

Aluno: Josean Mario Moreira Rodrigues
Orientador: Rayner Gomes Sousa

Identificando a Capacidade da Infraestrutura 5G de Suportar *Streaming* de Vídeo Baseado na Classificação

Picos - PI
31 de julho de 2023

Aluno: Josean Mario Moreira Rodrigues
Orientador: Rayner Gomes Sousa

Identificando a Capacidade da Infraestrutura 5G de Suportar *Streaming* de Vídeo Baseado na Classificação

Trabalho de Conclusão de Curso em Bacharelado em Sistemas de Informação, Campus Senador Helvidio Nunes de Barros, Universidade Federal do Piauí, como parte dos requisitos para obtenção do Grau de Bacharel em Sistemas de Informação. Orientador: Prof. Rayner Gomes Sousa.

Universidade Federal do Piauí
Campus Senador Helvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
31 de julho de 2023

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

R696i Rodrigues, Josean Mario Moreira
Identificando a capacidade da infraestrutura 5G de suportar *Streaming* de vídeo baseado na classificação [recurso eletrônico] / Josean Mario Moreira Rodrigues - 2023.
51 f.

1 Arquivo em PDF
Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB
Aberto a pesquisadores, com restrições da Biblioteca

Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Bacharelado em Sistemas de Informação, Picos, 2023.
“Orientador : Prof. Me. Rayner Gomes Sousa”

1. Telefonia móvel 5G. 2. Streaming de vídeo. 3. Aprendizado de máquina. 4. Rede neural. 5. Classificação. I. Sousa, Rayner Gomes. II. Título.

CDD 621.385

IDENTIFICANDO A CAPACIDADE DA INFRAESTRUTURA 5G DE SUPORTAR
STREAMING DE VÍDEO BASEADO NA CLASSIFICAÇÃO

JOSEAN MARIO MOREIRA RODRIGUES

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas
de Informação.

Data de Aprovação

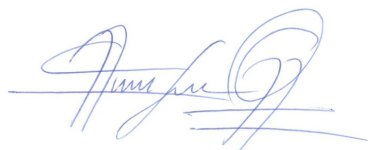
Picos – PI, 14 de agosto de 2023



Prof. Rayner Gomes Sousa



Prof. Deborah Maria Vieira Magalhães



Prof. Fredison Muniz de Sousa

Agradecimentos

Agradeço primeiramente ao professor orientador Rayner Gomes, por ajudar-me ao longo desse trabalho. Agradeço a minha avó materna, irmã, mãe e pai por sempre me motivarem a estudar, não desistir, persistir.

Basta ser sincero e desejar profundo, você será capaz de sacudir o mundo.

Raul Seixas

Resumo

A quinta geração de telefonia móvel (5G) traz grandes avanços tecnológicos para a qualidade de vida humana, sendo orientada a serviços e abrangendo vários campos, dentre eles: medicina, veículos autônomos e aplicações móveis. As redes 5G serão em grande parte utilizadas para transmissão de vídeo, o que inclui cirurgias remotas e realidade aumentada. As transmissões de vídeos em redes 5G suportam o uso de Ultra-Alta Definição que inclui vídeos em 4K e 8K, tais definições exigem uma baixa latência e uma maior vazão na transmissão dos dados pela rede. Porém, a rede apesar de ser muito robusta e complexa também está sujeita a problemas: por exemplo, a não prioridade do *uplink* quando se fala em compartilhamento de rede, em casos que exigem baixa latência como a transmissão de vídeo ou casos de intensidade do sinal e outros. Nesse caso, a classificação exerce um papel fundamental no processo de mapeamento da fatia de rede virtual, ao auxiliar na avaliação dos parâmetros de QoS requisitados pelo usuário, determinando se podem ou não ser atendidos pelo serviço de transmissão de *streaming*. Essa avaliação é de extrema importância para assegurar que a rede proporcione um desempenho adequado e atenda de forma precisa às necessidades individuais dos usuários. Nesse trabalho desenvolvemos uma abordagem capaz de analisar os parâmetros da transmissão de vídeo, tais como: latência, vazão, capacidade da rede, cobertura, largura de banda, eficiência espectral, taxa de transferência, frequência de rádio, densidade de usuários, confiabilidade, disponibilidade, mobilidade, taxa de erro de bit, capacidade da antena, conectividade IoT e sincronização de tempo. A abordagem utiliza três modelos de aprendizado de máquina e um de rede neural, cada um dos modelos utilizados conseguiu classificar em quais casos acontecem problemas na transmissão de vídeo. Em relação a acurácia e precisão os modelos de regressão logística, árvore de decisão, SVM e a RNA obtiveram os valores de (89%,97%); (99%,100%) e (66%,66%); (80%,100%) respectivamente.

Palavras-chaves: Quinta Geração de Telefonia Móvel (5G); Aprendizado de Máquina; Rede Neural; Transmissão De Vídeo; Classificação; Parâmetros de *Streaming* de Vídeo.

Abstract

The fifth generation of mobile telephony (5G) brings excellent technological advances to the quality of human life, being service-oriented and covering several fields: medicine, autonomous vehicles, and mobile applications. 5G networks will primarily be used for video streaming, which includes remote surgery and augmented reality. Video transmissions on 5G networks support the use of Ultra-High Definition that includes 4K and 8K videos, and such definitions require low latency and higher throughput in the transmission of data over the network. However, despite being very robust and complex, the network is also subject to problems: for example, the non-priority of *uplink* when talking about network sharing, in cases that require low latency such as video transmission or signal strength and others. In this case, the classification plays a fundamental role in the mapping process of the virtual network slice by helping to evaluate the QoS parameters requested by the user, determining whether or not they can be met by the *streaming* transmission service. This assessment is critical to ensure that the network provides adequate performance and accurately completes the individual needs of users. In this work, we developed an approach capable of analyzing video transmission parameters, such as latency, throughput, network capacity, coverage, bandwidth, spectral efficiency, transfer rate, radio frequency, user density, reliability, availability, mobility, bit error rate, antenna capacity, IoT connectivity, and time synchronization. The approach uses three machine learning models and one neural network; each model could classify in which cases problems occur in video transmission. Regarding accuracy and precision, the logistic regression model, decision tree, SVM, and ANN obtained values of (89%,97%); (99%,100%) and (66%,66%); (80%,100%) respectively.

Key words: Fifth Generation Mobile Telephony (5G); Machine Learning; Video Streaming; Classification; Video *streaming* parameters.

Lista de ilustrações

| | |
|------------------------------------------------------------------------|----|
| Figura 1 – Metodologia do Projeto. | 24 |
| Figura 2 – Aquitetura de Serviço no 5G. | 26 |
| Figura 3 – Resultados Métrica de Acurácia | 39 |
| Figura 4 – Resultados Métrica de Precisão | 40 |
| Figura 5 – Resultados Métrica de <i>Recall</i> | 40 |
| Figura 6 – Resultados Métrica de F1-Score | 41 |
| Figura 7 – Resultados Matriz de Confusão Regressão Logística | 41 |
| Figura 8 – Resultados Matriz de Confusão Árvore de Decisão | 42 |
| Figura 9 – Resultados Matriz de Confusão SVM | 42 |
| Figura 10 – Resultados Matriz de Confusão RNA | 43 |

Lista de tabelas

| | |
|-----------------------------------------------------------------|----|
| Tabela 1 – Trabalhos Relacionados | 20 |
| Tabela 2 – Cronograma Para Desenvolvimento Do Projeto | 26 |
| Tabela 3 – Desempenho Dos Modelos | 38 |
| Tabela 4 – Tabela de Variáveis | 43 |
| Tabela 5 – Fórmulas de Avaliação | 44 |

Lista de abreviaturas e siglas

| | |
|--------|-------------------------------------------------|
| 5G | Quinta Geração de Telefonia Móvel |
| eMBB | <i>Enhanced Mobile Broadband</i> |
| uRLLC | <i>Ultra Reliable Low Latency Communication</i> |
| mMTC | <i>Massive Machine-Type Communication</i> |
| ML | <i>Machine Learning</i> |
| QoE | <i>Quality of Experience</i> |
| UHD | <i>Ultra-High Definition</i> |
| ITU | <i>International Telecommunication Union</i> |
| 3GPP | <i>Third Generation Partnership Project</i> |
| CDN | <i>Content Delivery Network</i> |
| QoS | <i>Quality of Service</i> |
| ABS | <i>Adaptive Bitrate Streaming</i> |
| KPI | Indicadores de desempenho |
| KQI | Indicadores de qualidade |
| SVM | <i>Support Vector Machine</i> |
| RNA | Rede Neural Artificial |
| DL | <i>Deep Learning</i> |
| SDN | <i>Software-Defined Networking</i> |
| NFV | <i>Network Function Virtualization</i> |
| VANETs | <i>Vehicular Ad-Hoc Network</i> |
| KPIs | Indicadores-Chave de Desempenho |
| KQIs | Indicadores-Chave de Qualidade |
| AI | <i>Artificial Intelligence</i> |

Sumário

| | | |
|----------|----------------------------------------|-----------|
| 1 | Introdução | 13 |
| 1.1 | Objetivos | 15 |
| 1.1.1 | Objetivos Específicos | 15 |
| 1.2 | Desafios | 15 |
| 1.3 | Organização do Trabalho | 15 |
| 2 | Referencial Teórico | 17 |
| 2.1 | Quinta Geração de Telefonia Móvel (5G) | 17 |
| 2.2 | <i>Streaming</i> de Vídeo | 17 |
| 2.3 | Qualidade Experiência e de Serviço | 18 |
| 2.4 | Aprendizado de Máquina | 19 |
| 3 | Trabalhos Relacionados | 20 |
| 4 | Desenvolvimento do Projeto | 24 |
| 4.1 | Arquitetura de Serviço | 26 |
| 4.2 | Infraestrutura de Desenvolvimento | 27 |
| 4.2.1 | Python | 27 |
| 4.2.2 | <i>Google Colaboratory</i> | 28 |
| 4.2.3 | Bibliotecas | 28 |
| 4.2.3.1 | <i>Scikit-Learn</i> | 28 |
| 4.2.3.2 | <i>Keras</i> | 28 |
| 4.3 | Modelos | 29 |
| 4.3.1 | Regressão Logística | 29 |
| 4.3.1.1 | Pseudo-código | 29 |
| 4.3.2 | Árvore de decisão | 30 |
| 4.3.3 | Máquina de Vetores de Suporte | 31 |
| 4.3.3.1 | Pseudo código | 31 |
| 4.3.4 | Rede Neural Artificial | 32 |
| 4.3.4.1 | Pseudo código | 32 |
| 4.4 | Métricas | 33 |
| 4.5 | <i>Dataset</i> | 34 |
| 5 | Resultados e Discussão | 38 |
| 5.1 | Análise Gráfica dos Resultados | 39 |
| 5.1.1 | Equações Usadas nos Modelos | 43 |

| | |
|--------------------------------------------------|-----------|
| 5.2 Análise Comparativa | 46 |
| 6 Conclusão e Trabalhos Futuros | 47 |
| Referências | 49 |

1 Introdução

A [Quinta Geração do Sistema Celular \(5G\)](#) foi introduzida em vários países e tem como principal objetivo ser uma arquitetura inovadora que abrange serviços em diversas áreas. A sua arquitetura é direcionada para o suporte de três tipos de casos de uso, são elas: (1) Banda Larga Móvel Melhorada (*enhanced Mobile Broadband*, eMBB), que diz respeito à banda larga móvel com melhorias; (2) Comunicações Ultra Confiáveis e de Baixa Latência (*ultra Reliable Low Latency Communication*, uRLLC) comunicação ultra confiável com maior vazão de dados e baixa latência; (3) Comunicação Massiva de Máquinas (*massive Machine-Type Communication*, mMTC) que suporta maior demanda de máquinas conectadas ([KIMURA; ALMEIDA et al., 2021](#)). A transmissão de vídeo é um serviço que pode estar presente em qualquer um desses casos de usos e, dependendo do tipo da aplicação, ser transmitido com características diferentes.

O sistema 5G foi planejado para suportar a transmissão de vídeo de baixa latência, sendo incorporada em várias áreas, por exemplo, indústria, entretenimento, educação, ou a comunicação entre veículos para o monitoramento de pacientes em uma ambulância em movimento, que neste último caso, exige uma alta confiabilidade da rede. Uma rede sem fio confiável permite a comunicação de sistemas críticos não suportados em gerações anteriores ao 5G. No entanto, tais cenários estão sujeitos a problemas na latência de transmissão de vídeo. Cada um dos principais passos de transmissão como captura, codificação, transmissão, decodificação e exibição adicionam algum atraso e a soma destes atrasos é a latência de ponta a ponta, tal performance implica diretamente na confiabilidade da rede. Portanto, a atenção dada aos parâmetros de transmissão de vídeo é essencial ([UITTO; HEIKKINEN, 2021](#)) no sistema 5G.

