

## Algoritmo VQM-SSIM para Avaliação da Degradação da Qualidade de Conteúdo Multimídia Transmitido por Dispositivo *Android*

Marcia dos Santos de Sa<sup>1,2</sup>, Jucicarla Pires Barbosa<sup>1</sup>, Ewerton M. Barbosa<sup>1</sup>, Luiz Eduardo S. de Araújo<sup>1</sup>, Walter Seiffert Simões<sup>1,2</sup>

<sup>1</sup>ICOMP - Instituto de Computação - Universidade Federal do Amazonas - UFAM – 69.067-005 – Manaus – AM – Brazil (e-mail: jucipiris@gmail.com, ewerton.linfest@gmail.com, 14eduard@gmail.com)

<sup>2</sup>CESAR - Centro de Estudos e Sistemas Avançados de Recife - Manaus - AM - Brazil, (e-mail: marcia.santos@cesar.org.br, wcsss@cesar.org.br)

---

*Abstract: Currently, streaming video content is subjectively evaluated by smartphone manufacturers to indicate potential flaws perceived in receiving the content. However, many flaws are not noticed and can generate unpleasant effects for the end user if they are not worked on. This paper proposes to use Artificial Intelligence (AI) techniques to align the user's visual demands with an objective evaluation. The applied methodology consists of combining the Video Quality Metric (VQM) and Structural Similarity Index (SSIM) algorithms by means of AI techniques, in order to provide an indication of the degradation of the multimedia content without the interference of possible transmission noise in the data network. The results show a level of accuracy in the similarity analysis of static multimedia structure at 99.42% and 99.10% for dynamic media, consumed in test time. The major contribution of this work is in the computing society, which will be able to apply an objective tool in the evaluation of multimedia content.*

**Resumo:** Atualmente os conteúdos de *streaming* de vídeo são avaliados pelos fabricantes de *smartphones* de forma subjetiva para indicar possíveis falhas percebidas no recebimento do conteúdo. Porém, muitas falhas não são percebidas e podem gerar efeitos desagradáveis ao usuário final, caso não sejam trabalhadas. Este artigo propõe utilizar técnicas de Inteligência Artificial (IA) para alinhar as demandas *visuais do usuário a uma avaliação objetiva*. A metodologia aplicada consiste em combinar os algoritmos *Video Quality Metric* (VQM) e *Structural Similarity Index* (SSIM) por meios de técnicas de IA, a fim de fornecer uma indicação de degradação do conteúdo multimídia sem a interferência de eventuais ruídos da transmissão na rede de dados. Os resultados obtidos mostram um nível de acerto na análise de similaridade de estrutura de multimídia estática em 99,42% e 99,10% para mídias dinâmicas, consumidas em tempo de teste. A principal contribuição deste trabalho é com a sociedade de computação, que poderá aplicar uma ferramenta objetiva na avaliação de conteúdo multimídia.

**Keywords:** *Video Quality, SSIM, PSNR, Linear Regression, Chaquopy.*

**Palavras-chaves:** Qualidade de Vídeo, SSIM, PSNR, Regressão Linear, Chaquopy.

---

### 1. INTRODUÇÃO

Com a evolução de novas tecnologias notou-se um aumento significativo no uso de plataformas digitais com o intuito de proporcionar uma melhor experiência no consumo de conteúdos nos formatos sonoros e visuais (UKOMMI *et al.*, 2020). Este conteúdo pode representar desde documentos multimídia fornecidos através de portais de *streaming* até ferramentas de segurança e outras aplicações mais críticas (BROSS *et al.*, 2021). Independente de qual o objetivo final do uso do conteúdo multimídia, seu público consumidor tem sido bastante rigoroso quanto a qualidade recebida, o que exige que tanto quem produz os conteúdos, como quem fornece os ambientes físicos, lógicos e de transmissão entendam e possam aplicar novas abordagens e ferramentas (SARA *et al.*, 2019).

Entendendo que é necessário conhecer a qualidade de um conteúdo multimídia a partir do dispositivo móvel, o problema

desta pesquisa é definido por: Como avaliar a qualidade de um conteúdo multimídia transmitido por *smartphone* com o sistema *Android*?

A hipótese considerada para ser tratada ao longo desta pesquisa foi de que a aplicação de métodos de varredura ao longo dos conteúdos multimídia inicial e o transmitido possam fornecer uma nota referente a qualidade.

