58], dentre outras. Conseqüentemente, conforme surgem oportunidades de negócios, a já complexa camada de rede subjacente fica ainda mais complexa, portanto, mais exigente e demandante em termos de objetivos de gerenciamento e operação de a mesma. Nesse contexto de rápidas mudanças tecnológicas do setor de serviços de telecomunicações, faz-se necessário utilizar inteligência artificial para entender a experiência do cliente já que indicativos de que, com o 5G, o modelo atual de gerenciamento da rede estará obsoleto [59].

O presente estudo fornece informações empíricas valiosas que podem ajudar a tomar decisões estratégicas visando a satisfação e retenção de clientes. Para serem competitivos no mercado de telecomunicações, os provedores de serviços móveis precisam antever possíveis problemas e tomar medidas proativas de melhorias contínuas e de retenção de clientes. Neste trabalho, foi proposta a utilização de diferentes métricas de rede, de negócio e de aplicações para a construção de um modelo preditivo do NPS e da possibilidade de *churn*. Métodos como o apresentado podem auxiliar as empresas na formulação de estratégias adequadas à retenção de clientes.

A proposta deste trabalho foi aplicada em dados reais disponibilizados por uma operadora. Foi possível verificar o desempenho da proposta com classificadores projetados usando RNA, FA e *XGBoost* onde a RNA apresentou o melhor resultado para o modelo de duas classes.

Quando projetamos classificadores FAs e *XGBoost* foi possível investigar quais são os indicadores que tiveram correlação com os problemas de detração (*churn*) a partir do processo de treinamento do classificador; isso permite tanto aplicar melhorias na rede que visem melhorar esses indicadores como estabelecer

procedimentos para manter um controle mais firme desses indicadores. No caso, a partir desse estudo, a operadora que disponibilizou os dados, realizou alterações na rede para melhoria dos indicadores a partir dessa análise que levou a uma melhoria no NPS da empresa.

7 REFERÊNCIAS

- [1] CISCO visual networking index: global mobile data traffic forecast update, 2016-2021: technical report white paper. 2017.
- [2] LEMMENS, A.; SUNIL, G. Managing churn to maximize profits. *Marketing Science*, [preprint (no prelo)], 2020.
- [3] LAGHARI, K. U. R.; CONNELLY, K. Toward total quality of experience: a QoE model in a communication ecosystem. *IEEE Communications Magazine*, v. 50, n. 4, p. 58–65, 2012.
- [4] KOTLER, P.; ARMSTRONG, G. *Administração de marketing*. São Paulo: Atlas, 2000.
- [5] MISRA, R.; SINGH, S.; MAHAJAN, R. An empirical study on the cellular subscribers churn, selection factors and satisfaction with the services. *International Journal of Product Development*, v. 23, n. 2-3, p. 105-121, 2019.
- [6] DASGUPTA, K. et al. Social ties and their relevance to churn in mobile telecom networks. In: *Proceedings of the 11th international conference on extending database technology: advances in database technology*, p. 668-677, 2008.
- [7] AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES. Anatel. *Qualidade da telefonia móvel*. 2018.
- [8] REICHHELD, F. F. *The one number you need to grow*. Harvard business review. 2003.
- [9] SILVA, F. H. M. R.; SILVA, C. E. S.; MORAIS, N. S. A contribuição do net promoter score no processo de desenvolvimento de produtos. *Ingepro: inovação, gestão e produção*, v. 2, n. 2, 2010. Disponível em: <http://www.ingepro.com.br/Publ_2010/Fev/199-553-1-PB.pdf>
- [10] MOZER, M. C. et al. Predicting subscriber dissatisfaction and improving retention in the wireless telecommunications industry. *IEEE Transactions on neural networks*, v. 11, n. 3, p. 690-696, 2000.
- [11] SRIDHAR, K. et al. System and method for predicting and reducing subscriber churn. US Patent Application nº 16/598,112, 10 out. 2018 a 16 abr. 2020.
- [12] FANG, C.; LIN, D. Low false positive behavioral fraud detection. U.S. Patent Application nº 14/308,599, 18 jun. 2014 a 23 jul. 2034.