O sistema 5G é baseado no conceito de programação de toda a infraestrutura de rede (em inglês este conceito é referido como *softwarization*). O conceito implica que a rede, de ponta a ponta, deve ser programável. Para a realização deste conceito o 5G é dependente de três paradigmas: (a) computação em nuvem: os serviços são mantidos na nuvem; (b) redes definidas por *software*: o comportamento da transmissão de dados pode ser gerenciado de forma centralizada e novas funções podem ser adicionadas em tempo real; (c) virtualização de funções de rede: todos os serviços são funções encadeadas e distribuídas na rede. O objetivo da incorporação destes três paradigmas na arquitetura do sistema 5G é permitir que as aplicações sejam independentes do *hardware* e dos fabricantes de equipamentos ([ORDONEZ-LUCENA et al., 2017](#)). Logo, não é mais a aplicação que tem que se adaptar a rede e, sim, a rede as aplicações.

Em decorrência da programação de rede, o 5G pode implantar redes virtuais sob demanda de forma a suportar os três tipos essenciais de casos de usos supracitados (eMBB, uRLLC e mMTC). Desse modo, o sistema 5G é flexível o suficiente para ser programado

a fim de potencializar a resolução de problemas enfrentados nas gerações anteriores. Um problema atual, decorrente da herança dos sistemas antigos, é que o sistema telefônico móvel nunca foi projetado para realizar o *streaming* nativamente, como consequência, o sistema não prioriza o *uplink* (canal de envio de dados contínuos do usuário para o sistema). A não priorização é um dos fatores para geração de gargalos na rede, ocasionando problemas em diversas áreas críticas que demandam baixa latência como, por exemplo: cirurgias remotas, veículos autônomos e entrega de dados ambientais em tempo real (UITTO; HEIKKINEN, 2022).

O uso de inteligência artificial (*Artificial Intelligence*, AI), especialmente o aprendizado de máquina (*Machine Learning*, ML) permitem que as redes móveis como o 5G possam adotar medidas que abrangem previsão e proatividade da rede (WANG et al., 2022). Os aplicativos de *streaming* atuais fornecem altos níveis de qualidade de experiência do usuário (*Quality of Experience*, QoE). Porém, maior qualidade passa a ser um grande desafio, pois a transmissão do usuário pela *Internet* pode estar sujeita a fatores como variação na largura de banda, mobilidade do usuário, variação do atraso de pacotes (*jitter*) e outros. O uso de aprendizado de máquina utilizando uma quantidade adequada de parâmetros é atraente para melhorar a estimativa de precisão e, portanto, a qualidade de transmissão de vídeos (RACA et al., 2019).

Considerando um futuro próximo, a (CISCO, 2022) disponibilizou uma série de pesquisas que apontam que até 2023 haverá mais de 13,1 bilhões dos dispositivos conectados na *Internet* por meio do 5G, isso representa mais do que de 10% dos dispositivos móveis globais atuais. Por exemplo, carros com condução autônoma são cobertos pelo sistema 5G. A assistência remota de direção oferece mais flexibilidade do que permitir que o veículo seja controlado por uma única IA. A latência da rede, o *jitter* e a qualidade da transmissão de vídeo, por exemplo vídeos em ultra alta definição (*Ultra-High Definition*, UHD) que implicam em uma resolução de imagem com no mínimo 3.840 x 2.160 *pixels*, são alguns dos desafios para o controle de veículo em tempo real, qualquer esforço que possa reduzir a latência é um aspecto muito importante (YU; LEE, 2022).

O formato de vídeo UHD é uma das demandas dos usuários quando se aborda o tema *streaming* de vídeo em redes 5G. Por esta razão, a criação de modelos que possam prever a qualidade de vídeo baseado nas suas características e configurações de codificação é essencial. O uso de ML oferece as técnicas factíveis para que os dados extraídos possam ser processados de modo a extrair informações de modo a identificar padrões que possam prever a qualidade do conteúdo audiovisual, resultando na melhora da qualidade de transmissão através da programação de rede (LÓPEZ et al., 2018).

Uma das formas de melhorar a qualidade de *streaming* é através do mapeamento da fatia de rede, este pode ser feito por agrupamento, predição e classificação que é a técnica abordada neste trabalho. Os autores (GOMES et al., 2021) e (CUNHA et al., 2021) deixam claro em suas obras que o processo de mapeamento é muito custoso em termos

de recursos e tempo, tendo a classificação um papel de suma importância no serviço de mapeamento. A classificação auxilia na avaliação dos parâmetros de QoS requisitados pelos usuários, determinando se podem ser satisfatoriamente atendidos pelo serviço de transmissão de *streaming*. Essa avaliação é crucial para assegurar que a rede ofereça um desempenho adequado e corresponda às necessidades específicas dos usuários.

1.1 Objetivos

O objetivo principal deste projeto é desenvolver uma solução para identificar se o serviço *streaming* de vídeo no 5G pode ser ofertado ou não, por meio das abordagens de aprendizado de máquina e rede neural a fim de analisar parâmetros de QoS que podem gerar problemas na conexão de *streaming*. Assim, contribuindo para que sistemas atuais e futuros possam garantir a qualidade de transmissão de vídeo.

1.1.1 Objetivos Específicos

Os objetivos específicos deste trabalho são:

- Desenvolver um *dataset* próprio no contexto de *streaming* em redes 5G.
- Identificar problemas em *streaming* de vídeo por meio de classificação.
- Realizar comparação de modelos de *Machine Learning* e rede neural a fim de identificar qual o melhor algoritmo para classificar problemas em *streaming* no 5G.
- Apresentar o rendimento dos modelos por meio de gráficos e tabelas.

1.2 Desafios

No momento da escrita desta obra, ainda existem poucas bases de dados com parâmetros de *streaming* de vídeo em rede 5G, a maior delas encontrada até então é apresentada por (QUINLAN et al., 2020). Apesar das poucas bases de dados disponíveis, existem várias obras que utilizam a base citada acima, como as apresentadas por (KIMURA; ALMEIDA et al., 2021), (MUSTAFA et al., 2020), (MUSTAFA; MOURA; ROTHENBERG, 2021), (MEHMETI; PORTA, 2021) e (GAO, 2022). Essas poucas obras evidenciam a dificuldade em reproduzir o serviço de transmissão de vídeo no sistemas 5G e da contemporaneidade do tema.

1.3 Organização do Trabalho

Este trabalho está estruturado em seis capítulos. O [Capítulo 1](#) apresenta a introdução sobre o tema central do projeto, objetivos e desafios encontrados. No [Capítulo 2](#), são

apresentados os conceitos fundamentais relacionados ao contexto do *streaming* de vídeo em redes 5G. São abordados temas como a arquitetura da rede 5G, *streaming* de vídeo, QoS e QoE e aprendizado de máquina. No [Capítulo 3](#), são apresentados os trabalhos que têm relação com o trabalho desenvolvido, e as abordagens utilizadas para identificar e solucionar os problemas de *streaming*. Cada um dos trabalhos passou por uma filtragem rigorosa. No [Capítulo 4](#), são abordadas todas as ferramentas e conceitos intrínsecos deste projeto, abordando conceitos sobre a arquitetura de serviço, infraestrutura de desenvolvimento, modelos e métricas. No [Capítulo 5](#), são apresentados os resultados através de gráficos, tabelas e matriz de confusão, além de uma análise detalhada dos resultados. No [Capítulo 6](#), é realizado o fechamento da monografia, com as considerações finais sobre todo o aprendizado ao longo do desenvolvimento e trabalhos futuros.

2 Referencial Teórico

Esta seção descreve conceitos importantes para o entendimento deste projeto. As seções incluem conceitos sobre a Quinta Geração de Telefonia Móvel. (3.1), *Streaming* de vídeo (3.2), Qualidade de experiência do usuário e Qualidade de Serviço (3.2.1), Aprendizado de máquina (3.3).

2.1 Quinta Geração de Telefonia Móvel (5G)

A Quinta Geração de Telefonia Móvel (5G) é o sistema mais recente de telecomunicação desenvolvida, o qual seu projeto e especificações ficam sobre responsabilidade da *International Telecommunication Union* (ITU) e *Third Generation Partnership Project* (3GPP). Espera-se que os sistema atinja taxas de dados entre 10 *Gbit/s* e 20 *Gbit/s*, com latência de 1 ms de ponta a ponta.

O 5G é um sistema vital para serviços emergentes, que envolvem condução autônoma, realidade virtual, realidade aumentada e jogos móveis (FENG; YUAN; QIU, 2022). No 5G a rede é baseada na virtualização da rede e dos serviços que são disponibilizados para cada usuário, na nomenclatura do 5G essas redes virtuais são chamadas de fatias de rede (SRIRAAM et al., 2020). As fatias possibilitam que as aplicações não sejam dependentes do *hardware*, como ocorre na versão anterior do 5G, a saber, a rede de quarta geração (4G). Os benefícios do fatiamento de rede consiste no maior controle e flexibilidade no manejo dos serviços ofertados.

Os autores ZHAO et al. citam que o 5G, apesar de ser uma tecnologia que traz bastantes benefícios, o custo para a construção deste tipo de rede é enorme, o que aumenta com a densa cobertura e os altos requisitos para a distribuição, como consequência, a modelagem e ambientes de simulação se mostram atraentes para estudos no contexto do 5G.

2.2 *Streaming* de Vídeo

Streaming é a distribuição de conteúdos multimídia na rede, o que inclui música, vídeo e outros. Funciona através do *download* do conteúdo em um *buffer* no dispositivo do usuário, que ocorre durante a transmissão. O *streaming* de vídeo impacta não apenas no consumo, mas também na criação e distribuição de conteúdo. O *streaming* pode ser feita de duas formas, que são elas: sob demanda e ao vivo. Na transmissão por demanda o conteúdo é criado e salvo em um servidor, então os clientes podem acessar este conteúdo sempre que desejarem, enquanto que ao vivo o conteúdo é criado em tempo real, geralmente

streaming de vídeo ao vivo é caracterizado pela interação entre o criador de conteúdo e os consumidores por meio de bate-papos (BAENA et al., 2022). Nessa segunda forma, o canal de *uplink* se mostra um ponto chave para sucesso das transmissões em tempo real, uma vez que historicamente são os canais de *uplink* os mais limitados, uma vez que o padrão de transmissão consiste em maior banda nos canais de *downlink*.

De acordo com o (CLOUDFLARE, 2022), as principais etapas que ocorrem durante a transmissão de vídeo ao vivo são: (1) captura de vídeo; (2) compactação; (3) codificação; (4) segmentação e distribuição; (5) decodificação e (6) reprodução do vídeo. Na etapa 1 o vídeo é capturado por uma câmera externa ou pelo próprio dispositivo do usuário, estas informações visuais capturadas são representadas por dados digitais, assumindo valores binários de 0 e 1. Na etapa 2 o vídeo é compactado, removendo informações redundantes, estas informações redundantes podem ser algum objeto visual que seja estático, assim, este objeto não precisa ser renderizado em todos os quadros subsequentes. Sequencialmente, na etapa 3 o vídeo é codificado em formato digital interpretável, geralmente algum reconhecido como por exemplo: H.264, VP9, AV1. Na etapa 4 o vídeo é dividido em segmentos com duração de alguns segundos, que são enviados para uma rede de distribuição de conteúdo (*Content Delivery Network*, CDN), que por sua vez armazena estes segmentos em *cache*. A ideia por trás de uma CDN é fazer com que o usuário consuma estes segmentos sem ter que fazer a solicitação diretamente no servidor de origem, resultando no desempenho substancial da transmissão. Na etapa 5, o usuário recebe o segmento, o seu dispositivo faz a decodificação e descompactação, então o reproduzidor de mídia é utilizado, que pode ser um aplicativo específico ou o próprio navegado (etapa 6).

2.3 Qualidade Experiência e de Serviço

Qualidade de Experiência (QoE) é originada do termo Qualidade de Serviço (QoS). Tem como objetivo melhorar a percepção do usuário sobre o conteúdo que ele recebe, como por exemplo algoritmos de *Adaptive Bitrate Streaming* (ABS), que de acordo com a qualidade da *Internet* fazem a conversão de qualidade de vídeo, evitando assim que o vídeo sofra por interrupções (MUSTAFA et al., 2020). De acordo com os autores SAOVAPAKHIRAN et al. o QoE também pode ser visto como a forma que o usuário se sente bem ou aborrecido com determinado serviço ou aplicativo.

Qualidade de Serviço (QoS) tem como objetivo o melhorar o serviço ofertado. O QoS desempenha um papel fundamental na manutenção de serviços na *Internet*. Visando melhorar os critérios de otimização da rede, qualidade da rede, consumo de energia e outros. Sendo assim, as métricas de QoS são fatores indispensáveis e que tem impacto direto na experiência do usuário (SAOVAPAKHIRAN et al., 2022). Na prática o QoE é construído através da aplicação de QoS em vários elos do sistema. Por exemplo, o QoS em redes de computadores é aplicado através da classificação de pacotes e por política de filas.

O QoS e o QoE são métodos essenciais para a avaliação de *streaming* de vídeo em redes 5G. De acordo com os autores [CHEN; WU; ZHANG](#) a avaliação de *streaming* de vídeo evoluiu de uma avaliação centrada no QoS para uma avaliação mais centrada no QoE. Esta tendência é muito por conta da demanda do usuário por serviços e vídeo, o que torna a criação de modelos de QoE que possam monitorar, prever e controlar um fator importante que impacta de forma positiva provedores de serviços e operadoras de rede ([CHEN; WU; ZHANG, 2015](#)).

