

Predição de Qualidade de Vídeo em Serviços de Streaming utilizando Redes 5G

Ivo A. Pimenta¹, Michael S. Souza¹, Carlos A. Aquino¹,
Ariel L. Portela¹, Rafael L. Gomes¹

¹Universidade Estadual do Ceará (UECE), Fortaleza, Ceará, Brasil.

{michael.souza, aguiar.pimenta, carlos.aquino,
ariel.portela}@aluno.uece.br, rafa.lopes@uece.br

Abstract. *The advent of 5G networks has brought about a significant transformation in contemporary society, highlighting notable growth, especially in the real-time video transmission sector but also in streaming services. However, users still face issues with inadequate video quality, particularly when the transmission characteristics of 5G networks vary. Within this context, this article presents an Artificial Intelligence (AI) model for predicting the video quality delivered to the end user. The proposed model considers both static and dynamic scenarios in vehicular devices, recognizing the importance of understanding content delivery according to the user's situation. This work's proposal uses real network data from 5G network measurements, enabling the optimization of user experience in dynamic 5G environments. The results demonstrate that the proposal is capable of contributing to the continuous improvement of video quality delivery in the context of mobile networks.*

Resumo. *O surgimento das redes 5G provocou uma transformação significativa na sociedade contemporânea, evidenciando um notável crescimento, especialmente no setor de transmissão de vídeos em tempo real, mas também nos serviços de Streaming. Contudo, os usuários ainda sofrem com problemas de qualidade de vídeo inadequada, principalmente quando as características de transmissão das Redes 5G variam. Dentro deste contexto, este artigo apresenta um modelo de Inteligência Artificial (IA) para a predição da qualidade de vídeo entregue ao usuário final. O modelo proposto considera tanto cenários estáticos quanto cenários dinâmicos em dispositivos veiculares, reconhecendo a importância de compreender a entrega de conteúdo de acordo com a situação do usuário. A proposta deste trabalho utiliza dados de medições de Redes 5G, possibilitando a otimização da experiência do usuário em ambientes 5G dinâmicos. Os resultados mostram que a proposta é capaz de contribuir para o aprimoramento contínuo da entrega de qualidade de vídeo em redes móveis.*

1. Introdução

A evolução das redes de telecomunicação celular, desde os primeiros sistemas de voz da primeira geração até a avançada Quarta Geração (4G), tem ocorrido de maneira contínua. Essa progressão, normalmente influenciada pelos serviços e aplicativos que fazem uso da rede, não havia previsto as atuais exigências de largura de banda na rede 4G. Aplicativos envolvendo mídias sociais, jogos em tempo real, conteúdo multimídia e os recentes avanços em Realidade Aumentada têm intensificado as necessidades, preparando

o cenário para a próxima geração, a Quinta Geração (5G), no mundo das comunicações celulares [Oliveira et al. 2020, Gomes et al. 2016].

Os dois fatores mais significativos que impulsionam o desenvolvimento dos padrões de celular da próxima geração é o rápido aumento no número de dispositivos conectados e o aumento sem precedentes no tráfego multimídia, e como resultado direto, suas crescentes demandas de largura de banda e qualidade de sinal [Portela et al. 2024, Gomes et al. 2010]. As previsões da indústria indicam que o número de dispositivos conectados até 2025, considerando dispositivos IoT também, deverá atingir 75,44 bilhões [Alam 2018, Costa et al. 2020].

No centro desse crescimento na demanda por largura de banda está o tráfego de vídeo, transmitido por meio de diferentes aplicativos, como vídeo sob demanda, transmissões ao vivo e vídeos em 360 graus. As plataformas de streaming atuais utilizam a técnica de streaming adaptativo HTTP (HAS) [Riiser et al. 2013] para a entrega de vídeos. HAS permite uma adaptação suave da qualidade do vídeo durante a reprodução por meio da segmentação do conteúdo de vídeo. Novos padrões de compressão de vídeo (H.265/HEVC) e resoluções de ultra alta definição têm altas exigências de largura de banda [Nightingale et al. 2018].

A qualidade de vídeo em streaming é crucial para oferecer uma experiência satisfatória aos usuários, também conhecida como Qualidade de Experiência (*Quality of Experience* - QoE) [Gomes et al. 2017], o qual é um conceito que se refere à medida subjetiva da satisfação geral do usuário ao interagir com um determinado serviço, produto ou aplicativo [da Silva et al. 2020]. Este aspecto é importante por várias razões [Kao and Wu 2023]: Engajamento, vídeos de alta qualidade têm maior probabilidade de manter os espectadores engajados por mais tempo; Valor Percebido, Vídeos de alta qualidade também podem influenciar a percepção do valor do serviço ou produto associado ao conteúdo, podendo aumentar a satisfação geral e a lealdade; e Capacidade de Monetização, Para plataformas de streaming que dependem de receitas publicitárias, a qualidade do vídeo pode impactar diretamente a eficácia dos anúncios.

Com base no exposto, podemos concluir que, embora o 5G forneça uma largura de banda superior à do seu antecessor, ainda é necessário aprimorar o serviço prestado, principalmente considerando que há diferentes cenários de utilização no que se refere a aplicações, mobilidade e interferência do ambiente. Uma das soluções mais promissoras para serviços multimídia sobre redes 5G é a predição da qualidade de vídeo em streaming, visto que sua aplicação tem impactos em diferentes áreas, incluindo aprimoramento da experiência do usuário, otimização de recursos e suporte à tomada de decisões.