- [13] MARTINS JR, C. A.; LOVISOLO, L.; RUBINSTEIN, M. G. Classificação do índice de satisfação de clientes a partir de indicadores de rede móvel e de negócios utilizando redes neurais. XXXVIII Simposio Brasileiro de Telecomunicações e Processamento de Sinais. SBrT2020, Florianópolis, 2020.
- [14] MILLARD, N. Learning from the “wow” factor: how to engage customers through the design of effective affective customer experiences. *BT Technology Journal*, v. 24, n. 1, p. 11-16, 2006.
- [15] CARBONE, L. P.; HAECKEL, S. H. Engineering customer experiences. *Marketing Management*, v.3, n. 3, p. 8-19, 1994.
- [16] ISLAM, M. B.; RIMA, A. R. Factors affecting customer experience in telecommunication services and its importance on brand equity: a study on telecommunication companies in Bangladesh. *Interdisciplinary Journal of Contemporary Research in Business*, v. 5, n. 8, 2013.
- [17] SANTOS, J. E-service quality: a model of virtual service quality dimensions. *Managing Service Quality: an international journal*, v. 13, n. 3, p. 233-46, 2003.
- [18] VOSS, C. Trends in the experience and service economy: the experience profit cycle. London Business School, 2004.
- [19] ALLEN, J.; REICHHELD, F. F.; HAMILTON, B.; MARKEY, R. Closing the delivery gap. In: ANAMAN, M. Toward a model of customer experience, Bain & Co., Brunel University, School of Information Systems, Computing and Mathematics, 2010.
- [20] REICHHELD, F. The ultimate question: driving good profits and true growth. Boston: Harvard Business School Press, 2006.
- [21] KEININGHAM, T. L. et al. Service failure severity, customer satisfaction, and market share: an examination of the airline industry. *Journal of Service Research*, v. 17, n. 4, p. 415-431, 2014.
- [22] CUSTOMER GAUGE. The 2018 NPS & CX benchmarks report. 2018. Disponível em: <<https://customergauge.com/benchmarks-report>>
- [23] BOMFIM, M. Na Vivo, satisfação de clientes influencia na remuneração de executivos. Exame, 2019. Disponível em: <<https://exame.abril.com.br/marketing/na-vivo-satisfacao-de-clientes-influencia-na-remuneracao-de-executivos/>>.

- [24] PINTO, L. NPS, a solução para a eficiência no atendimento ao cliente. Consumidor Moderno, 2018. Disponível em: <<https://www.consumidormoderno.com.br/2018/09/06/nps-solucao-para-eficiencia-no-atendimento-ao-cliente/>>
- [25] AQUINO, M. Presidente da Tim quer mudar imagem do setor. tele.síntese, 2018. Disponível em: <<https://www.telesintese.com.br/presidente-da-tim-quer-mudar-imagem-do-setor/>>
- [26] ERNEST & YOUNG. Top 10 risks in telecommunications: report. 2016.
- [27] SAROHA, R.; DIWAN, S. P. Development of an empirical framework of customer loyalty in the mobile telecommunications sector. Journal of Strategic Marketing, v. 28, n. 8, p. 659-680, 2020.
- [28] BHATTI, H. S.; HASSAN, T. The influence of customer experience on customer loyalty for the mobile telecommunication services. In: CONF-IRM, p. 8, 2019.
- [29] SILVA, I. N.; SPATII, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artliber, 2010.
- [30] BREIMAN, L. Random forests. Machine Learning, n. 45, p. 5-32, 2001.
- [31] XGBOOST Read the docs: introduction to boosted trees. 2020. Disponível em: <<https://xgboost.readthedocs.io/en/latest/tutorials/model.html>>
- [32] HUNG, S.; YEN, D. C.; WANG, H. Applying data mining to telecom churn management. Expert Systems with Applications, n. 31, p. 515-524, 2006.
- [33] MOUSA, A. Prospective of fifth generation mobile communications. International Journal of Next-Generation Networks (IJNGN), v. 4, n. 3, 2012.
- [34] HOLMA, H.; TOSKALA, A. WCDMA for UMTS: HSPA evolution and LTE. [S.l.: s.n.], 2010.
- [35] THE 3RD GENERATION PARTNERSHIP PROJECT. Network architecture: release 5 3GPP TS 23.002 6. 2002.
- [36] THE 3RD GENERATION PARTNERSHIP PROJECT. General packet radio service (GPRS): service description TS 23.060 v. 5,2. 2019.
- [37] SHEN, Z. et al. Overview of 3GPP LTE-advanced carrier aggregation for 4G wireless communications. IEEE Communications Magazine, v. 50, n. 2, p. 122-130, 2012.