2.4 Aprendizado de Máquina

Aprendizado de Máquina (AM) são técnicas computacionais desenvolvidas e aperfeiçoadas dentro da área de Inteligência Artificial (IA) que permitem que um programa de computador adquira conhecimento de forma automática e que baseada em experiências anteriores possa tomar decisões de forma precisa ([MONARD; BARANAUSKAS, 2003](#)). A IA está avançando muito rápido, as máquinas já conseguem realizar trabalhos manuais e tarefas que exigem raciocínio lógico, como por exemplo: condução de veículos não tripulados, automação de diagnósticos médicos e aplicação em tradutores como o do *Google* ([LUDERMIR, 2021](#)).

O aprendizado de máquina pode ser classificado como supervisionado e não supervisionado. No aprendizado de máquina supervisionado o algoritmo possui conhecimento prévio dos rótulos dos dados, os rótulos são as informações de saída desejadas ou as classes atribuídas a um conjunto de dados. Fazendo comparações entre os rótulos previamente classificados e os resultados obtidos com o modelo de classificação. O algoritmo é repetido até que a acurácia desejada seja alcançada. Enquanto que no aprendizado não supervisionado o algoritmo extrai as características sem o conhecimento prévio dos rótulos e constrói uma representação, assim identificando heurísticamente os padrões de classificação, ou seja, exige menos interferência humana para que se chegue no resultado pretendido ([PAIXÃO et al., 2022](#)).

Como parte do aprendizado de máquina, o aprendizado profundo ou *Deep Learning* (DL) é uma técnica que utiliza redes neurais artificiais, que através do processamento de dados que simulam o processo de aprendizado humano. O DL é bastante utilizado no meio tecnológico, como por exemplo: detecção de doenças, assistentes digitais, carros autônomos e outros ([AMAZON_AWS, 2023](#)).

3 Trabalhos Relacionados

Este capítulo apresenta os trabalhos que se relacionam com o trabalho proposto. A Tabela 1 apresenta um resumo comparativo dos trabalhos relacionados em três aspectos: *Streaming* em redes 5G, Utiliza ML, identifica problemas. Artigos que estavam no contexto de *streaming* de vídeo em redes 5G foram o principal objetivo, pois o projeto desenvolvido tem ele como tema central. Em seguida artigos que utilizaram ML para solucionar problemas no contexto de *streaming*, a solução que será apresentada neste trabalho utiliza ML. Como objetivo final, foi dada importância para trabalhos que estivessem no contexto de identificar problemas em *streaming* de vídeo.

Tabela 1 – Trabalhos Relacionados

| Trabalhos relacionados | <i>Streaming</i> em 5G | Utiliza ML | Identifica problemas |
|------------------------------------|------------------------|------------|----------------------|
| (KIMURA; ALMEIDA et al., 2021) | Sim | Sim | Sim |
| (MUSTAFA et al., 2020) | Sim | Sim | Sim |
| (MUSTAFA; MOURA; ROTHENBERG, 2021) | Sim | Sim | Sim |
| (MEHMETI; PORTA, 2021) | Sim | Não | Sim |
| (GAO, 2022) | Sim | Sim | Sim |
| (QUINLAN et al., 2020) | Sim | Não | Não |
| (BAENA et al., 2022) | Sim | Não | Não |
| (GOMES et al., 2021) | Não | Sim | Não |
| (CUNHA et al., 2021) | Não | Não | Não |
| (PRECIADO-VELASCO et al., 2021) | Não | Sim | Não |
| Este trabalho | Sim | Sim | Sim |

Os trabalhos de (QUINLAN et al., 2020) e (BAENA et al., 2022) são semelhantes, pois apresentam bases de dados para serem usadas em pesquisas posteriores. No trabalho de (QUINLAN et al., 2020), é apresentado um conjunto de dados no contexto do 5G, os dados foram coletados de uma operadora móvel Irlandesa. Os dados são gerados de duas maneiras: estática e em movimento (utilizando carro). Com 2 tipos de padrões: *streaming* de vídeo e *download* de um arquivo. Sendo o conjunto de dados composto com os principais indicadores de desempenho (KPI). Enquanto que no trabalho de (BAENA et al., 2022), é apresentada uma base de dados com várias métricas chaves de indicadores de qualidade (KQI). Os serviços considerados nestes dados são *streaming* de vídeo e jogos em nuvem. O autor também faz uma descrição detalhada do *testbed* em que os dados foram gerados, discutindo as ideias por trás das escolhas para o seu desenvolvimento.

Os trabalhos de (KIMURA; ALMEIDA et al., 2021), (MUSTAFA et al., 2020), (MUSTAFA; MOURA; ROTHENBERG, 2021), (MEHMETI; PORTA, 2021), (GAO, 2022) e este trabalho utilizam a base de dados apresentada por (QUINLAN et al., 2020). Nos parágrafos seguintes apresentamos um resumo das principais contribuições que foram realizadas em cada um dos trabalhos mencionados acima.

No trabalho de (KIMURA; ALMEIDA et al., 2021) ele propõem uma nova abordagem de ML para realizar previsões em redes 5G. Ele faz a transformação das séries temporais

de informações de rede em imagens, obtendo assim uma representação bidimensional. As diferentes técnicas utilizadas foram: campos de transição de Markov (MTF), gráficos de recorrência (RP) e campos angulares de Gramian (GAF).

O trabalho de (MUSTAFA et al., 2020) apresentam duas contribuições. A primeira delas consiste no relato do estado da arte de algoritmos ABS, variando as chaves de QoS em cenários estáticos e móveis. A segunda contribuição, consiste na comparação de relacionamento entre cinco modelos de QoE, três parâmetros de QoS e sete Indicadores-chave de desempenho (KPI) de diferentes vídeos. Enquanto que no trabalho de (MUSTAFA; MOURA; ROTHENBERG, 2021), são examinados recursos reais de QoS criptografados derivados de uma rede 5G com o objetivo de estimar indicadores de QoE. Selecionou-se três algoritmos ABS que são: Híbrido – Elástico, *Buffered* – BBA e Tarifário – Convencional. Em seguida, os autores propõem um classificador de aprendizado de máquina para estimar o QoE, este classificador conseguiu alcançar precisão de 91%.

O trabalho de (MEHMETI; PORTA, 2021) analisa um conjunto de dados de *streaming* de vídeo em 5G, a análise foi conduzida separadamente entre dados estáticos e móveis. As contribuições desta obra que se destacam são: (i) caracterização da distribuição de taxas de dados utilizando funções de distribuição, (ii) demonstração da qualidade de um canal em *streaming* móvel e estático e (iii) indicação das transições mais prováveis de um estado do canal para outro estado.

(GAO, 2022) apresenta um modelo de previsão precisa da rede 5G, baseado no modelo *Smoothed Long Short Term Memory* (SLSTM). Os resultados mostram que o algoritmo SLSTM pode melhorar a precisão da previsão do tráfego no 5G de maneira efetiva. Além disso, comparando o método proposto no artigo com outros métodos, foi constatado que o modelo do autor se mostrou com maior grau de ajuste, menor grau de erro e previsão mais precisa. Porém, os fatores que possam afetar o tráfego como gargalos não são considerados de forma abrangente.

O trabalho de (GOMES et al., 2021) ele propõe uma solução chamada NS4MIoT que tem como objetivo alocar recursos de fatias de rede para cada inquilino (ou usuário) em uma rede 5G voltada para comunicação em massa da IoT (Internet das Coisas). Essa solução é capaz de considerar a periodicidade de cada transmissão, a quantidade de dados e a duração das comunicações.

O NS4MIoT foi desenvolvido para aumentar a quantidade de requisições mapeadas na rede 5G, melhorando assim a eficiência do mapeamento de recursos para atender a demanda dos inquilinos. A solução foi validada e incorporada em dois algoritmos de incorporação diferentes. Além disso, foram realizadas comparações entre os mesmos algoritmos com e sem a abordagem NS4MIoT. Os resultados obtidos demonstram que a inclusão do NS4MIoT resulta em uma melhoria no mapeamento de recursos em todos os casos em que foi aplicado.

(CUNHA et al., 2021) apresenta uma revisão sistemática sobre o tema do tráfego in-

teligente em Redes Veiculares Ad-Hoc ou do inglês *Vehicular Ad-Hoc Network*(VANETs), essas redes são sistemas de comunicação sem fio que permitem a troca de informações entre veículos e infraestruturas de transporte, como semáforos, sinais de trânsito e postes, de forma *ad-hoc*, ou seja, sem a necessidade de uma infraestrutura de rede fixa e pré-estabelecida. Nesta obra foram analisados diversos estudos relacionados ao controle de tráfego inteligente. Também foram realizados processos de filtragem para selecionar 115 trabalhos relevantes para uma revisão detalhada. Os artigos selecionados foram classificados de acordo com três critérios: foco geral, método de avaliação e tipo de comunicação. A revisão revelou lacunas de pesquisa e tendências na área de tráfego inteligente, identificando desafios e direções de pesquisa, como questões relacionadas à segurança e protocolos de comunicação. O trabalho também fornece uma lista de referências que serve como base para orientar futuras pesquisas mais confiáveis na área. Ao abordar questões cruciais de segurança, segurança física das pessoas e protocolos, o artigo contribui para a compreensão e o avanço do campo de tráfego inteligente em VANETs.

O autor (PRECIADO-VELASCO et al., 2021) propôs um classificador de serviços em redes 5G/B5G com o objetivo de melhorar a distribuição de recursos e o tráfego nessas redes. Para atingir esse objetivo, ele utilizou uma abordagem de ML baseada em Aprendizado Supervisionado. Essa abordagem utiliza algoritmos de ML para classificar os serviços com base nos Indicadores-Chave de Desempenho (KPIs) e nos Indicadores-Chave de Qualidade (KQIs) que caracterizam os diferentes serviços em redes 5G. O classificador desenvolvido foi capaz de selecionar as fatias de rede mais adequadas para cada serviço, o que resultou em uma melhoria significativa no QoS da rede e no QoE percebido pelos usuários. O uso de KQIs, que geralmente não são considerados em outros projetos, possibilitou uma melhor previsão e classificação dos serviços. A solução do autor com a incorporação dos KQIs alcançou uma precisão de 97% e um coeficiente de correlação de Matthews de 96,6% com um classificador *Random Forest*

Considerando o estado da arte, nosso trabalho propõe utilizar um conjunto de dados no contexto de *streaming* de vídeo em 5G e identificar problemas na conexão através da técnica de classificação, a classificação tem o propósito de ajudar no mapeamento de fatia de rede virtual. É importante ressaltar que os trabalhos de (GOMES et al., 2021) e (CUNHA et al., 2021) foram fundamentais para dar propósito ao contexto de classificação aplicado a fatia de rede no 5G, já que ambos citam que a questão do mapeamento é algo que demanda tanto tempo quanto recursos do sistema. Foi proposto um algoritmo capaz analisar os parâmetros da transmissão de vídeo como latência, vazão, capacidade da rede, largura de banda, cobertura e outros. O trabalho desenvolvido utiliza quatro classificadores e também a partir do resultado das métricas é possível inferir qual o melhor modelo a se utilizar para problemas na conexão de *streaming* de vídeo em 5G. Apontamos que como contribuição os resultados trazem diversos benefícios e pontos importantes para a melhoria da qualidade de serviço nesse contexto e também para futuras melhorias na

futura rede 6G, pontos estes apresentados nos próximos capítulos.

4 Desenvolvimento do Projeto

Esta seção descreve detalhadamente os procedimentos, técnicas e abordagens utilizadas para coletar e analisar os dados, bem como para realizar as etapas do estudo em questão. Adicionalmente, fornece informações sobre como o projeto foi planejado e executado, permitindo que outros pesquisadores possam compreender e replicar o estudo. A Figura 1 apresenta a metodologia adotada neste trabalho e aponta atividades inseridas no cronograma de planejamento. A metodologia planejada deste trabalho é composta em nove etapas que são: (i) Definição do tema, (ii) Definição das palavras chaves, (iii) Levantamento bibliográfico, (iv) Extração das características, (v) Desenvolvimento do projeto, (vi) Experimento, (vii) Análise dos resultados, (viii) Redação da monografia e (ix) Apresentação da monografia.