Atualmente, existem ferramentas de coleta de dados que permitem a análise abrangente da implementação de redes, cobertura e desempenho para o usuário final. Este fato permite a criação de soluções mais complexas que podem ser posteriormente utilizados para o desenvolvimento e teste de modelos de Inteligência Artificial (IA) e Aprendizado de Máquina (*Machine Learning* - ML) voltadas para a otimização de recursos e otimização de serviços de rede [Kousias et al. 2023, Silveira et al. 2023], bem como atender à crescente demanda por tráfego de vídeo e aprimorar a qualidade da experiência do usuário considerando aspectos de mobilidade e sinal [Gomes et al. 2020, Portela et al. 2023].

Dentro deste contexto, este trabalho apresenta o desenvolvimento de modelos de IA, com otimização de hiperparâmetros, para a estimativa de qualidade de vídeo de Streaming sobre redes 5G através da predição de capacidade de transmissão da rede, considerando cenários tanto estáticos (sem mobilidade) quanto móveis (mobilidade veicular). Adicionalmente, os modelos aplicam um mapeamento de qualidade de vídeo utilizado pelas principais plataformas de streaming existentes (tais como, Netflix e Amazon Prime Video) a fim de maximizar a capacidade dos modelos de indicar a QoE dos usuários de acordo com os dados da Rede 5G.

Os experimentos realizados, usando dados reais de monitoramento de qualidade de sinal e transmissão de redes 5G, mostram que os modelos desenvolvidos conseguem prever com cerca de 92% de média precisão para o cenário estático e 90% de média de precisão para o cenário dinâmico, a qualidade de vídeo desses serviços utilizando suas respectivas taxas de transmissão. Desta forma, os modelos desenvolvidos podem servir de insumo para aplicações de gerenciamento de redes 5G e serviços de streaming.

Portanto, podem-se elencar que este trabalho possui as seguintes contribuições: (i) Gerar bons modelos de aprendizado de máquina para classificar a qualidade do vídeo como base nos dados de pacotes de rede ; (ii) Gerenciamento de recursos de rede 5G no cenário de serviços de Streaming; (iii) Colaborar com estratégias para fazer com que 5G se adapte a cenários de problemas reais.

O restante deste artigo está organizado da seguinte forma: A Seção 2 apresenta os trabalhos relacionados existentes. A Seção 3 apresentará os modelos desenvolvidos e análise dos dados realizada, enquanto a Seção 4 descreve os resultados dos experimentos. Por fim, a Seção 5 conclui o artigo e apresenta trabalhos futuros.

2. Trabalhos Relacionados

Esta seção descreve os principais trabalhos relacionados, e recentemente publicados pela comunidade científica, sobre experimentos sobre qualidade de vídeo e predição de características de redes 5G, incluindo aspectos de desempenho e qualidade de serviço.

Raca et al. [Raca et al. 2020] realizam uma coleta de dados sobre a tecnologia 5G através do aplicativo GNetTrack. Este conjunto de dados, proveniente de um grande operador na Irlanda, apresenta métricas-chave do lado do cliente, abrangendo canal, contexto e taxa de transferência. Esses dados são utilizados para comparações entre as redes 4G e 5G, com foco nos desempenhos em plataformas como Netflix e Prime Video, bem como na análise do download de pacotes.

Elsherbiny et al. [Elsherbiny et al. 2020] descrevem a urgência de melhorias na rede 4G devido ao crescente aumento na demanda por serviços e lista os aprimoramentos necessários através de redes 5G visando otimizar o desempenho da rede, tais como alocação preditiva de recursos e análise de transição entre células. O indicador-chave enfatizado para avaliar esse desempenho é a taxa de transferência. Foram utilizadas duas abordagens, séries temporais e modelos de classificação, sendo que os modelos de classificação tiveram um melhor comportamento.

Irina et al. [Irina et al. 2020] usam o método de extrapolação por spline para prever o tráfego multimídia em redes 5G e identificar picos "súbitos" de tráfego em tempo real. Os autores aplicam a predição de tráfego multimídia para alocar os buffers nos

dispositivos com o tamanho adequado, ou seja, sem desperdiçar recursos e evitando congestionamento de rede por estouro da capacidade dos buffers. Os autores do trabalho, apesar de preverem tráfego multimídia, não atuam no contexto de prever a qualidade do ponto de vista dos usuários.

Zhang et al. [Zhang et al. 2020] desenvolveram um modelo fim-a-fim de predição de Qualidade de Experiência (QoE) de vídeos, chamado DeepQoE. O DeepQoE combina técnicas de aprendizado profundo para extrair características dos vídeos e, posteriormente, usa estas características para alimentar uma rede neural para representação de conhecimento. Similarmente, Duanmu et al. [Duanmu et al. 2023] propõem um modelo preditivo de QoE, chamado Índice de Qualidade de Transmissão Bayesiana (BSQI), integrando conhecimento prévio sobre o conteúdo multimídia e dados anotados por especialistas, a fim de analisar as características subjetivas em relação a vídeos transmitidos. Assim, o BSQI consegue estimar a qualidade que os usuários irão receber os conteúdos multimídia. Em ambos os casos, DeepQoE e BSQI, não ocorre uma predição baseada nas características de transmissão da rede, tampouco consideram o contexto de redes 5G.

A partir do levantamento bibliográfico realizado, nota-se que nenhum artigo da literatura se concentrou no desenvolvimento de uma solução para prever a qualidade de vídeo que a rede poderá dar suporte aos usuários, considerando ambos os cenários de localização estática quanto de movimentação dinâmica, que é o foco deste artigo.