O restante deste trabalho está organizado da seguinte forma: na Seção 2 é apresentado um conjunto de trabalhos relacionados que apontam técnicas e ferramentas que ajudam a entender as possibilidades de resolução do problema. Na Seção 3 é apresentada formalmente a arquitetura deste trabalho. Na Seção 4 são executados processos avaliativos para indicar como este estudo se posiciona em relação aos trabalhos relacionados. Na Seção 5 é descrita a conclusão, trazendo o resultado mais significativo.

## 2. REVISÃO DAS METODOLOGIAS E TECNOLOGIAS DE CODIFICAÇÃO DE MULTIMÍDIA

A seleção de trabalhos relacionados é uma etapa importante para indicar a força de uma pesquisa desenvolvida. Por esta razão, neste trabalho foi adotada a revisão sistemática, que indica aplicação de uma série de filtros, que vão desde a leitura do título e resumo (filtro 1) até a indicação de que os autores trataram de problemas iguais ou similares ao aqui proposto, apresentando suas metodologias e critérios avaliativos (filtro 2) (MACEDO *et al.*, 2022). Assim, os trabalhos resultantes da aplicação da revisão sistemática são apresentados a seguir.

Bross e seus co-autores trouxeram uma visão geral do padrão de codificação de vídeo de alta eficiência (HEVC), utilizando o novo padrão internacional de codificação de vídeo desenvolvido pela Joint Vídeo Experts Team (JVET) e pelo ISO/IEC *Moving Picture Experts Group* (MPEG) (BROSS *et al.*, 2021). Este novo padrão busca atender a uma necessidade cada vez maior de compressão de vídeo aprimorada, bem como para oferecer suporte a uma ampla variedade de conteúdo de mídia atual e aplicativos emergentes. No estudo, Bross indica que a utilização dos novos codecs trazem reduções significativas na taxa de *bits* em torno de 50% em relação ao seu antecessor para qualidade de vídeo semelhante, o padrão HEVC (*High Efficiency Video Coding*), e cerca de 75 % sobre o formato mais usado atualmente, o padrão *Advanced Video Coding* (AVC).

Sani direcionou seu estudo para o entendimento do impacto da qualidade de um conteúdo multimídia submetido a transmissão em redes sem fio. Neste estudo, os autores avaliaram os protocolos de rede, além dos processos de compressão e modificação de elementos que compõem o documento multimídia, que buscam manter um aspecto de normalidade ao usuário que tenta avaliar a olho nu qualquer diferença entre o conteúdo transmitido e o recebido (SANI *et al.*, 2017). Os autores utilizaram como ambiente o HTTP *Adaptive Streaming* (HAS) que permite a experimentação de transmissão de conteúdo multimídia sem a necessidade de construção de uma infraestrutura dedicada, e o *Adaptive Bitrate Selection* (ABR), que permite avaliar a qualidade do conteúdo multimídia do lado do cliente. Os autores conseguiram relacionar a taxa de transmissão do bitrate à duração de transmissão, e que no modo bruto o conteúdo consome entre 200% a 300% a mais de armazenamento (utilização de *buffers*) para manter a alta qualidade.

Yan e seus co-autores adotaram um processo avaliação da qualidade do vídeo com base na medição da distorção estrutural, aplicando o algoritmo SSIM (*Structural Similarity*), que permite identificar variações entre dois conteúdos multimídia a partir da similaridade entre eles (YAN *et al.*, 2021). Os autores partiram da premissa de que a maioria das abordagens de avaliação de qualidade propostas na literatura são métodos baseados na sensibilidade ao erro, e que é possível também investigar a qualidade de conteúdos multimídia utilizando a distorção estrutural como uma estimativa da distorção visual percebida.

Yi e seus co-autores desenvolveram um estudo da qualidade da imagem, considerando a necessidade de mostrar ao usuário erros visíveis a partir da análise de semelhança estrutural

obtida pelo algoritmo SSIM (YI *et al.*, 2019). Como cenário de experimentação, os autores aplicaram a análise sobre o consumo de imagens médicas utilizando como parâmetros a reconstrução de imagem, segmentação, detecção, classificação e síntese de modalidade cruzada. O estudo indica que alguns erros previamente inseridos na mídia só foram percebidos por apenas 6,1% dos observadores humanos, enquanto que o algoritmo conseguiu indicar diferenças mais graves ou sutis em cerca de 77,5%.