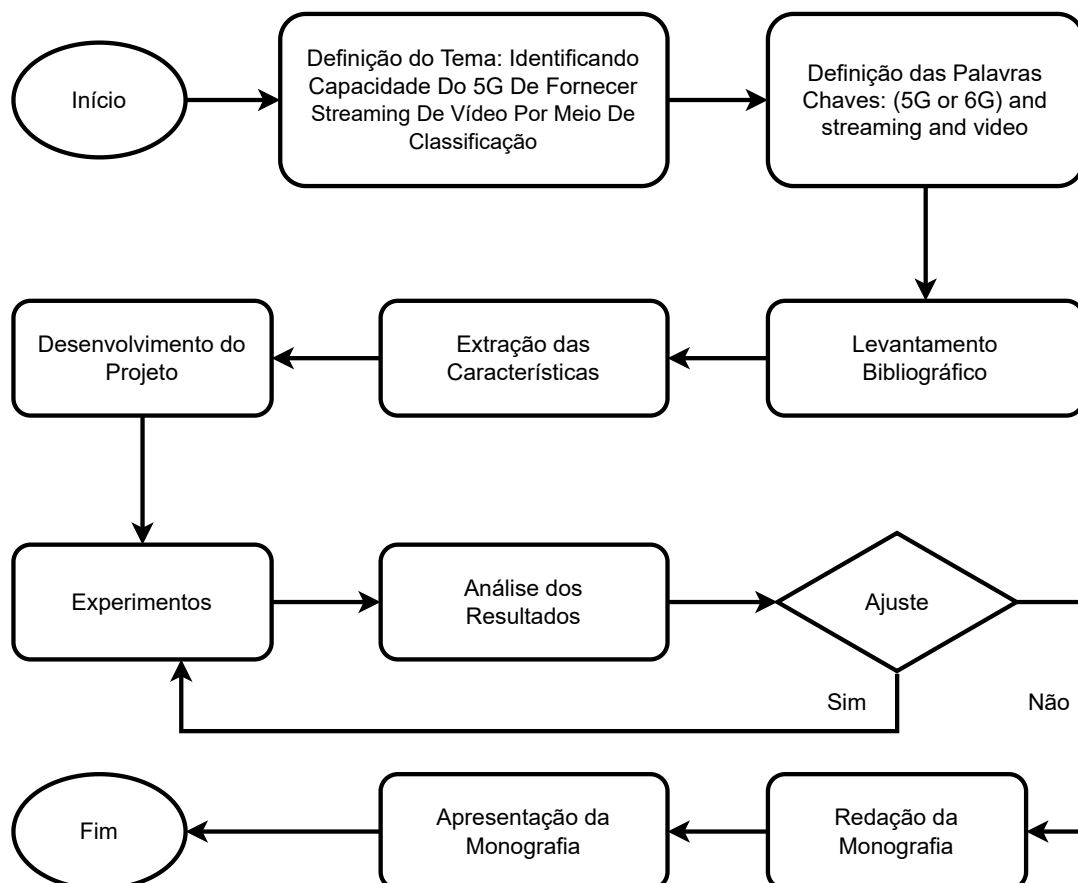


Figura 1 – Metodologia do Projeto.

1. Definição do Tema: Nesta etapa, anterior a escrita deste documento, compreen-

deu a escolha do tema do trabalho, levando em conta fatores como viabilidade de desenvolvimento do projeto e inovação para a área.

2. Definição das palavras chaves: Esta etapa é uma atividade crucial para o sucesso do projeto, pois as palavras chaves são guias para a correta coleta de artigos utilizados como fundamentação teórica.
3. Pesquisa Bibliográfica: Atividade que compreende a identificação, localização, compilação e a extração das informações e ideias mais importantes de nossa pesquisa. A obtenção de informações relevantes do tema escolhido na Etapa 1. A base de dados a qual as palavras chaves são inseridas e a qualidade dos artigos obtidos são críticos para o desenvolvimento do projeto, também nesta etapa é realizada a filtragem, a primeira etapa da filtragem consiste na leitura do título e resumo, a segunda etapa consiste em ler o artigo completo.
4. Extração das características: Nesta etapa são extraídas as características da base de dados que será utilizada para a resolução do problema.
5. Desenvolvimento do projeto: Nesta etapa inicia-se o desenvolvimento do projeto, como escolher modelo de resolução, a linguagem de programação e plataformas de desenvolvimento.
6. Experimentos: Nesta etapa os experimentos são executados, objetiva-se aplicar a solução proposta.
7. Análise de resultados: Após finalizar a etapa anterior, esta etapa compreende a examinação minuciosa e detalhada dos resultados obtidos no experimentos, caso a ineficácia da solução, a etapa de Experimentos será repetida com os devidos aprimoramentos.
8. Redação da monografia: Nesta etapa serão redigidas as seções que compreendem a natureza deste trabalho e de todo o seu invólucro contextual, segundo as regras e formatos que compõem um trabalho de conclusão de curso.
9. Apresentação da monografia: Nesta etapa será apresentado o trabalho perante a banca.

Por fim, a Tabela 2 apresenta o cronograma planejado para a execução do projeto de forma detalhada.

Tabela 2 – Cronograma Para Desenvolvimento Do Projeto

| Etapas em Meses | 1-2 | 3-4 | 5-6 | 7-8 | 9-10 | 11-12 |
|------------------------------|-----|-----|-----|-----|------|-------|
| Levantamento Bibliográfico | X | X | X | X | | |
| Extração das Características | X | | | | | |
| Desenvolvimento do Projeto | X | X | X | X | | |
| Análise dos Resultados | | | X | X | | |
| Redação da Monografia | | | X | X | | |
| Apresentação da Monografia | | | | X | | |

4.1 Arquitetura de Serviço

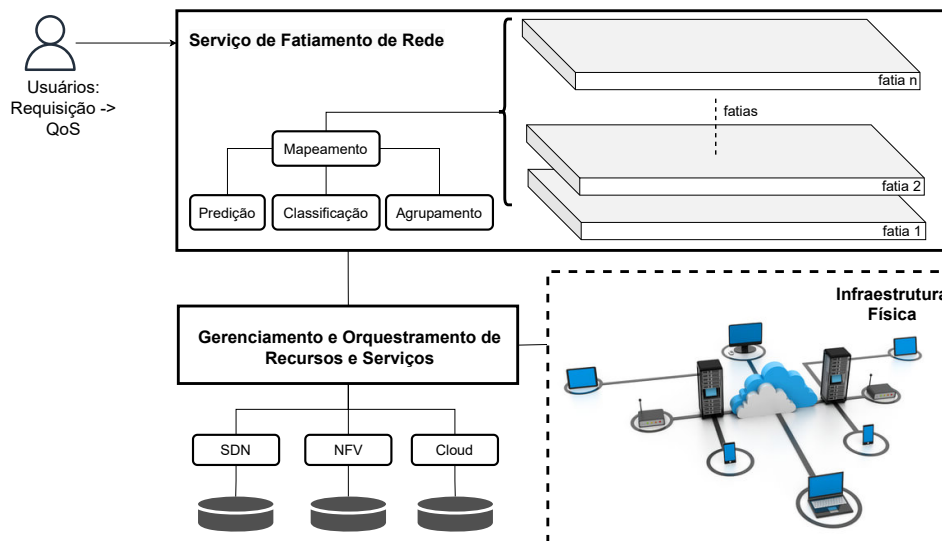


Figura 2 – Aquitetura de Serviço no 5G.

A Figura 2 ilustra a arquitetura de serviço no contexto do 5G, onde o projeto de classificação de *streaming* ocupa um papel importante nessa complexidade. O retângulo representando a estrutura física simboliza os componentes físicos da rede, tais como computadores, servidores, roteadores, *switches* e dispositivos móveis.

Conectado a esse retângulo, temos o Gerenciamento e Orquestramento de Recursos e Serviços, que no contexto do 5G é um serviço horizontal responsável por criar as fatias de rede, permitindo assim que a rede se torne programável. Esse serviço engloba tecnologias como SDN (*Software-Defined Networking*), NFV (*Network Function Virtualization*) e *Cloud*.

Acima dessa camada, temos o retângulo denominado Serviço de Fatiamento de Redes, que representa uma camada de software responsável pela finalidade do fatiamento. Cada fatia corresponde a uma rede virtual que oferece um serviço específico, como *streaming*,

veículos autônomos ou serviços médicos, e geralmente possui um proprietário associado, como mostrado na Figura 2, representado pelo Usuário.

Quando o Usuário realiza uma requisição, ela é enviada para o serviço de fatiamento de rede, conhecido também como *Network as a Service* (NaaS), que é responsável por mapear a requisição do usuário. Esse mapeamento é uma tarefa que demanda tempo e recursos, e para otimizá-lo, podem ser aplicadas técnicas como predição, classificação ou agrupamento.

O agrupamento é utilizado para categorizar os recursos que serão alocados para atender à requisição do usuário, simplificando o processo de mapeamento. A predição, por sua vez, lida com situações em que os parâmetros de qualidade de serviço (QoS) solicitados pelo usuário não podem ser inteiramente atendidos devido à dinamicidade da rede. Nesse caso, a predição ajuda a tomar decisões sobre alocação adicional de recursos para o serviço.

Já a classificação desempenha um papel importante no serviço de mapeamento, auxiliando na avaliação se os parâmetros de QoS requisitados pelo usuário podem ou não ser satisfeitos pelo serviço de transmissão de *streaming*. Essa avaliação é crucial para garantir que a rede ofereça um desempenho adequado e atenda às necessidades específicas dos usuários.

Dessa forma, a classificação de *streaming* se mostra relevante e essencial no contexto do 5G, contribuindo para a criação de redes virtualizadas e programáveis, proporcionando um serviço eficiente e personalizado aos usuários. A aplicação de técnicas de predição, classificação e agrupamento otimiza o mapeamento de recursos, possibilitando uma melhor alocação de recursos e, conseqüentemente, uma melhor experiência de *streaming* para os usuários.

4.2 Infraestrutura de Desenvolvimento

Esta seção aborda de forma detalhada todas as ferramentas utilizadas para o desenvolvimento do projeto.

4.2.1 Python

Python é uma linguagem de programação de alto nível, interpretada e de propósito geral. Foi criada por Guido van Rossum e apresentada pela primeira vez em 1991. *Python* se tornou uma das linguagens de programação mais populares do mundo devido à sua simplicidade, legibilidade e versatilidade. Ela é amplamente utilizada em uma variedade de áreas, incluindo ciência de dados, inteligência artificial, desenvolvimento *web*, automação de tarefas, análise de dados, entre outras. Sua simplicidade, legibilidade e ampla adoção fazem dela uma ótima escolha para iniciantes em programação, bem como para projetos de grande escala como no desenvolvimento deste projeto.

4.2.2 Google Colaboratory

O *Google Colab* é uma plataforma baseada na nuvem desenvolvida pelo *Google*, que permite a execução de notebooks *Jupyter* de forma interativa. Ele oferece um ambiente de programação colaborativo e gratuito que permite escrever e executar código *Python* diretamente no navegador, sem a necessidade de configurar um ambiente local.

Uma das principais vantagens do *Google Colab* é que ele fornece recursos de computação em nuvem de alto desempenho, permitindo que os usuários executem e treinem modelos de *Machine Learning* e *Deep Learning* em grande escala, sem depender de recursos de *hardware* locais. O Colab oferece acesso gratuito a GPUs e TPUs (*Tensor Processing Units*), que são unidades de processamento especializadas para acelerar o treinamento de modelos de aprendizado profundo.

4.2.3 Bibliotecas

Esta seção apresenta as duas principais bibliotecas utilizadas no projeto, tanto em questão de ML como de DL.

4.2.3.1 Scikit-Learn

O *Scikit-Learn* ou *sklearn* é uma das bibliotecas amplamente utilizadas para aprendizado de máquina em *Python*. Essa biblioteca fornece uma ampla gama de algoritmos e ferramentas eficientes para tarefas de aprendizado supervisionado e não supervisionado, pré-processamento de dados, avaliação de modelos e seleção de recursos. Os algoritmos de aprendizado supervisionado, incluem regressão linear, regressão logística, árvores de decisão, florestas aleatórias, *gradient boosting*, máquinas de vetores de suporte (SVM), entre outros. Como também, essa biblioteca fornece algoritmos para aprendizado não supervisionado, como agrupamento (*clustering*), redução de dimensionalidade e decomposição de valores singulares.

4.2.3.2 Keras

O *Keras* é uma biblioteca de alto nível para construção e treinamento de redes neurais em *Python*. Foi desenvolvido com o objetivo de ser uma interface simples e intuitiva para construir modelos de aprendizado profundo, permitindo que os usuários experimentem e implementem rapidamente diferentes arquiteturas de rede. Essa biblioteca tem uma ampla gama de camadas pré-definidas que podem ser facilmente empilhadas para construir uma arquitetura de rede, como foi o caso para criação do modelo de RNA apresentada nesta obra. O *keras* suporta uma variedade de tipos de camadas, como camadas totalmente conectadas, convolucionais, de *pooling*, recorrentes e de regularização. Além disso, também permite a criação de modelos mais complexos, como redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs) e redes neurais generativas adversárias (GANs).

A simplicidade e a flexibilidade do *Keras* também se estendem à compilação e treinamento dos modelos. Os usuários podem definir as funções de perda, otimização e métricas de avaliação do modelo com apenas algumas linhas de código. Além disso, o *Keras* oferece suporte a recursos como treinamento em lote (*batch training*), validação cruzada e salvamento de modelos em diferentes etapas de treinamento.