3. Proposta

A motivação essencial deste trabalho é a necessidade de testar o 5G em redes reais e diversos cenários. Ao fazê-lo, poderemos avaliar como o 5G se adapta e performa, fornecendo uma base sólida para melhorias futuras. Esses testes são cruciais para garantir que a tecnologia 5G continue a evoluir e atender às crescentes demandas de largura de banda, dispositivos e aplicativos, mantendo-se relevante em um cenário de comunicações sem fio em constante evolução. Para a construção da proposta, foi realizada uma pesquisa para encontrar conjuntos de dados contendo informações sobre pacotes de rede. Depois de uma cuidadosa seleção, escolhemos utilizar o conjunto de dados gerado a partir da coleta de informações de rastreamento 5G, os quais foram obtidos de um grande operador de telefonia móvel na Irlanda. Esse conjunto de dados é composto por informações coletadas de dois padrões de mobilidade (estática e veicular) e dois padrões de aplicação (transmissão de vídeo e download de arquivos).

O conjunto de dados é composto por Indicadores de Desempenho-Chave (KPIs) de células no lado do cliente, englobando métricas relacionadas ao canal, contexto da rede, métricas específicas da célula e informações de vazão. Essas métricas foram geradas através do uso de um aplicativo de monitoramento de rede conhecido, o G-NetTrack Pro, que não requer que o dispositivo esteja enraizado. Tendo à disposição esse conjunto de dados, a proposta deste trabalho envolve a classificação da qualidade de entrega de vídeo de serviços de streaming, como Netflix e Prime Video. Essa classificação será baseada na análise dos dados de tráfego de pacotes de rede.

3.1. Análise de Características

Analisamos as características das medições de sinal e capacidade de transmissão das Redes 5G, os quais incluem as seguintes informações:

1. Data e hora: Registro de data e hora da amostra.
2. Longitude e Latitude: Coordenadas GPS do dispositivo móvel.
3. Velocidade: Velocidade do dispositivo móvel em quilômetros por hora.
4. Nome do operador: Nome do operador de telefonia móvel, anonimizado para privacidade.
5. ID da célula: Identificação da célula de serviço associada ao dispositivo móvel.
6. Modo de Rede: Padrão de comunicação móvel utilizado (2G, 3G, 4G, 5G).
7. Taxa de download e taxa de upload : Taxa de download e upload medidas no dispositivo, na camada de aplicativo, expressas em kilobits por segundo (kbps).
8. Estado: Indica o estado do processo de download, com valores "I" para inativo (sem download em andamento) e "D" para ativo (download em andamento).
9. Ping médio, Ping mínimo, Ping máximo, Ping desvio padrão e Perda de Ping: Estatísticas de ping, incluindo média, mínimo, máximo, desvio padrão e perda de pacotes.
10. SNR (Relação Sinal-Ruído): Valor que representa a relação entre o sinal e o ruído, expresso em decibéis (dB).
11. RSRQ (Relação Sinal-Interferência e Qualidade): Indica a relação entre o RSSI e o RSRP
12. RSRP (Potência do Sinal de Referência da Célula): Valor que representa a potência média do sinal da célula, com base em símbolos de referência específicos transportados em diferentes elementos de recurso (RE). Utilizado para medir a cobertura da célula e seleção da célula (dBm).
13. RSSI (Indicador de Intensidade do Sinal Recebido): Valor que representa a potência recebida de forma ampla, incluindo a célula de serviço e interferências de outras fontes. RSRQ, RSRP e RSSI são utilizados para medir a força e cobertura da célula, incluindo o processo de handover (dBm).
14. CQI (Indicador de Qualidade de Canal): Valor que representa o feedback fornecido pelo dispositivo móvel ao eNB. Indica a taxa de dados que pode ser transmitida por um canal com base na relação SINR e nas características do receptor do dispositivo. Isso auxilia na escolha do esquema de modulação e taxa de codificação apropriados.
15. NRxRSRQ e NRxRSRP: Valores de RSRQ e RSRP para as células vizinhas.

Como queremos classificar a taxa de entrega da qualidade do vídeo, apenas na rede 5G e apenas o cenário de quando estiver ocorrendo a vazão, selecionamos para treinamento, o RSRP, CQI, RSSI, SNR e RSRQ como colunas de treinamento, e foram removidos os cenários em que o download está inativo.

3.2. Definição das classes de qualidade de vídeo

A qualidade da entrega do vídeo pode ser influenciada por diversos fatores, sendo crucial assegurar uma experiência de visualização otimizada para os telespectadores. Os principais aspectos considerados na qualidade de entrega desses serviços incluem:

1. Resolução de Vídeo: Deve ser checado se os serviços proporcionam a exibição de vídeos em alta definição (HD) ou ultra alta definição (UHD/4K), considerando a configuração do dispositivo utilizado e a capacidade da conexão à internet do usuário. A resolução do vídeo deve ser compatível com o dispositivo em uso e a largura de banda disponível.

2. Taxa de Bits e Qualidade de Compressão: É necessário avaliar a taxa de bits do vídeo transmitido. Geralmente, uma taxa de bits mais elevada resulta em uma qualidade de vídeo superior. Além disso, é importante observar a qualidade da compressão, uma vez que uma compressão excessiva pode impactar negativamente a qualidade do vídeo.

Foi adotado o modelo de entrega de vídeos do YouTube, pois oferece uma variedade mais ampla de faixas de qualidade. Isso possibilita uma análise mais abrangente da qualidade dos vídeos reproduzidos com 5G.