Ukommi desenvolveu um estudo sobre a distribuição de recursos baseado em movimento de mídia para rede de vídeo móvel (UKOMMI, 2020). O autor utilizou como base o *Media Motion-based Resource Distribution* (MRD), para maximizar a qualidade média do vídeo recebido no sistema sem fio, regulando a distribuição de recursos dos fluxos de mídia com base em suas características de atividade de movimento. Como parâmetros, eram observados os valores de força de sinal por RSSI, o ruído que a rede gerava sobre o conteúdo (SNR), ambos medidos em dB. O impacto da melhoria e controle do canal de redes trouxe uma redução de impacto sobre a degradação do conteúdo multimídia em torno de 12,7%, saindo de uma faixa de entrega de 28,2 dB para 32 dB.

A análise dos trabalhos aqui apresentados é confrontada em relação aos seus métodos e tecnologias, dispostos na Tabela 1.

Tabela 1. Referência Cruzada dos Trabalhos Relacionados.

Autores	HEVC	AVC	HTTP Adapt	ABR	SSIM	Distorção visual
BROSS <i>et al.</i> , 2021	x	x	-	-	-	-
SANI <i>et al.</i> , 2017	-	-	x	x	-	-
YAN <i>et al.</i> , 2021	-	-	-	-	x	x
YI <i>et al.</i> , 2019	-	-	-	-	x	-
UKOMMI 2020	-	-	x	-	-	-
<b>Este Trabalho</b>	-	-	-	-	x	x

As escolhas das técnicas SSIM e a análise da distorção do conteúdo visual do documento multimídia devem-se aos principais critérios avaliativos indicados pelos autores dos trabalhos relacionados ao tema. As técnicas foram selecionadas por considerar que atualmente o principal modo de inspeção utilizado por testadores e pelos consumidores de conteúdos multimídia utilizam estas duas estratégias para definir ou entender que o conteúdo multimídia recebido manteve a qualidade ou não esperada.

Este conjunto de escolhas está representado na arquitetura da Seção de Metodologia, onde cada etapa é detalhada para permitir um entendimento sobre a abordagem dada nesta pesquisa.

## 3. METODOLOGIA

A metodologia aplicada é a de combinar os algoritmos SSIM (*Structural Similarity Index*) para fornecer a indicação de degradação do conteúdo multimídia sem a interferência de eventuais ruídos da transmissão na rede de dados e a análise

de vídeo baseado na verificação de qualidade, utilizando uma abordagem de IA (Inteligência Artificial), pelo método de regressão linear. A arquitetura mostrada na Fig. 1 indica as etapas necessárias para que a combinação dos algoritmos VQM e SSIM permitam levantar uma nota da qualidade do streaming a ser submetido à análise de qualidade.

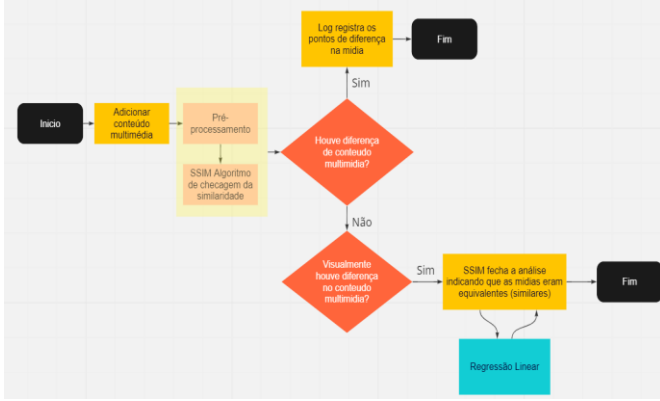


Fig. 1. Arquitetura Geral.

### 3.1 Adicionar conteúdo multimídia

A etapa de adição de conteúdo multimídia permite que o usuário ou testador possa utilizar uma mídia padrão para fazer a execução de inspeção de qualidade, tendo um conteúdo previamente preparado para ser utilizado nas comparações entre o conteúdo transmitido e o conteúdo recebido.