4.3 Modelos

Esta seção apresenta de forma detalhada os modelos utilizados no projeto, são eles: Regressão Logística (1), Árvore de Decisão (2), SVM (3), RNA (4). Cada um dos modelos de ML e DL foram treinados de modo semelhante, a variável X recebe todas as características presentes no *Dataset*, enquanto a variável Y recebe os rótulos identificados pela variável 'Problema'. No caso dos modelos de ML 80% dos dados foram para treinamento e 20% para teste. Para o modelo de DL 70% dos casos foram para treinamento e 30% dos casos para teste. Além disso, no caso do modelo de DL foi feita uma segunda divisão no conjunto de teste para criar um conjunto de validação e um conjunto de teste final. Essa divisão é feita para termos um conjunto de dados separado para a etapa de validação, onde podemos ajustar os hiperparâmetros do modelo sem interferir na avaliação final do seu desempenho, esse modelo também foi compilado utilizando o otimizador 'adam', com lote de amostras igual a 32 e quantidade de épocas iguais a 200.

4.3.1 Regressão Logística

A Regressão Logística é um modelo de classificação que é amplamente utilizado para problemas de classificação binária, como o problema de classificar a qualidade da conexão de *streaming* em redes 5G. Este modelo é baseado no conceito de regressão, mas é aplicado para realizar previsões sobre a probabilidade de um evento ocorrer ou não. Na Regressão Logística, as características (*features*) do conjunto de dados são usadas para estimar as probabilidades de pertencer a cada classe. A Regressão Logística utiliza a função logística, também conhecida como função sigmoide, para mapear o resultado para um valor entre 0 e 1, representando a probabilidade de pertencer à classe positiva. O modelo de regressão logística possui algumas limitações, como a suposição de linearidade e a sensibilidade a *outliers*. Em problemas mais complexos ou com relacionamentos não-lineares, outros modelos mais avançados, como árvores de decisão ou redes neurais, podem ser mais adequados.

4.3.1.1 Pseudo-código

Algoritmo: Regressão Logística Entrada:

- Conjunto de treinamento (X_{train} , y_{train})

- Conjunto de teste (X_{test} , y_{test})

Passo 1: Inicialização dos parâmetros 1. Inicializa os parâmetros do modelo (w , b) com valores aleatórios ou pré-definidos.

Passo 2: Treinamento do modelo

1. Para cada iteração:

- Calcula o vetor de ativação (z) através da combinação linear dos atributos de entrada (X_{train}) e os parâmetros (w , b).

- Aplica a função *sigmoide* nos valores de z para obter as probabilidades preditas (y_{pred}).

- Calcula o custo da função de perda (L) entre as probabilidades preditas (y_{pred}) e os rótulos reais (y_{train}).

- Calcula os gradientes do custo em relação aos parâmetros (w , b).

- Atualiza os parâmetros (w , b) usando um algoritmo de otimização, como o Gradiente Descendente, com base nos gradientes calculados.

Passo 3: Classificação do conjunto de teste

1. Calcula o vetor de ativação (z) para o conjunto de teste (X_{test}) usando os parâmetros treinados (w , b).

2. Aplica a função *sigmoide* nos valores de z para obter as probabilidades preditas (y_{pred}).

Passo 4: Avaliação do modelo

1. Calcula as métricas de desempenho, como acurácia, precisão, *recall* e *F1-Score*, comparando os rótulos preditos (y_{pred}) com os rótulos reais (y_{test}).

Saída: - Métricas de desempenho do modelo, como acurácia, precisão, *recall* e *F1-Score*.

4.3.2 Árvore de decisão

O modelo de Árvore de Decisão é um algoritmo de aprendizado de máquina utilizado para problemas de classificação e regressão. Pode ser utilizado quando se deseja entender o processo de tomada de decisão em um problema, pois o modelo gera uma árvore que representa o fluxo de decisões a serem tomadas com base nas características do conjunto de dados. O modelo de Árvore de Decisão é bastante poderoso devido à sua capacidade de lidar com relações não-lineares e identificar padrões complexos nos dados. Além disso, sua estrutura em forma de árvore permite uma interpretação intuitiva das decisões tomadas pelo modelo. No entanto, é importante considerar que a Árvore de Decisão pode ser suscetível a *overfitting*, ou seja, a criação de regras muito específicas que se ajustam perfeitamente aos dados de treinamento, mas não generalizam bem para novos dados. Portanto, é necessário utilizar técnicas de regularização, como a poda da árvore ou a limitação da profundidade, para evitar esse problema.

Pseudo-código do modelo de Árvore de Decisão

Entrada:

- Conjunto de treinamento (X_{train} , y_{train})
- Conjunto de teste (X_{test} , y_{test})

Passo 1: Treinamento do Modelo

1. Cria uma instância do modelo de Árvore de Decisão (tree_model).
2. Treina o modelo utilizando o conjunto de treinamento (X_{train} , y_{train}).

Passo 2: Classificação do Conjunto de Teste

1. Faz as previsões utilizando o modelo treinado no conjunto de teste (X_{test}).
2. Armazena as previsões em um vetor (y_{pred}).

Passo 3: Avaliação do Modelo

1. Calcula as métricas de desempenho, como acurácia, precisão, *recall* e *F1-Score*, comparando as previsões (y_{pred}) com os rótulos reais (y_{test}).

Saída:

- Métricas de desempenho do modelo, como acurácia, precisão, *recall* e *F1-Score*.

4.3.3 Máquina de Vetores de Suporte

O modelo SVM (*Support Vector Machine*), ou Máquina de Vetores de Suporte é um algoritmo de aprendizado supervisionado que encontra o melhor hiperplano de separação entre as classes do conjunto de dados. O objetivo é encontrar um hiperplano que maximize a margem entre as classes, permitindo uma melhor generalização para novos dados. Em casos em que as classes não são linearmente separáveis, o SVM utiliza uma técnica chamada truque do *kernel* para mapear os dados em um espaço de maior dimensão, onde as classes podem ser separadas linearmente. O SVM possui algumas vantagens, como a capacidade de lidar com conjuntos de dados de alta dimensionalidade e a capacidade de lidar com problemas de classificação não lineares, graças ao uso de *kernels*. Ao utilizar este modelo, é importante ter cuidado, pois o treinamento do SVM pode ser computacionalmente intensivo para conjuntos de dados muito grandes.

4.3.3.1 Pseudo código

Algoritmo: SVM**Entrada:**

- Conjunto de treinamento (X_{train} , y_{train})
- Conjunto de teste (X_{test} , y_{test})

Passo 1: Treinamento do Modelo

1. Cria uma instância do modelo SVM (svm_model).
2. Define os parâmetros do modelo, como o tipo de kernel e os hiperparâmetros, se apli-

cável.

3. Treina o modelo utilizando o conjunto de treinamento (X_{train} , y_{train}).

Passo 2: Classificação do Conjunto de Teste

1. Faz as previsões utilizando o modelo treinado no conjunto de teste (X_{test}).

2. Armazena as previsões em um vetor (y_{pred}).

Passo 3: Avaliação do Modelo

1. Calcule as métricas de desempenho, como acurácia, precisão, *recall* e *F1-Score*, comparando as previsões (y_{pred}) com os rótulos reais (y_{test}).

Saída:

- Métricas de desempenho do modelo, como acurácia, precisão, *recall* e *F1-Score*.

4.3.4 Rede Neural Artificial

O modelo Rede Neural Artificial (RNA), ou *Artificial Neural Network* em inglês, é uma abordagem de aprendizado de máquina inspirada no funcionamento do cérebro humano. É composto por camadas de neurônios artificiais interconectados, onde cada neurônio recebe entradas, realiza cálculos ponderados e passa o resultado para a próxima camada. Uma das principais vantagens da RNA é sua capacidade de aprender e capturar relacionamentos complexos nos dados, mesmo em conjuntos de dados de alta dimensionalidade. As RNAs têm a capacidade de generalização, o que significa que elas podem fazer previsões precisas em dados não vistos durante o treinamento. Porém, o desempenho das RNAs depende fortemente da arquitetura escolhida, do número de camadas, do número de neurônios em cada camada e dos hiperparâmetros de treinamento, como a taxa de aprendizado e o número de épocas. Para este problema a arquitetura foi desenvolvida com 3 camadas. A primeira camada é a de entrada, uma camada densa (totalmente conectada) com 64 unidades. Ela utiliza a função de ativação ReLU (*Rectified Linear Unit*), que é comumente usada em redes neurais para introduzir não linearidade. Em seguida, há outra camada densa que é a oculta, com 64 unidades e função de ativação ReLU. Essa camada adiciona mais capacidade de aprendizado e complexidade ao modelo, permitindo que ele aprenda representações mais complexas dos dados. Por fim, a última camada a de saída, é uma camada densa com uma única unidade de saída, usando a função de ativação sigmoid. Essa camada é responsável por produzir a saída final do modelo, que é uma probabilidade entre 0 e 1, representando a classe positiva. Para a parte de treinamento foram utilizadas 200 épocas.

4.3.4.1 Pseudo código

Algoritmo: RNA Entrada:

- Conjunto de treinamento (X_{train} , y_{train})

- Conjunto de teste (X_{test} , y_{test})

Passo 1: Definição da Arquitetura do Modelo

1. Cria uma instância do modelo Sequential (model).
2. Adiciona uma camada densa (*Dense*) com 64 neurônios e função de ativação ReLU como a primeira camada.
3. Especifica o formato de entrada da primeira camada através do parâmetro *input_shape*, que corresponde ao número de atributos das amostras (`X_train.shape[1]`).
4. Adiciona uma segunda camada densa (*Dense*) com 64 neurônios e função de ativação ReLU.
5. Adiciona uma terceira camada densa (*Dense*) com 1 neurônio e função de ativação *sigmoid*, que é utilizada para problemas de classificação binária.

Passo 2: Compilação do Modelo

1. Compila o modelo utilizando a função `compile()`.
2. Especifica a função de perda (loss) adequada para o problema de classificação binária, como *'binary_crossentropy'*.
3. Especifica o otimizador a ser utilizado, como *'adam'*.
4. Especifica as métricas que serão calculadas durante o treinamento, como *'accuracy'*.

Passo 3: Treinamento do Modelo

1. Treina o modelo utilizando o conjunto de treinamento (`X_train, y_train`).
2. Especifica o número de épocas de treinamento, *batch size* e outras configurações relevantes.
3. Utiliza a função `fit()` para iniciar o treinamento.

Passo 4: Avaliação do Modelo

1. Avalia o desempenho do modelo utilizando o conjunto de teste (`X_test, y_test`).
2. Calcula as métricas de desempenho, como acurácia, precisão, *recall* e *F1-Score*.

Saída:

- Métricas de desempenho do modelo, como acurácia, precisão, *recall* e *F1-Score*.

4.4 Métricas

Esta seção apresenta as métricas utilizadas no projeto de forma detalhada, são elas: Acurácia (1), Precisão (2), *Recall* (3), *F1-Score* (4).

1. Acurácia: A métrica de acurácia é amplamente utilizada para avaliar o desempenho de modelos de classificação. Ela representa a proporção de exemplos corretamente classificados em relação ao total de exemplos no conjunto de dados. No contexto do problema de classificação da qualidade da conexão de *streaming* em redes 5G, a acurácia é uma medida importante para avaliar o quão bem os modelos conseguem classificar corretamente classes: com problema e sem problema. Quanto mais alta a acurácia, maior a capacidade do modelo de fazer previsões corretas. A acurácia é uma métrica geral que considera igualmente as classificações corretas de ambas as

classes. Em alguns casos, uma alta acurácia pode mascarar um desempenho desequilibrado entre as classes, especialmente se houver um desequilíbrio significativo na distribuição dos rótulos. Portanto, é fundamental considerar outras métricas, como precisão, *recall* e *F1-score*, para obter uma visão mais abrangente do desempenho dos modelos.

2. **Precisão:** A precisão mede a capacidade do modelo de evitar a classificação incorreta de exemplos negativos como positivos. A precisão é uma métrica importante em casos em que a identificação correta dos casos positivos é crucial.
3. **Recall:** A métrica de *recall*, também conhecida como sensibilidade ou taxa de verdadeiros positivos, mede a proporção de exemplos positivos que foram corretamente identificados pelo modelo. O *recall* avalia a capacidade do modelo de encontrar todos os casos positivos, minimizando os falsos negativos.
4. **F1-score:** O *F1-score* é uma métrica que combina as informações de precisão e *recall* em um único valor, fornecendo uma medida balanceada do desempenho do modelo. Ele é calculado a partir da média harmônica entre a precisão e o *recall*, levando em consideração tanto os falsos positivos quanto os falsos negativos.

4.5 Dataset

O *dataset* foi criado manualmente com base nas características presentes no 5G. É importante salientar que o *dataset* produzido foi fortemente inspirado nos *datasets* utilizados pelos autores (PRECIADO-VELASCO et al., 2021) e (QUINLAN et al., 2020). O *dataset* contém informações relevantes sobre parâmetros de conexão de *streaming* em redes 5G. Esses parâmetros são cruciais para avaliar o desempenho e a qualidade das conexões de *streaming* em ambientes de rede 5G. A compreensão desses parâmetros é fundamental para otimizar a experiência do usuário em termos de latência, vazão, capacidade de rede e outros aspectos importantes.