Tabela 1. Tabela com dados de vídeo do Youtube

Qualidade de vídeo	Resolução	Velocidade recomendada
SD	360p	0.7 Mbps ou mais
SD	480p	1.1 Mbps ou mais
Alta definição (HD)	720p	2.5 Mbps ou mais
Máxima alta definição (FHD)	1080p	5 Mbps ou mais
Ultra alta definição (UHD)	4K	20 Mbps ou mais

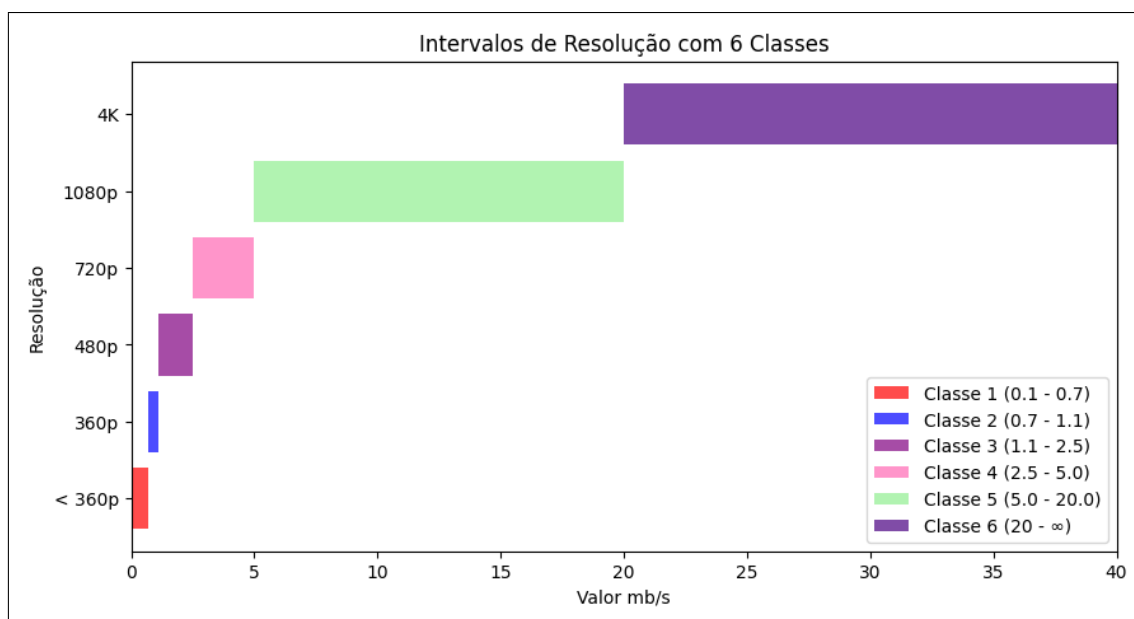


Figura 1. Definição do Intervalo das 6 classes.

Analisando esses dados da tabela acima para esse trabalho será feita uma nova linha na tabela para indicar que a algo abaixo de 0.7 Mbps, será entregue uma qualidade de vídeo menor que 360p.

3.3. Definição de Cenários de Mobilidade

Neste estudo, foram investigados dois cenários distintos: o estático e o veicular, cada um apresentando características específicas. No cenário estático, denominado "Estático", as avaliações foram conduzidas em trilhas estáticas, abrangendo locais fechados ou veículos parados. Por outro lado, no cenário veicular, identificado como "Veicular", as análises foram realizadas em trilhas que envolvem movimentos em ambientes urbanos e suburbanos. A tabela abaixo resume essas informações:

Tabela 2. Tabela de padrões de mobilidade

Tipo	Resolução	Velocidade recomendada	Classe
Entrega de qualidade baixa de vídeo	< 360p	0.1 Mbps ou mais	1
SD	360p	0.7 Mbps ou mais	2
SD	480p	1.1 Mbps ou mais	3
Alta definição (HD)	720p	2.5 Mbps ou mais	4
Máxima alta definição (FHD)	1080p	5 Mbps ou mais	5
Ultra alta definição (UHD)	4K	20 Mbps ou mais	6

Tabela 3. Tabela de padrões de mobilidade

Tipo	Sumário
Estático	Trilhas estáticas (Locais fechados ou em veículos parados)
Veicular	Trilhas em ambientes urbanos e suburbanos em movimentos

Em cada um desses cenários, iremos realizar testes com alguns dos programas do catálogo de dois dos principais serviços de streaming: Netflix e Amazon Prime Video. No contexto do Netflix, estamos considerando o provedor de serviços de streaming renomado por sua vasta oferta de conteúdo audiovisual. Já em relação ao Amazon Prime Video, este é reconhecido como o provedor de serviços de streaming associado à plataforma Amazon, e assim como o primeiro, também possui uma vasta oferta de conteúdo audiovisual.

Tabela 4. Padrões de aplicação

Tipo	Sumário
Netflix	O provedor de serviços de streaming da Netflix
Amazon Prime Video	Provedor de serviços de streaming da Amazon

3.4. Modelos de IA

Aplicamos os seguintes modelos de classificação, os quais foram otimizados através de uma busca em grade para realizar a seleção de hiperparâmetros:

- *k-Nearest Neighbors* (KNN) [Ukey et al. 2023]: é baseado em uma função de distância que mede a diferença ou similaridade entre duas instâncias. Seu viés indutivo corresponde à suposição de que a classificação de uma instância de teste será mais semelhante à classificação de outras instâncias que estão próximas no espaço euclidiano. Portanto, a definição da função de distância é crucial. No KNN, a distância euclidiana padrão é utilizada. Assim, a distância entre instâncias é calculada com base em todos os atributos da instância.
- *Árvore de Decisão* [Costa and Pedreira 2023]: é uma estrutura em forma de fluxograma, onde cada nó interno representa um teste em um atributo, cada ramo representa um resultado do teste, e cada nó folha (ou nó terminal) representa um rótulo de classe. Dado um conjunto de dados X , os valores dos atributos do conjunto de dados são testados em relação à árvore de decisão. Um caminho é traçado da raiz até um nó folha que contém a previsão de classe para o conjunto de dados. É fácil converter árvores de decisão em regras de classificação. A aprendizagem de árvores de decisão utiliza uma árvore de decisão como modelo preditivo, que mapeia observações sobre um item para conclusões sobre o valor-alvo do item.
- *Florestas Aleatórias* [Jiang et al. 2023]: esta técnica gera árvores de decisão para garantir diversidade entre as árvores de decisão base. Em particular, a cada divisão

de um nó durante a construção da árvore, um subconjunto aleatório de características é considerado para determinar a melhor divisão. Além disso, o método de amostragem bootstrap é aplicado, o que implica que cada árvore é treinada em uma subamostra única e aleatória do conjunto de dados original.