### 3.2 Pré-processamento

A etapa de pré-processamento representa a verificação das características do conteúdo multimídia em relação à *largura x altura*, quantidade de frames a serem transmitidos, o padrão de formato do conteúdo. A coleta ocorre através *Wireshark*, que é uma ferramenta de análise de tráfego de rede. Quando o *Wireshark* captura pacotes de dados de multimídia, ele armazena essas informações em sua forma original, que é binária. No entanto, para visualizar esses dados e repassar para os algoritmos de análise de vídeo, será necessário utilizar a ferramenta *SCAT (Signaling Collection and Analysis Tool)*, que converte os dados binários em dados digitais (SARA *et al.*, 2019).

### 3.3 Análise de vídeo

Para assegurar que um vídeo transmitido por dispositivos móveis manteve sua integridade e qualidade, são aplicados inúmeros processos que observam características como foco, coloração, contraste, definição luminosidade, perda de informações, *noise range*, congelamento, vibração, etc. (YI *et al.*, 2019). Estes itens podem ser percebidos individualmente ou através de técnicas que executam varreduras ao longo do arquivo de base e o transmitido, detectando as anormalidades e indicando taxas de resposta. O algoritmo utilizado para checar as mudanças de conteúdo dentro destas características é o *SSIM (Structural Similarity Index)* (SARA *et al.*, 2019).

O *SSIM* adota como critério fatores perceptivos importantes, incluindo luminância, contraste e informações estruturais no

sistema métrico. Os três componentes produzem um peso de similaridade geral (YAN *et al.*, 2021). Formalmente, a estrutura do *SSIM* utilizado neste estudo utilizou a formulação dada pela equação (1).

$$S(a, b) = f\{L(a, b), C(a, b), S(a, b)\} \quad (1)$$

onde,  $L(a, b)$ ,  $C(a, b)$  e  $S(a, b)$  representam a luminância, contraste e componentes estruturais respectivamente. A comparação de luminância é definida por:

$$L(a, b) = \frac{2\mu_a\mu_b + C_1}{\mu_a^2 + \mu_b^2 + C_1} \quad (2)$$

onde  $\mu_a$  e  $\mu_b$  representam os *pixels* nas amostras originais e de teste. A constante  $C_1$  é expressa como:

$$C_1 = (K_1L)^2 \quad (3)$$

onde  $K_1 = 0,01$  e  $L$  representa a faixa dinâmica dos valores de *pixels*, dados por:

$$L = (x^2 - 1) \quad (4)$$

A comparação de contraste é definida por:

$$C(a, b) = \frac{2\sigma_a\sigma_b + C_2}{\sigma_a^2 + \sigma_b^2 + C_2} \quad (5)$$

onde os parâmetros  $\sigma_a$  e  $\sigma_b$  são a variância de  $a$  e variação de  $b$ . A constante  $C_2$  é dada por:

$$C_2 = (K_2l)^2 \text{ e } K_2 = 0,03 \quad (6)$$

A comparação estrutural é calculada após subtração de luminância e normalização de variância, definida por:

$$S(a, b) = \frac{\sigma_{ab} + C_3}{\sigma_a\sigma_b + C_3} \quad (7)$$

Onde  $\sigma_{ab}$  é a covariância de  $a$  e  $b$ , respectivamente.

A combinação de luminância, contraste e estrutura de comparação formam a estrutura do índice de similaridade (*SSIM*) entre os sinais  $a$  e  $b$ :

$$SSIM(a, b) = [L(a, b)]^\alpha \times [C(a, b)]^\alpha \times [S(a, b)]^\gamma \quad (8)$$

Onde  $\alpha > 0$ ,  $\beta > 0$  e  $\gamma > 0$  estão modificando os parâmetros de luminância, contraste e da estrutura de componentes. Para expressão simplificada,  $\alpha = \beta = \gamma = 1$  e  $C_3 = C_2/2$ . Assim, o índice *SSIM* pode ser simplificado:

$$SSIM(a, b) = \frac{(2\mu_a\mu_b + C_1)(2\sigma_{ab} + C_2)}{(\mu_a^2 + \mu_b^2 + C_1)(\sigma_a^2 + \sigma_b^2 + C_2)} \quad (9)$$

Nesta pesquisa, o valor médio da estimativa do *SSIM* em toda a sequência de vídeo de teste é usado na avaliação do desempenho geral da qualidade do vídeo de teste.