O *dataset* consiste em 7.500 entradas, são 5.000 entradas com problema e 2.500 sem problema, onde cada entrada representa uma amostra de parâmetros de conexão. As 17 colunas do *dataset* fornecem uma ampla gama de informações sobre os aspectos técnicos das conexões de *streaming* em redes 5G.

As descrições dos parâmetros presentes no *dataset* são:

1. **Latência:** Medida da latência de rede em milissegundos. A latência é um fator crítico para a qualidade do *streaming* de vídeo em tempo real. Os valores gerados variam de 1 a 20 para casos com problema e de 0.1 a 1 para casos sem problema, refletindo as variações típicas de latência em redes 5G. Os valores maiores para casos com

problema podem representar situações de congestionamento ou interferência que afetam a transmissão do vídeo.

2. **Vazão:** Medida da vazão de rede em Mbps. A vazão representa a quantidade de dados que podem ser transmitidos em uma determinada unidade de tempo. Os valores gerados variam de 1 a 10 para casos com problema e de 10 a 100 para casos sem problema, refletindo a capacidade da rede para transmitir dados em diferentes situações.
3. **Capacidade_Redde:** Medida em Mbps (megabits por segundo), representando a capacidade máxima de transmissão de dados da rede. Os casos com problemas variaram de 1 a 10 Mbps, enquanto os casos sem problemas variaram de 10 a 100 Mbps.
4. **Cobertura:** Medida da cobertura da rede em metros. A cobertura representa a área geográfica que a rede é capaz de atender. Os valores gerados variam de 1 a 10 para casos com problema e de 10 a 100 para casos sem problema, representando diferentes tamanhos de áreas cobertas pela rede.
5. **Largura_Banda:** Largura de banda da rede em KHz. A largura de banda é a capacidade da rede para transmitir dados em uma determinada frequência. Os valores gerados variam de 1 a 10 para casos com problema e de 10 a 100 para casos sem problema, levando em consideração a quantidade de dados que a rede pode transmitir em diferentes frequências.
6. **Eficiencia_Espectral:** Eficiência espectral da rede em bits/s/Hz. A eficiência espectral representa a quantidade de dados que podem ser transmitidos por unidade de espectro de frequência. Os valores gerados variam de 1 a 20 para casos com problema e de 20 a 50 para casos sem problema.
7. **Taxa_Transferencia:** Taxa de transferência de dados em Mbps. A taxa de transferência representa a velocidade com que os dados são transferidos na rede. Os valores gerados variam de 1 a 100 para casos com problema e de 100 a 1000 para casos sem problema, representando diferentes velocidades de transmissão.
8. **Portadora_Radio:** Frequência da portadora de rádio em MHz. A portadora de rádio representa a frequência de rádio utilizada para a transmissão de dados. Os valores gerados variam de 600 MHz a 100 GHz para ambos os casos, refletindo a ampla gama de frequências utilizadas em redes 5G.
9. **Densidade_Usuarios:** A densidade de usuários representa o número de dispositivos conectados à rede em uma determinada área geográfica. Os valores gerados variam de 100.000 a 1.000.000 para casos com problema e de 1.000.000 a 10.000.000 para casos sem problema, representando diferentes densidades de usuários na rede..

10. Confiabilidade: Nível de confiabilidade da rede em porcentagem. A confiabilidade representa a probabilidade de sucesso na transmissão de dados. Os casos com problemas variaram de $1e-5$ (0,00001) a 1 (100% de confiabilidade), enquanto os casos sem problemas variaram de $1e-9$ (0,000000001) a $1e-6$ (0,000001).
11. Disponibilidade: Nível de disponibilidade da rede em porcentagem. A disponibilidade representa a porcentagem de tempo em que a rede está disponível para transmissão de dados. Os valores gerados variam de 99.9% a 100% para casos com problema e de 99.999% a 100% para casos sem problema, refletindo diferentes níveis de disponibilidade da rede.
12. Mobilidade: Medida da mobilidade dos dispositivos na rede. A mobilidade representa a velocidade com que os dispositivos se movem na rede. Os valores gerados variam de 0 a 500 para casos com problema e de 500 a 1000 para casos sem problema, levando em consideração diferentes velocidades de mobilidade dos dispositivos na rede.
13. Taxa_Erro_Bit: Taxa de erro de bit da comunicação. A taxa de erro de bit representa a probabilidade de erro na transmissão de dados. Casos com problema de conexão em redes 5G, a taxa de erro de bit foi gerada com valores variando entre $1e-6$ (0,000001) e $1e-3$ (0,001). Já no grupo de casos sem problema de conexão, a taxa de erro de bit foi gerada com valores variando entre $1e-9$ (0,000000001) e $1e-6$ (0,000001). Essa medida é fundamental para entender a qualidade da conexão em redes de dados, especialmente em aplicações sensíveis a erros, como *streaming* de vídeo, onde a transmissão de cada bit é essencial para garantir a integridade e a fidelidade do conteúdo transmitido.
14. Capacidade_Antena: Capacidade de transmissão da antena em decibéis (dB). A capacidade da antena representa o número de fluxos de dados que a antena pode suportar. Os valores gerados variam de 1 a 64 para casos com problema e de 64 a 128 para casos sem problema, refletindo diferentes capacidades de suporte da antena.
15. Conectividade_IoT: Medida da conectividade da Internet das Coisas (IoT). A conectividade IoT representa o número de dispositivos IoT conectados à rede. Os valores gerados variam de 100.000 a 1.000.000 para casos com problema e de 1.000.000 a 10.000.000 para casos sem problema, representando diferentes números de dispositivos IoT na rede.
16. Sincronizacao_Tempo: Medida da sincronização de tempo da rede. A sincronização de tempo representa a precisão da sincronização de tempo entre os dispositivos na rede. Os valores gerados variam de 0 a $1e-6$ para casos com problema e de $1e-6$ a $1e-9$ para casos sem problema, refletindo diferentes níveis de precisão de sincronização de tempo.

17. Problema: Variável alvo que indica se há um problema (1) ou não (0).

5 Resultados e Discussão

Nesta seção os resultados são apresentados de maneira clara e organizada, utilizando-se de tabelas e gráficos. Esses elementos visuais auxiliam na compreensão e na comunicação dos principais resultados encontrados. Além disso, os resultados também são acompanhados de uma descrição textual que os contextualiza e os interpreta, destacando os pontos mais relevantes e fornecendo uma análise detalhada dos dados.

A Tabela 3 mostra a média de desempenho dos modelos de Regressão Logística, Árvore de decisão, SVM e RNA através das métricas de Acurácia, Precisão, *Recall* e *F1-Score*.

Tabela 3 – Desempenho Dos Modelos

| Modelo | Acurácia | Precisão | <i>Recall</i> | <i>F1 Score</i> |
|---------------------|----------|----------|---------------|-----------------|
| Regressão Logística | 0,890 | 0,978 | 0,854 | 0,912 |
| Árvore de Decisão | 0,999 | 1,000 | 0,999 | 0,999 |
| SVM | 0,668 | 0,668 | 1,000 | 0,801 |
| RNA | 0,808 | 1,000 | 0,715 | 0,834 |

A regressão logística é um modelo de aprendizado de máquina utilizado para problemas de classificação binária, como o caso em questão. O modelo foi treinado com base nas características do *dataset* gerado, que incluem diferentes parâmetros relacionados à rede 5G. A acurácia do modelo foi de aproximadamente 0,890, o que significa que ele classificou corretamente cerca de 89,0% dos casos. A precisão foi de 0,978, indicando que a maioria dos casos classificados como problema pelo modelo realmente apresentava problemas. O *recall* foi de 0,854, o que significa que o modelo identificou corretamente cerca de 85,4% dos casos que realmente apresentavam problemas. O *F1 Score*, que combina a precisão e o *recall* em uma única métrica, foi de 0,912.

A árvore de decisão também foi treinada com as mesmas características do dataset gerado. A acurácia do modelo foi de aproximadamente 0,999, o que indica que ele classificou corretamente cerca de 99,9% dos casos. A precisão foi de 1,000, indicando que todos os casos classificados como problema pelo modelo realmente apresentavam problemas. O *recall* foi de 0,999, ou seja, o modelo identificou corretamente a maioria dos casos que realmente apresentavam problemas. O *F1 Score* foi de 0,999, indicando um desempenho excelente do modelo.

No caso do SVM (*Support Vector Machine*) a acurácia do foi de aproximadamente 0,668, o que indica que ele classificou corretamente cerca de 66,8% dos casos. A precisão foi de 0,668, indicando que a maioria dos casos classificados como problema pelo modelo realmente apresentava problemas. O *recall* foi de 1,0, ou seja, o modelo identificou corretamente todos os casos que realmente apresentavam problemas. O *F1 Score* foi de 0,801, indicando um desempenho razoável do modelo.

RNA (Rede Neural Artificial) demonstrou um desempenho promissor, com uma acurácia de aproximadamente 0,808, o que significa que ele classificou corretamente cerca de 80,8% dos casos. A precisão da RNA foi de 1,000, sugerindo que a maioria dos casos classificados como problema pelo modelo realmente apresentava problemas. O *recall*, por sua vez, foi de 0,715, indicando que o modelo foi capaz de identificar corretamente 71,5% dos casos que realmente apresentavam problemas. Essa é uma taxa bastante satisfatória para a detecção de problemas na conexão de streaming de vídeo em redes 5G. O *F1-Score* da RNA foi de 0,834, o que indica um bom equilíbrio entre a precisão e o recall. Isso sugere que o modelo é capaz de realizar classificações precisas e identificar corretamente a maioria dos casos problemáticos.

5.1 Análise Gráfica dos Resultados

Esta seção apresenta os resultados de maneira visual, através de gráfico de barras e matriz de confusão.

A Figura 3 mostra o gráfico de comparação dos modelos na métrica de acurácia. Os modelos de Regressão Logística e Árvore de decisão são superiores aos demais, mostrando resultados acima de 88%, no caso do SVM, ele apresentou o pior desempenho, mostrando uma acurácia satisfatória entre 60% e 70% mas não excelente se comparada aos demais casos.

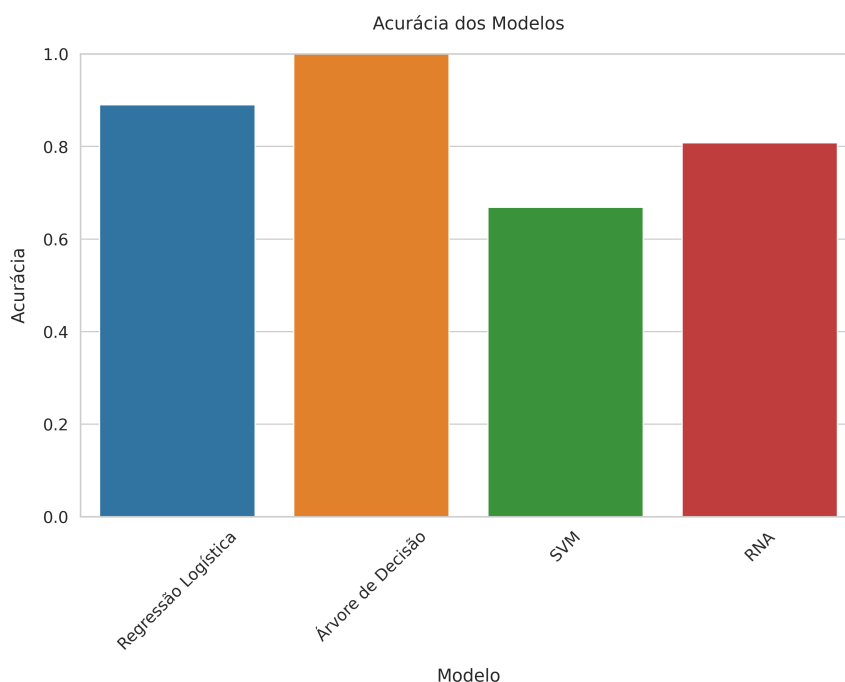


Figura 3 – Resultados Métrica de Acurácia

A Figura 4 mostra o gráfico de comparação dos modelos na métrica de precisão. Os modelos de Regressão logística, Árvore de decisão e RNA apresentaram os melhores

resultados, enquanto que o modelo SVM, novamente apresentou resultados insatisfatórios, com resultados entre 60% e 70%.