Durante o desenvolvimento dos modelos de IA adotamos a técnica de Busca em Grade, a qual definimos um conjunto finito de valores para cada hiperparâmetro, e a busca em grade avalia o produto cartesiano desses conjuntos. Isso sofre com o problema da dimensionalidade, uma vez que o número necessário de avaliações da função cresce exponencialmente com a dimensionalidade do espaço de configuração. Um problema adicional da busca em grade é que aumentar a resolução da discretização aumenta substancialmente o número necessário de avaliações da função [Hutter et al. 2019].

No entanto, enfrenta desafios significativos, como a maldição da dimensionalidade, exigindo avaliações exponencialmente crescentes à medida que os hiperparâmetros e valores aumentam, tornando-a ineficiente em espaços de alta dimensionalidade. Aumentar a resolução da discretização também amplia a carga computacional, tornando-a impraticável em problemas complexos com recursos limitados.

4. Experimentos

Esta seção irá descrever a forma avaliar os experimentos e as métricas utilizadas em cada experimento (Subseção 4.1), bem como discutir os resultados obtidos a partir desse conjunto de experimentos, utilizando dados de medição de rede reais (Subseção 4.2).

4.1. Configuração dos Experimentos

O conjunto de dados usado ¹, foi coletado usando o G-NetTrack Pro, uma ferramenta de monitoramento de rede móvel, em um dispositivo Android Samsung S10 5G. Este aplicativo permite a coleta de várias métricas, como informações de canal, contexto, célula e desempenho (uplink e downlink). A implementação de métodos de retorno de chamada para relatar os valores do canal depende do fabricante do chipset. O conjunto de dados de produção inclui 83 sessões, totalizando 3.142 minutos de tráfego coletado. A estratégia de coleta de dados envolve realizar experimentos até que o limite de dados seja atingido para cada combinação de aplicativo (download de arquivos, Netflix, Amazon Prime) e padrão de mobilidade (estático e dinâmico). Isso resulta em um número limitado de sessões, pois certos cenários consomem dados rapidamente. Por exemplo, foram capturadas apenas quatro sessões de largura de banda em um cenário estático com grandes downloads de arquivos, totalizando 160 minutos. Para testes de download de arquivos, foram utilizados arquivos grandes (> 200 MB) para permitir que a janela de envio TCP atingisse seu tamanho máximo. Para Netflix e Amazon Prime, transmitimos conteúdo de vídeo animado (cerca de 200m) e de ação ao vivo (cerca de 400m), enquanto o G-NetTrack Pro rodava em segundo plano, registrando largura de banda e informações de canal [Raca et al. 2020].

Com relação a avaliação dos modelos desenvolvidos, uma maneira usual de avaliar o desempenho de um classificador é olhar para a matriz de confusão. A ideia geral é contar o número de vezes que as instâncias da classe A são classificadas como classe B. Cada linha em uma matriz de confusão representa uma classe real, enquanto cada coluna

¹<https://github.com/uccmis/5Gdataset>

representa uma classe prevista [Géron 2017]. Será realizada uma análise detalhada das matrizes de confusão de cada modelo.

Além disso, consideramos as seguintes métricas para avaliar o desempenho da predição [Moreira et al. 2021]: Acurácia (em percentual), taxa de classificações corretas; Recall (em percentual), eficiência em detectar corretamente a entrada analisada; Precisão (em percentual), capacidade de acertar quais dos valores positivos são realmente positivos; e F1-Score (em percentual), a média harmônica da precisão e Recall.

4.2. Resultados

Os resultados são apresentados e discutidos a seguir, considerando cada um dos cenários definidos: Estático na Seção 4.2.1 e Veicular na Seção 4.2.2.

4.2.1. Cenário estático

Primeiramente iremos avaliar as matrizes de confusão, ilustradas na Figura 2, obtida pelos modelos Árvore de Decisão, Florestas Aleatórias e KNN no cenário estático. É perceptível que devido a forte ocorrência da classe 5, percebemos que os três modelos quando não conseguem diferenciar uma classe tendem a classificar o elemento como classe 5 porque é o que mais ocorre dentro da distribuição dos dados.

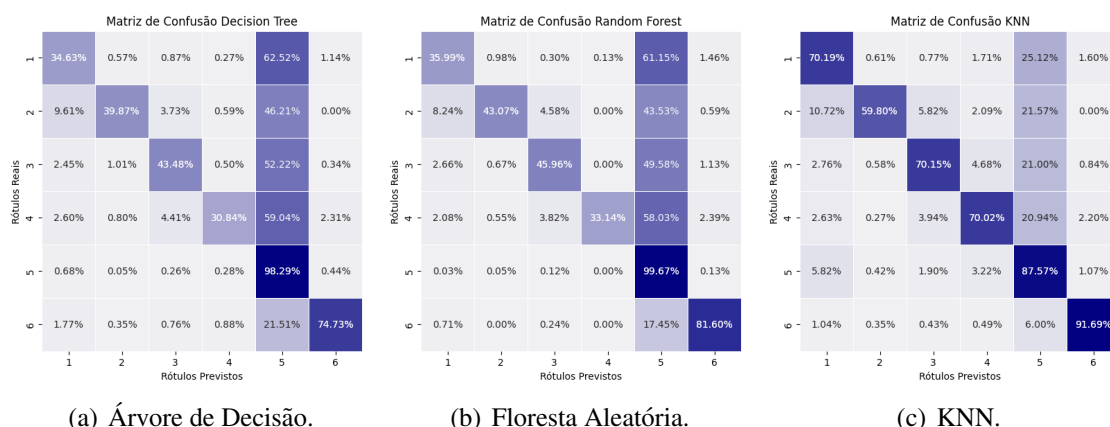


Figura 2. Matrizes de Confusão - Caso Estático

Analisando as matrizes da árvore de decisão e da floresta aleatória respectivamente percebemos que elas tiveram uma classificação bastante próxima em cada classe, acertando principalmente a classe 5. Já a matriz do KNN obteve um resultado melhor em classificar cada um das classes mostrando que o KNN, desempenha consegue classificar e diferenciar melhor cada classe.