- [38] VAS3K BLOG. Machine learning for everyone: in simple words, with real-world examples, yes, again. Disponível em: <https://vas3k.com/blog/machine_learning/>
- [39] FLECK, L. et al. Redes neurais artificiais: princípios básicos. Revista Eletrônica Científica Inovação e Tecnologia, v. 7, n. 15, p. 47-57, 2016.
- [40] ROSENBLATT, F. F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological review, v. 65 6, p. 386-408, 1958.
- [41] HAYKIN, S. Neural networks: a comprehensive foundation. Upper Saddle River (EUA): Prentice Hall, 1994.
- [42] HECHT-NIELSEN, R. Theory of the backpropagation neural network. International 1989 Joint Conference on Neural Networks, v. 1, p. 593-605, 1988.
- [43] MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. Rectifier nonlinearities improve neural network acoustic models. In: Proceedings of The International Conference on Machine Learning, v. 30, n. 1, 2013.
- [44] TENSOR FLOW core v2.2.0 just your regular densely-connected NN layer. 2020.
- [45] HOSSIN, M.; SULAIMAN, M. N. A review on evaluation metrics for data classification evaluations. International Journal of Data Mining Knowledge Management Process, v. 5, p. 1-11, 2015.
- [46] HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. The elements of statistical learning: data mining, inference, and prediction. Maastricht: Springer, 2009.
- [47] BREIMAN, L. Bagging predictors. Machine Learning, n. 24, p. 123-140, 1996.
- [48] CHEN, T.; GUESTRIN, C. Xgboost: a scalable tree boosting system. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16), p. 785–794, 2016.
- [49] MORDE, V.; SETTY, V. An. Xgboost algorithm: long may she reign! Towards data science. 2019. Disponível em: <<https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>>
- [50] SAMUDRALA, A. Unveiling mathematics behind Xgboost. Medium, 2016. Disponível em: <<https://medium.com/@samudralaajit/unveiling-mathematics-behind-xgboost-c7f1b8201e2a>>

- [51] SHARMA, K.; PATOA, S. Diving into data lakes. International Journal of Science and Research (IJSR), v. 6, n. 9, p. 1303-1308, 2017.
- [52] HUAWEI SEQ Analyst Solution. Truly managing customer experience has begun: NetProbe support full scale data collection. 2015
- [53] PANDAS Data analysis and manipulation tool with Python, 2020. Disponível em: <<https://pandas.pydata.org/>>.
- [54] NUMPY Scientific computing with Python, 2020. Disponível em: <<https://numpy.org/>>.
- [55] MATPLOTLIB Visualization with Python, 2020. Disponível em: <<https://matplotlib.org/>>.
- [56] SEABORN Statistical data visualization with Python, 2020. Disponível em: <<https://seaborn.pydata.org/>>.
- [57] ICKIN, S. et al. On network performance indicators for network promoter score estimation. In: IEEE Eleventh International Conference on Quality of Multimedia Experience (QoMEX), 2019.
- [58] NOKIA. 5G report: The value of 5G services and the opportunity for CSPs. Disponível em: <<https://www.nokia.com/networks/research/5g-consumer-market-research/>>
- [59] NOKIA. Here's how analytics are the silver bullet for 5G success to improve customer experience and employee effectiveness. 2019. Disponível em: <<https://www.nokia.com/blog/heres-how-analytics-are-the-silver-bullet-for-5g-success-to-improve-customer-experience-and-employee-effectiveness/>>