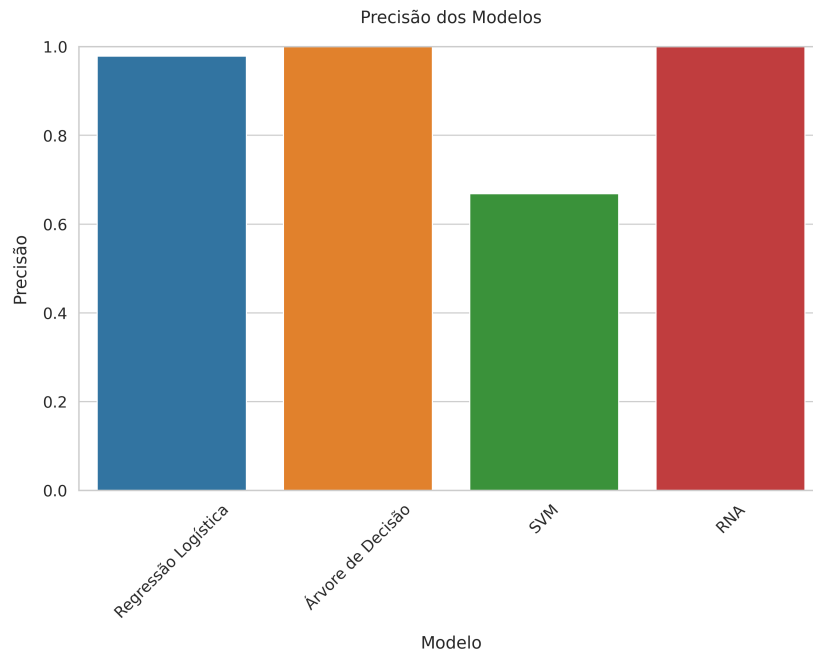


Figura 4 – Resultados Métrica de Precisão

A Figura 5 mostra o gráfico de comparação dos modelos na métrica de *recall*. Os modelos de Árvore de decisão e SVM apresentam os melhores resultados, com recall de aproximadamente 99%. Enquanto o modelo de RNA apresentou o pior desempenho com aproximadamente 70%.

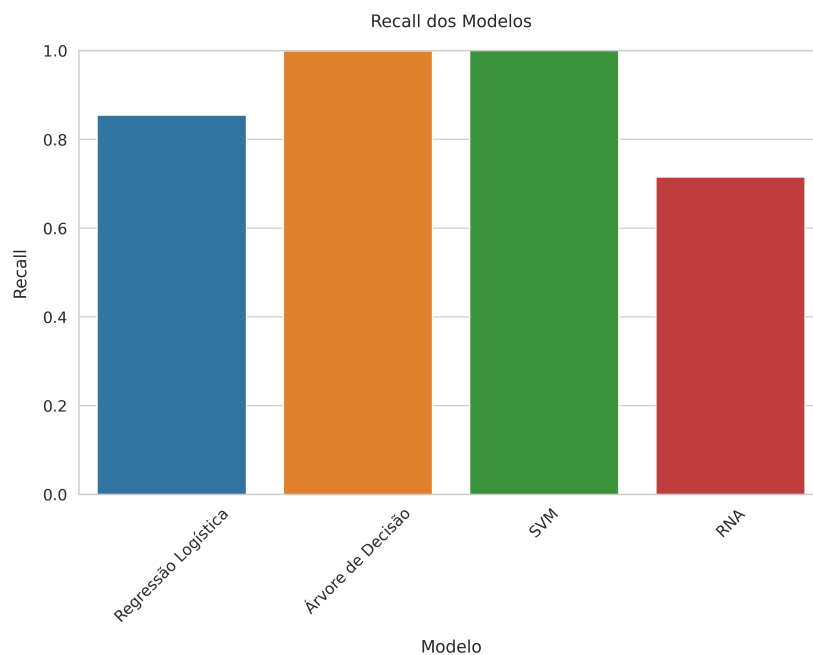


Figura 5 – Resultados Métrica de *Recall*

A Figura 6 mostra o gráfico de comparação dos modelos na métrica de *F1-Score*. Os modelos de Regressão Logística e Árvore de decisão apresentam os melhores resultados

com *F1-Score* de aproximadamente 99%, enquanto o SVM e RNA tiveram resultados excelentes de aproximadamente 80%, porém, ainda assim inferior aos outros 2.

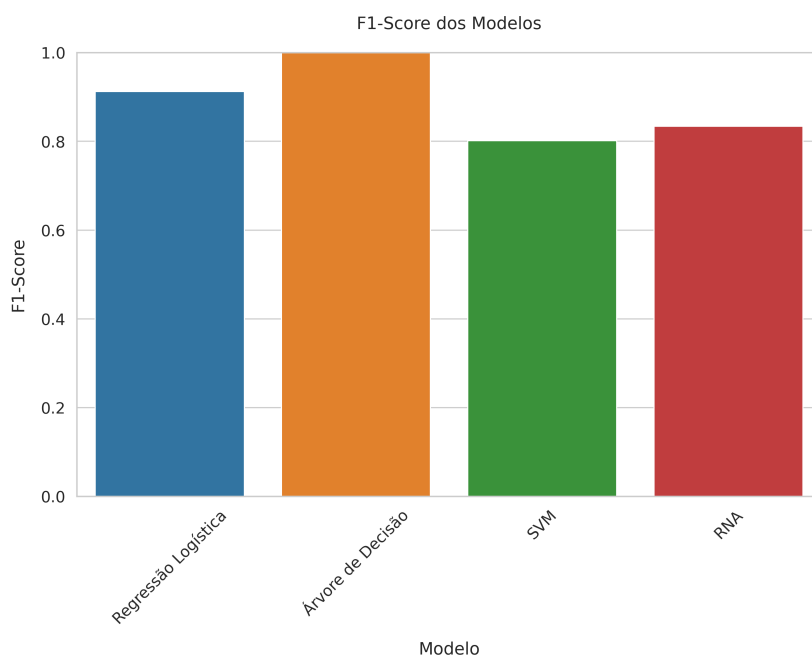


Figura 6 – Resultados Métrica de F1-Score

A Figura 7 mostra a matriz de confusão do modelo de regressão logística. O Modelo teve 478 observações corretamente classificadas como verdadeiro negativo. 19 de falso positivo, 146 de falso negativo e 856 de verdadeiro positivo.

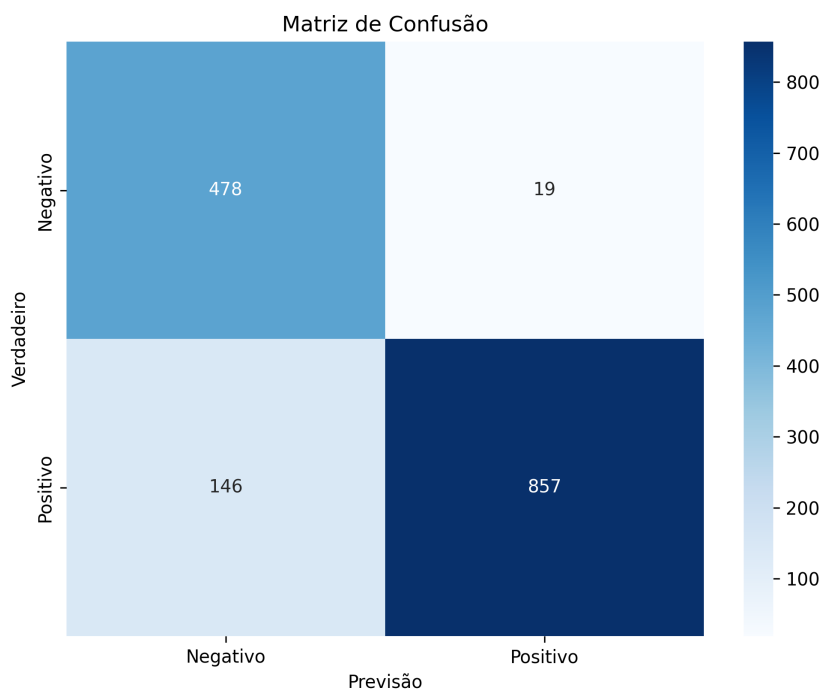


Figura 7 – Resultados Matriz de Confusão Regressão Logística

A Figura 8 mostra a matriz de confusão do modelo de árvore de decisão. O Modelo teve

497 observações corretamente classificadas como verdadeiro negativo. 0 de falso positivo, 1 de falso negativo e 1.002 de verdadeiro positivo.




Figura 8 – Resultados Matriz de Confusão Árvore de Decisão

A Figura 9 mostra a matriz de confusão do modelo SVM. O Modelo teve 0 observações corretamente classificadas como verdadeiro negativo. 497 de falso positivo, 0 de falso negativo e 1.003 de verdadeiro positivo.

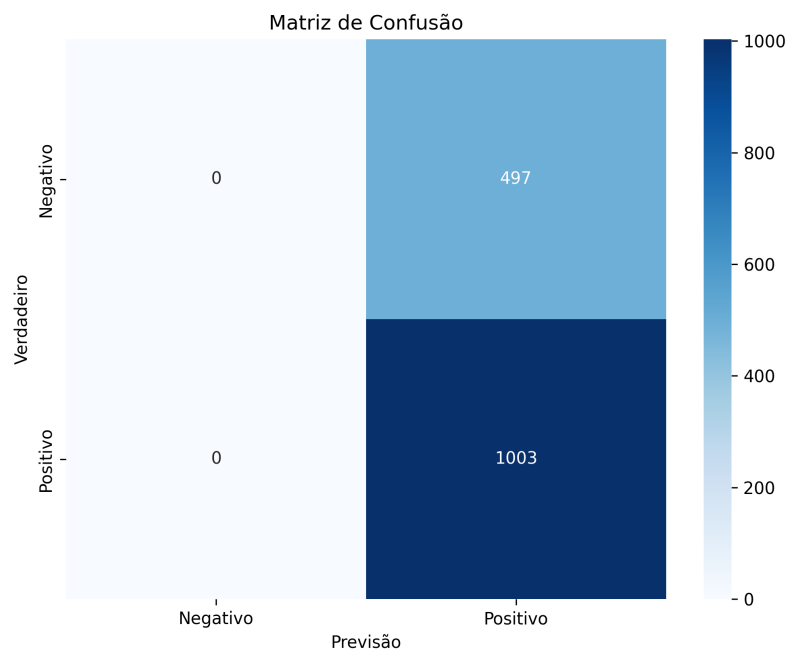


Figura 9 – Resultados Matriz de Confusão SVM

A Figura 10 mostra a matriz de confusão do modelo de árvore de RNA. O Modelo teve 367 observações corretamente classificadas como verdadeiro negativo, 0 de falso positivo, 216 de falso negativo e 542 de verdadeiro positivo.




Figura 10 – Resultados Matriz de Confusão RNA

5.1.1 Equações Usadas nos Modelos

A Tabela 4 apresenta os significados de cada variável utilizada nas equações de Acurácia, Precisão, Recall e F1-Score.

Tabela 4 – Tabela de Variáveis

| Variável | Significado |
|----------|---------------------|
| VP | Verdadeiro Positivo |
| VN | Verdadeiro Negativo |
| FP | Falso Positivo |
| FN | Falso Negativo |

A Tabela 5 apresenta a fórmula das equações de Acurácia, Precisão, Recall e F1-Score. A primeira coluna Métrica é composta pelas métricas utilizadas neste trabalho e a coluna Fórmula compõe as respectivas fórmulas de cada métrica.

Tabela 5 – Fórmulas de Avaliação

| Métrica | Fórmula |
|----------|-----------------------------------------------------------------------------------------|
| Acurácia | $\frac{VP+VN}{VP+FP+VN+FN}$ |
| Precisão | $\frac{VP}{VP+FP}$ |
| Recall | $\frac{VP}{VP+FN}$ |
| F1-score | $\frac{2 \times \text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}}$ |

Calculando Acurácia para o modelo de Regressão Logística:

$$\text{Acurácia} = \frac{856 + 478}{856 + 478 + 19 + 149}$$

$$\text{Acurácia} \approx 0,88882$$

Calculando Precisão para o modelo de Regressão Logística:

$$\text{Precisão} = \frac{856}{856 + 19}$$

$$\text{Precisão} \approx 0,978311$$

Calculando *Recall* para o modelo de Regressão Logística:

$$\text{Recall} = \frac{856}{856 + 149}$$

$$\text{Recall} \approx 0,854437$$

Calculando *F1-Score* para o modelo de Regressão Logística:

$$\text{F1-Score} = \frac{2 \times 0,978311 \times 0,854437}{0,978311 + 0,854437}$$

$$\text{F1-Score} \approx 0,912187$$

Calculando Acurácia para o modelo Árvore de Decisão:

$$\text{Acurácia} = \frac{1002 + 497}{1002 + 497 + 0 + 1}$$

$$\text{Acurácia} \approx 0,99851$$

Calculando Precisão para o modelo Árvore de Decisão:

$$\text{Precisão} = \frac{1002}{1002 + 0}$$

$$\text{Precisão} = 1$$

Calculando *Recall* para o modelo Árvore de Decisão:

$$\text{Recall} = \frac{1002}{1002 + 1}$$

$$\text{Recall} \approx 0,999$$

Calculando *F1-Score* para o modelo Árvore de Decisão:

$$F1-Score = \frac{2 \times 1 \times 0,999}{1 + 0,999}$$

$$F1-Score \approx 0,9995$$

Calculando Acurácia para o modelo SVM:

$$Acurácia = \frac{1003 + 0}{1003 + 0 + 497 + 0}$$

$$Acurácia \approx 0,66867$$

Calculando Precisão para o modelo SVM:

$$Precisão = \frac{1003}{1003 + 497}$$

$$Precisão \approx 0,66867$$

Calculando *Recall* para o modelo SVM:

$$Recall = \frac{1003}{1003 + 0}$$

$$Recall = 1$$

Calculando *F1-Score* para o modelo SVM:

$$F1-Score = \frac{2 \times 0,66867 \times 1}{0,66867 + 1}$$

$$F1-Score \approx 0,80018$$

Calculando Acurácia para o modelo RNA:

$$Acurácia = \frac{542 + 367}{542 + 367 + 0 + 216}$$

$$Acurácia \approx 0,80571$$

Calculando Precisão para o modelo RNA:

$$Precisão = \frac{542}{542 + 0}$$

$$Precisão = 1$$

Calculando *Recall* para o modelo RNA:

$$Recall = \frac{542}{542 + 216}$$

$$Recall \approx 0,7152$$

Calculando *F1-Score* para o modelo RNA:

$$F1-Score = \frac{2 \times 1 \times 0,7152}{1 + 0,7152}$$

$$F1-Score \approx 0,834$$

5.2 Análise Comparativa

A Regressão Logística obteve uma acurácia e *F1-Score* razoáveis, mas um *recall* um pouco menor em comparação com os modelos de Árvore de Decisão e SVM. Pode ser que o modelo teve dificuldade em identificar corretamente todos os casos de problema. A Árvore de Decisão teve um desempenho excelente em todas as métricas, com acurácia, precisão, *recall* e *F1-Score* próximos de 1,0. Isso sugere que esse modelo foi capaz de capturar de forma precisa e completa a relação entre as características dos dados e o rótulo de problema.