A seguir, iremos avaliar cada modelos pelas métricas de Tempo de treinamento, Acurácia, *Precision*, *Recall*, *F1* de cada classe. Ao examinarmos os dados abrangentes na tabela de resultados, torna-se evidente uma notável discrepância nos tempos de treinamento entre os diferentes modelos. Destaca-se que o KNN alcança a mais alta acurácia entre os três, mesmo que o tempo necessário para seu treinamento seja ligeiramente superior ao da árvore de decisão, esta última caracterizada pelo menor período de treinamento.

Ao analisarmos as tabelas de classificação específicas para cada faixa geradas por cada modelo, observamos uma tendência interessante. Embora tanto a Árvore de Decisão

Tabela 5. Resultados da Árvore de Decisão

Classe	Precisão	Recall	F1-score
1	1.00	0.05	0.10
2	0.85	0.50	0.63
3	0.84	0.42	0.56
4	0.85	0.38	0.53
5	0.83	0.99	0.90
6	0.94	0.79	0.86

Tabela 6. Resultados da Floresta Aleatória

Classe	Precisão	Recall	F1-score
1	1.00	0.03	0.06
2	0.89	0.52	0.66
3	0.90	0.45	0.59
4	0.91	0.36	0.51
5	0.83	1.00	0.91
6	0.96	0.82	0.88

Tabela 7. Resultados do KNN

Classe	Precisão	Recall	F1-score
1	1.00	0.01	0.01
2	0.75	0.79	0.77
3	0.74	0.69	0.72
4	0.76	0.72	0.74
5	0.92	0.94	0.93
6	0.92	0.92	0.92

Tabela 8. Resultados gerais

Modelo	Acurácia	Tempo de Treinamento
KNN	0.88	3min
Floresta Aleatória	0.85	7min
Árvore de Decisão	0.84	1min

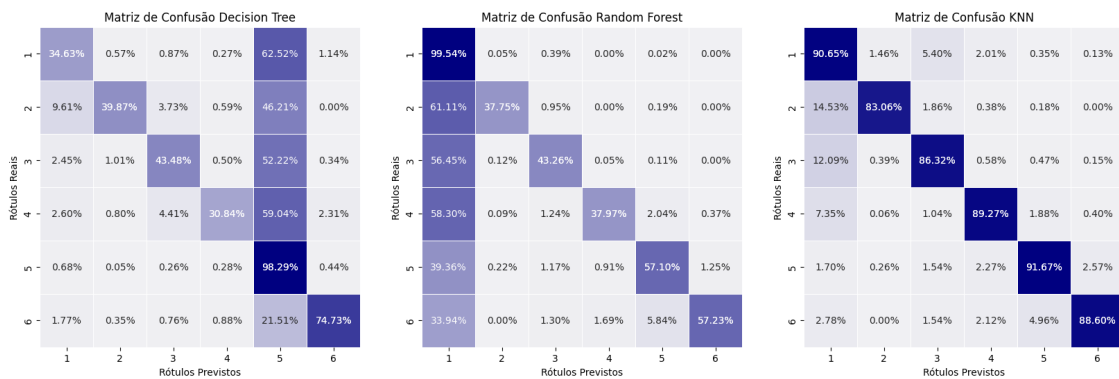
quanto as Florestas Aleatórias apresentem uma alta precisão em todas as classes, a recall e a F1 score revelam um desempenho inferior. Essa discrepância sugere que esses modelos podem estar deixando passar alguns casos que pertencem a cada classe, resultando em uma capacidade limitada de identificar todos os verdadeiros positivos. No entanto, ao direcionarmos nossa atenção para a recall e a F1 score, destacamos que o modelo KNN se destaca como o mais eficaz na classificação de cada classe, considerando o treinamento fornecido. A recall, que mede a capacidade do modelo de identificar todos os casos positivos, e a F1 score, que equilibra precisão e recall, revelam a capacidade superior do KNN em abranger de maneira abrangente todas as classes.

Essa análise sugere que, embora a precisão seja uma métrica crucial, a recall e a F1 score são igualmente importantes, especialmente em cenários em que a identificação de todos os casos positivos é fundamental. O KNN demonstra uma eficácia notável nesse aspecto, proporcionando uma visão mais abrangente e equilibrada da capacidade de classificação dos modelos considerados.

4.2.2. Cenário Veicular

Agora será iremos avaliar as matrizes de confusão, ilustradas na Figura 3, dos modelos Árvore de Decisão, Florestas Aleatórias e KNN no cenário veicular. Ao examinar as diagonais principais da Árvore de Decisão e da Floresta Aleatória, notamos que esses modelos tiveram um desempenho um pouco inferior em comparação com o cenário estático, mas ainda assim conseguiram apresentar um bom desempenho, classificando de maneira aceitável as outras classes.

Ao analisar a diagonal principal do KNN, observamos que ele teve um desempenho excelente, conseguindo classificar eficientemente cada classe e acertando a maioria dos testes para cada classe individualmente. E assim como no cenário estático quando os



(a) Árvore de Decisão.

(b) Floresta Aleatória.

(c) KNN.