O SVM não aprendeu, o modelo teve uma acurácia relativamente baixa em comparação com os outros modelos. As diferenças de desempenho podem ser atribuídas às diferentes propriedades e comportamentos dos modelos utilizados, bem como à natureza dos dados utilizados. O SVM pode ter sido mais sensível a *outliers* ou não ter sido capaz de encontrar um hiperplano de separação adequado para os dados específicos gerados. Por outro lado, o modelo baseado em árvore, Árvore de Decisão, pode ter se beneficiado da capacidade de dividir o espaço de características em regiões mais adequadas para classificar os casos.

A RNA também apresentou um desempenho sólido na tarefa de identificar problemas na conexão de *streaming* de vídeo em redes 5G. Os resultados indicam uma capacidade promissora de predição e uma alta taxa de detecção de casos problemáticos, tornando-a uma abordagem promissora para esse tipo de problema.

6 Conclusão e Trabalhos Futuros

Os resultados em relação a acurácia e precisão os modelo de regressão logística, árvore de decisão e o SVM obteve os valores de (89%; 97%), (99%;100%) e (80%;100%), mostrando a eficácia dos modelos na tarefa de classificar se os parâmetros de QoS da fatia de rede virtual podem ou não ser atendidos. A maior dificuldade foi encontrar *datasets* com dados reais no contexto de *streaming* de vídeo em redes 5G, a razão pela qual não é comum encontrar este tipo de *dataset*, é porque os provedores não gostam da ideia de fornecer dados que poderiam ser utilizados pela concorrência, opção que dificulta realizar trabalhos acadêmicos, pois tivemos que gerar dados fictícios o que pode nem sempre refletir a realidade total dos fatos.

Para trabalho futuro, pretendo realizar os testes com técnica de regressão, a predição nesse caso desempenha um papel fundamental ao lidar com situações em que os parâmetros de qualidade de serviço (QoS) requisitados pelo usuário não podem ser plenamente atendidos devido à natureza dinâmica da rede. Dessa forma, ela proporciona a capacidade de tomar decisões estratégicas para alocar recursos adicionais ao serviço, garantindo um melhor atendimento às necessidades dos usuários.

Outro benefício da regressão é a interpretabilidade dos resultados. Ao contrário de alguns modelos de aprendizado de máquina mais complexos, como as redes neurais, os modelos de regressão fornecem coeficientes e interceptos que permitem entender de forma mais clara como cada variável afeta a variável de resposta. Isso torna mais fácil para os pesquisadores entenderem o impacto de cada métrica na qualidade do *streaming* e tomar decisões informadas para otimizar a rede.

No entanto, há também desafios em realizar este trabalho com regressão. Um dos principais desafios é a seleção adequada das variáveis para a análise. Em um contexto de *streaming* de vídeo em redes 5G, há uma grande quantidade de métricas e parâmetros que podem influenciar a qualidade da conexão. A escolha das variáveis mais relevantes e a definição de suas relações com a variável de resposta requer conhecimento especializado e expertise na área.

Outro desafio está na obtenção de dados reais para a análise. Como mencionado anteriormente, muitos provedores de rede são relutantes em fornecer dados detalhados sobre o desempenho de suas redes, o que pode dificultar a obtenção de um *dataset* representativo e confiável para realizar a análise de regressão. Nesse sentido, a geração de dados sintéticos, como feito neste trabalho, pode ser uma alternativa viável, mas é importante garantir que esses dados reflitam as características reais do *streaming* de vídeo em redes 5G.

Apesar desses desafios, o uso da regressão como trabalho futuro é fundamental para a obtenção de *insights* valiosos sobre a relação entre as métricas de desempenho e a

ocorrência de problemas na conexão de *streaming* de vídeo em redes 5G. Os resultados obtidos com a análise de regressão podem contribuir para a otimização da qualidade do *streaming* e a tomada de decisões informadas para aprimorar o desempenho das redes 5G.

Concluindo, este trabalho apresenta uma análise da classificação de parâmetros de QoS em *streaming* de vídeo em redes 5G, utilizando diferentes modelos de aprendizado de máquina. Os resultados promissores obtidos demonstram o potencial desses modelos para identificar e classificar problemas de conexão. Apesar dos desafios enfrentados na obtenção de dados reais, a geração de um *dataset* sintético permitiu a realização dos testes e a validação das abordagens propostas. As descobertas e conclusões obtidas com este trabalho servem como base para futuras pesquisas na área de otimização da qualidade do *streaming* em redes 5G e contribuem para o avanço dos estudos em redes de comunicação de alta performance.

Referências

- AMAZON_AWS. *O que é o aprendizado profundo?* 2023. Disponível em: <<https://aws.amazon.com/pt/what-is/deep-learning/>>. Acesso em: 16 jul. 2023. Citado na página 19.
- BAENA, C. et al. Video streaming and cloud gaming services over 4g and 5g: a complete network and service metrics dataset. TechRxiv, 2022. Citado 2 vezes nas páginas 18 e 20.
- CHEN, Y.; WU, K.; ZHANG, Q. From qos to qoe: A tutorial on video quality assessment. *IEEE Communications Surveys Tutorials*, v. 17, n. 2, p. 1126–1165, 2015. Citado na página 19.
- CISCO. *Cisco Annual Internet Report (2018–2023) White Paper*. 2022. Disponível em: <<https://www.cisco.com/c/en/us/solutions/collateral/executive-perspectives/annual-internet-report/white-paper-c11-741490.html>>. Acesso em: 18 dez. 2022. Citado na página 14.
- CLOUDFLARE. *O que é streaming ao vivo? | Como funciona o streaming ao vivo*. 2022. Disponível em: <<https://www.cloudflare.com/pt-br/learning/video/what-is-live-streaming/>>. Acesso em: 23 dez. 2022. Citado na página 18.
- CUNHA, B. et al. Smart traffic control in vehicle ad-hoc networks: a systematic literature review. *International Journal of Wireless Information Networks*, Springer, v. 28, n. 3, p. 362–384, 2021. Citado 4 vezes nas páginas 14, 20, 21 e 22.
- FENG, X.; YUAN, S.; QIU, S. For high frequency 5g analysis and predictions for large video surveillance systems. In: *2022 IEEE 2nd International Conference on Electronic Technology, Communication and Information (ICETCI)*. [S.l.: s.n.], 2022. p. 1072–1075. Citado na página 17.
- GAO, Z. 5g traffic prediction based on deep learning. *Computational Intelligence and Neuroscience*, Hindawi, v. 2022, 2022. Citado 3 vezes nas páginas 15, 20 e 21.
- GOMES, R. et al. Network slicing for massive machine type communication in iot-5g scenario. In: IEEE. *2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring)*. [S.l.], 2021. p. 1–7. Citado 4 vezes nas páginas 14, 20, 21 e 22.
- KIMURA, B. Y. L.; ALMEIDA, J. et al. Deep learning in beyond 5g networks with image-based time-series representation. *arXiv e-prints*, p. arXiv-2104, 2021. Citado 3 vezes nas páginas 13, 15 e 20.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. *Estudos Avançados*, SciELO Brasil, v. 35, p. 85–94, 2021. Citado na página 19.
- LÓPEZ, J. P. et al. Prediction and modeling for no-reference video quality assessment based on machine learning. In: *2018 14th International Conference on Signal-Image Technology Internet-Based Systems (SITIS)*. [S.l.: s.n.], 2018. p. 56–63. Citado na página 14.

- MEHMETI, F.; PORTA, T. F. L. Analyzing a 5g dataset and modeling metrics of interest. In: *2021 17th International Conference on Mobility, Sensing and Networking (MSN)*. [S.l.: s.n.], 2021. p. 81–88. Citado 3 vezes nas páginas 15, 20 e 21.
- MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas inteligentes-Fundamentos e aplicações*, Manole, v. 1, n. 1, p. 32, 2003. Citado na página 19.
- MUSTAFA, R. U. et al. Dash qoe performance evaluation framework with 5g datasets. In: *IEEE. 2020 16th International Conference on Network and Service Management (CNSM)*. [S.l.], 2020. p. 1–6. Citado 4 vezes nas páginas 15, 18, 20 e 21.
- MUSTAFA, R. U.; MOURA, D.; ROTHENBERG, C. E. Machine learning approach to estimate video qoe of encrypted dash traffic in 5g networks. In: *2021 IEEE Statistical Signal Processing Workshop (SSP)*. [S.l.: s.n.], 2021. p. 586–589. Citado 3 vezes nas páginas 15, 20 e 21.
- ORDONEZ-LUCENA, J. et al. Network slicing for 5g with sdn/nfv: Concepts, architectures, and challenges. *IEEE Communications Magazine*, v. 55, 2017. ISSN 01636804. Citado na página 13.
- PAIXÃO, G. M. de M. et al. Machine learning na medicina: Revisão e aplicabilidade. *Arquivos Brasileiros de Cardiologia*, Sociedade Brasileira de Cardiologia, v. 118, n. 1, p. 95, 2022. Citado na página 19.
- PRECIADO-VELASCO, J. E. et al. 5g/b5g service classification using supervised learning. *Applied Sciences*, MDPI, v. 11, n. 11, p. 4942, 2021. Citado 3 vezes nas páginas 20, 22 e 34.
- QUINLAN, J. et al. Beyond throughput, the next generation: a 5g dataset with channel and context metrics. In: . [S.l.: s.n.], 2020. Citado 3 vezes nas páginas 15, 20 e 34.
- RACA, D. et al. Empowering video players in cellular: Throughput prediction from radio network measurements. In: *Proceedings of the 10th ACM Multimedia Systems Conference*. [S.l.: s.n.], 2019. p. 201–212. Citado na página 14.
- SAOVAPAKHIRAN, B. et al. Qoe-driven iot architecture: A comprehensive review on system and resource management. *IEEE Access*, v. 10, p. 84579–84621, 2022. Citado na página 18.
- SRIRAAM, S. et al. Implementation of 5g authentication and key agreement protocol on xbee networks. In: *2020 International Conference on COMmunication Systems NETworkS (COMSNETS)*. [S.l.: s.n.], 2020. p. 696–698. Citado na página 17.
- UITTO, M.; HEIKKINEN, A. Evaluation of live video streaming performance for low latency use cases in 5g. In: *IEEE. 2021 Joint European Conference on Networks and Communications & 6G Summit (EuCNC/6G Summit)*. [S.l.], 2021. p. 431–436. Citado na página 13.
- UITTO, M.; HEIKKINEN, A. Evaluating 5g uplink performance in low latency video streaming. In: *2022 Joint European Conference on Networks and Communications 6G Summit (EuCNC/6G Summit)*. [S.l.: s.n.], 2022. p. 393–398. Citado na página 14.

WANG, Y. et al. Qoe-driven link quality prediction for video streaming in mobile networks. In: *2022 IEEE 95th Vehicular Technology Conference: (VTC2022-Spring)*. [S.l.: s.n.], 2022. p. 1–5. Citado na página 14.

YU, Y.; LEE, S. Remote driving control with real-time video streaming over wireless networks: Design and evaluation. *IEEE Access*, v. 10, p. 64920–64932, 2022. Citado na página 14.

ZHAO, X. et al. Multi independent logical cells under 5g radio access network sharing of mobile operators. In: *2022 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting (BMSB)*. [S.l.: s.n.], 2022. p. 1–5. Citado na página 17.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- Tese
- Dissertação
- Monografia
- Artigo

Eu, Josean Mário Moreira Rodrigues, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação IDENTIFICANDO A CAPACIDADE DA INFRAESTRUTURA 5G DE SUPORTAR STREAMING DE VÍDEO BASEADO NA CLASSIFICAÇÃO, de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI - 23 de Agosto de 2023.

Assinatura