Figura 3. Matrizes de Confusão - Caso Veicular

modelos não tiveram sucesso em classificar uma classe corretamente, eles classificaram a mesma como classe 1 porque é a classe que mais aparece neste cenário.

A seguir, iremos avaliar cada modelo pelas métricas de Tempo de treinamento, Acurácia, *Precision*, *Recall*, *F1* de cada classe no cenário veicular. Ao analisarmos a tabela de resultados gerais, observamos uma significativa disparidade nos tempos de treinamento entre os modelos. Notavelmente, o KNN apresenta a melhor acurácia entre os três, embora seu tempo de treinamento seja ligeiramente superior ao da árvore de decisão, que, por sua vez, detém a menor duração de treinamento.

Tabela 9. Resultados da Árvore de Decisão

Classe	Precisão	Recall	F1-score
1	0.65	0.97	0.71
2	0.79	0.34	0.63
3	0.81	0.41	0.55
4	0.88	0.36	0.51
5	0.84	0.53	0.65
6	0.85	0.48	0.62

Tabela 10. Resultados da Floresta Aleatória

Classe	Precisão	Recall	F1-score
1	0.65	1.00	0.79
2	0.96	0.38	0.54
3	0.95	0.43	0.59
4	0.96	0.38	0.54
5	0.92	0.57	0.70
6	0.94	0.57	0.71

Tabela 11. Resultados do KNN

Classe	Precisão	Recall	F1-score
1	0.91	0.91	0.91
2	0.85	0.83	0.84
3	0.86	0.86	0.86
4	0.85	0.89	0.87
5	0.93	0.92	0.92
6	0.90	0.89	0.89

Tabela 12. Resultados gerais

Modelo	Acurácia	Tempo de Treinamento
KNN	0.89	3min
Floresta Aleatória	0.72	8min
Árvore de Decisão	0.70	2min

Ao examinarmos essas tabelas, notamos que os valores de precisão dos modelos são bastante próximos. No entanto, ao avaliarmos a *recall* e a *F1*, torna-se evidente que o KNN supera significativamente os demais em termos de desempenho na classificação de cada classe. Essa disparidade entre os modelos na *recall* e *F1* destaca a importância de uma análise mais abrangente na avaliação de desempenho. Enquanto a precisão inicialmente pode sugerir similaridade entre os modelos, a consideração mais aprofundada

de métricas como recall e F1 score revela nuances cruciais. O KNN, ao exibir um desempenho notavelmente superior na identificação de todos os casos positivos em cada classe, destaca-se como uma escolha mais robusta em cenários onde a abrangência na detecção é essencial. Essa compreensão refinada das métricas de avaliação contribui para uma tomada de decisão mais informada na escolha do modelo mais adequado para uma determinada tarefa de classificação.

4.3. Discussão Final

Com base nos resultados deste estudo, podemos inferir que a tecnologia 5G demonstra uma notável capacidade de proporcionar uma experiência de alta qualidade em cenários estáticos, especialmente quando se trata do consumo de streaming de vídeo. A eficaz entrega de streamings de vídeo sugere que o 5G surge como uma solução promissora para atender às crescentes demandas de transmissão de mídia em ambientes estáticos.

No entanto, a transição para cenários veicular revela uma variação considerável na qualidade da experiência do usuário, com a entrega frequentemente apresentando qualidade inferior, especialmente para usuários em movimento, como os streamers. É importante ressaltar que este estudo não abordou alguns fatores relevantes, como o posicionamento das antenas, que poderiam influenciar significativamente a qualidade da experiência móvel. A distância do usuário em relação às antenas, por exemplo, pode desempenhar um papel crucial na entrega eficaz de serviços em movimento.

Além disso, ao considerar as conclusões relacionadas à classificação, é essencial ponderar sobre a desigualdade na distribuição dos dados. Essa disparidade pode impactar os resultados, levando os modelos a prever de maneira mais eficaz os cenários em que os dados são mais recorrentes. Portanto, futuras investigações devem abordar essas lacunas e considerar uma variedade de variáveis para uma compreensão mais abrangente e precisa do desempenho da tecnologia 5G em diferentes contextos.

5. Conclusão

A chegada das redes 5G desencadeou uma transformação marcante na sociedade contemporânea, destacando um crescimento notável, especialmente no campo da transmissão de vídeos em tempo real e nos serviços de streaming. No entanto, mesmo com os avanços, os usuários ainda enfrentam desafios relacionados à qualidade inadequada de vídeo, especialmente quando as características de transmissão das redes 5G apresentam variações. Nesse cenário, este artigo propõe um modelo de Inteligência Artificial (IA) para prever a qualidade do vídeo entregue ao usuário final. O modelo proposto abrange tanto cenários estáticos quanto dinâmicos em dispositivos veiculares, reconhecendo a importância de compreender a entrega de conteúdo de acordo com a situação do usuário. A abordagem deste trabalho utiliza dados reais de medições de redes 5G, permitindo a otimização da experiência do usuário em ambientes 5G dinâmicos. Os resultados evidenciam que a proposta é eficaz para contribuir para o aprimoramento contínuo da entrega de qualidade de vídeo no contexto de redes móveis.

Para futuros trabalhos, é recomendável realizar uma nova coleta de dados e obter uma compreensão atualizada da implantação do 5G na localização em questão. Isso é essencial, pois o sucesso do 5G pode ser impactado pela infraestrutura e pelo posicionamento das antenas. Uma análise detalhada desses fatores pode ser crucial para garantir que o 5G atenda às suas propostas de maneira eficaz.

Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) (*N*º 303877/2021-9 e *N*º 405976/2022-4) pelo apoio financeiro.

Referências

- Alam, T. (2018). A reliable communication framework and its use in internet of things (iot). *CSEIT1835111— Received*, 10:450–456.
- Costa, V. G. and Pedreira, C. E. (2023). Recent advances in decision trees: An updated survey. *Artificial Intelligence Review*, 56(5):4765–4800.
- Costa, W. L., Silveira, M. M., de Araujo, T., and Gomes, R. L. (2020). Improving ddos detection in iot networks through analysis of network traffic characteristics. In *2020 IEEE Latin-American Conference on Communications (LATINCOM)*, pages 1–6.
- da Silva, G., Oliveira, D., Gomes, R. L., Bittencourt, L. F., and Madeira, E. R. M. (2020). Reliable network slices based on elastic network resource demand. In *NOMS 2020 - 2020 IEEE/IFIP Network Operations and Management Symposium*, pages 1–9.
- Duanmu, Z., Liu, W., Chen, D., Li, Z., Wang, Z., Wang, Y., and Gao, W. (2023). A bayesian quality-of-experience model for adaptive streaming videos. *ACM Trans. Multimedia Comput. Commun. Appl.*, 18(3s).
- Elsherbiny, H., Abbas, H. M., Abou-zeid, H., Hassanein, H. S., and Noureldin, A. (2020). 4g lte network throughput modelling and prediction. In *GLOBECOM 2020-2020 IEEE Global Communications Conference*, pages 1–6. IEEE.
- Gomes, R., Bittencourt, L., Madeira, E., Cerqueira, E., and Gerla, M. (2017). Management of virtual network resources for multimedia applications. *Multimedia Systems*, 23(4):405–419.
- Gomes, R., Junior, W., Cerqueira, E., and Abelem, A. (2010). A qoe fuzzy routing protocol for wireless mesh networks. In Zeadally, S., Cerqueira, E., Curado, M., and Leszczuk, M., editors, *Future Multimedia Networking*, pages 1–12, Berlin, Heidelberg. Springer Berlin Heidelberg.
- Gomes, R. L., Bittencourt, L. F., Madeira, E. R., Cerqueira, E., and Gerla, M. (2016). A combined energy-bandwidth approach to allocate resilient virtual software defined networks. *Journal of Network and Computer Applications*, 69:98–106.
- Gomes, R. L., Bittencourt, L. F., and Madeira, E. R. M. (2020). Reliability-aware network slicing in elastic demand scenarios. *IEEE Communications Magazine*, 58(10):29–34.
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O’Reilly Media.
- Hutter, F., Kotthoff, L., and Vanschoren, J. (2019). *Automated machine learning: methods, systems, challenges*. Springer Nature.
- Irina, S., Irina, S., and Anastasiya, M. (2020). Forecasting 5g network multimedia traffic characteristics. In *2020 IEEE 15th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, pages 982–987.

- Jiang, M., Wang, J., Hu, L., and He, Z. (2023). Random forest clustering for discrete sequences. *Pattern Recognition Letters*, 174:145–151.
- Kao, H.-W. and Wu, E. H.-K. (2023). Qoe sustainability on 5g and beyond 5g networks. *IEEE Wireless Communications*, 30(1):118–125.
- Kousias, K., Rajiullah, M., Caso, G., Ali, U., Alay, O., Brunstrom, A., De Nardis, L., Neri, M., and Di Benedetto, M.-G. (2023). A large-scale dataset of 4g, nb-iot, and 5g non-standalone network measurements. *IEEE Communications Magazine*.
- Moreira, D. A., Marques, H. P., Costa, W. L., Celestino, J., Gomes, R. L., and Nogueira, M. (2021). Anomaly detection in smart environments using ai over fog and cloud computing. In *2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC)*, pages 1–2. IEEE.
- Nightingale, J., Salva-Garcia, P., Calero, J. M. A., and Wang, Q. (2018). 5g-qoe: Qoe modelling for ultra-hd video streaming in 5g networks. *IEEE Transactions on Broadcasting*, 64(2):621–634.
- Oliveira, D. H. L., Filho, F. M. V., de Araújo, T. P., Celestino, J., and Gomes, R. L. (2020). Adaptive model for network resources prediction in modern internet service providers. In *2020 IEEE Symposium on Computers and Communications (ISCC)*, pages 1–6.
- Portela, A. L., Menezes, R. A., Costa, W. L., Silveira, M. M., Bittecourt, L. F., and Gomes, R. L. (2023). Detection of iot devices and network anomalies based on anonymized network traffic. In *NOMS 2023-2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–6.
- Portela, A. L. C., Ribeiro, S. E. S. B., Menezes, R. A., de Araujo, T., and Gomes, R. L. (2024). T-for: An adaptable forecasting model for throughput performance. *IEEE Transactions on Network and Service Management*, pages 1–1.
- Raca, D., Leahy, D., Sreenan, C. J., and Quinlan, J. J. (2020). Beyond throughput, the next generation: a 5g dataset with channel and context metrics. In *Proceedings of the 11th ACM multimedia systems conference*, pages 303–308.
- Riiser, H., Vigmostad, P., Griwodz, C., and Halvorsen, P. (2013). Commute path bandwidth traces from 3g networks: analysis and applications. In *Proceedings of the 4th ACM Multimedia Systems Conference*, pages 114–118.
- Silveira, M. M., Portela, A. L., Menezes, R. A., Souza, M. S., Silva, D. S., Mesquita, M. C., and Gomes, R. L. (2023). Data protection based on searchable encryption and anonymization techniques. In *NOMS 2023-2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–5.
- Ukey, N., Yang, Z., Li, B., Zhang, G., Hu, Y., and Zhang, W. (2023). Survey on exact knn queries over high-dimensional data space. *Sensors*, 23(2):629.
- Zhang, H., Dong, L., Gao, G., Hu, H., Wen, Y., and Guan, K. (2020). Deepqoe: A multimodal learning framework for video quality of experience (qoe) prediction. *IEEE Transactions on Multimedia*, 22(12):3210–3223.