### 3.4 Verificação de impacto da qualidade de conteúdo transmitido

A etapa de verificação de impacto de conteúdos permite aplicar mensurações da diferença absoluta ou quadrada entre a versão distorcida dos quadros e sua versão de referência. Os valores médios são calculados utilizando como referência o conjunto de métricas estabelecidas em ITU-T Rec. J.247 (YI

*et al.*, 2019). O nível de conformidade do VQM ITU-T Rec. J.247 é alto devido à aplicabilidade internacional e à alta qualidade garantida pelo secretariado da ITU-T, membros das principais empresas de tecnologia da informação e comunicação (TIC) do mundo e administrações globais (SANI, *et al.*, 2017).

Existem mais de 4.000 Recomendações (Rec) em vigor sobre tópicos desde a definição de serviço até a arquitetura e segurança de rede, de DSL de banda larga a sistemas de transmissão óptica Gbit/s, redes de próxima geração (NGN) e questões relacionadas a IP. Mas, para este estudo, serão consideradas as recomendações direcionadas a avaliação visual do conteúdo.

A norma ITU-T P.910 (07/2022) trata dos métodos subjetivos de avaliação de qualidade de vídeo para aplicações multimídia, principalmente para conteúdos operados a partir de um *smartphone* (SARA, *et al.*, 2019). O ITU-T P.910 descreve métodos de avaliação subjetiva não interativa para avaliar a qualidade geral de vídeo unidirecional para aplicativos multimídia, como aplicativos de videoconferência, armazenamento e recuperação, bem como aplicativos de telemedicina. Esses métodos podem ser usados para diversas finalidades, incluindo a seleção de algoritmos, classificação do desempenho do sistema audiovisual e avaliação do nível de qualidade durante uma conexão audiovisual. A recomendação ITU-T P.910 também descreve as características, como duração, tipo de conteúdo e número de sequências, das sequências de origem a serem utilizadas (SANI *et al.*, 2017). Assim, o algoritmo implementado executa uma varredura no conteúdo multimídia buscando distorções com a aplicação de filtro de Sobel e diferença absoluta de *frames*, onde o resultado esperado é um valor binário, sendo o 0 (zero) a equivalência total entre os dois conteúdos e 1 (um) o indicativo que algo diferente foi detectado.

A implementação do algoritmo de VQL é baseado no recurso de diferença de movimento,  $Mn(i, j)$ , que é a diferença entre os valores de pixel (do plano de luminância) no mesmo local no espaço, mas em tempos ou quadros sucessivos.  $Mn(i, j)$  como um função do tempo ( $n$ ) é definida como:

$$M_n(i, j) = F_n(i, j) - F_{n-1}(i, j) \quad (10)$$

Aqui  $F_n(i, j)$  é o *pixel* na  $i$ -ésima linha e na  $j$ -ésima coluna do  $n$ -ésimo quadro no tempo.

A medida TI é calculada como o máximo ao longo do tempo (maxtime) do SD ao longo do espaço ( $\sigma_{space}$ ) de  $Mn(i, j)$  sobre todo  $i$  e  $j$ :

$$TI = \max_{time} \{ \sigma_{space} [ Mn(i, j) ] \} \quad (11)$$

Mais movimento em quadros adjacentes resultará em valores mais altos de TI. Assim, para manter a performance do algoritmo de avaliação para cenas que contenham cortes de cena, dois valores podem ser fornecidos: um onde o corte de cena é incluído na medição de TI e outro onde é excluído.

### 3.5 Análise de dados com métricas de IA

A análise de dados com métricas de IA utilizando regressão linear para análise de vídeo é uma abordagem intrigante para

extrair informações relevantes de vídeos. A Fig. 2, exibe as etapas para analisar os dados coletados.




Fig. 2. Arquitetura da análise de dados com métrica de IA.

A regressão linear é um método estatístico que busca estabelecer uma relação linear entre uma variável dependente e uma ou mais variáveis independentes, permitindo fazer previsões ou inferências com base em dados supervisionados (DAUTOV *et al.*, 2022). Contudo, existem diferentes tipos de regressão linear, para o projeto será utilizado o tipo de regressão linear simples. O próximo passo é treinar o modelo. E isso envolve ajustar a linha de regressão aos dados coletados, identificando os melhores coeficientes que minimizem a diferença entre os valores reais e os previstos pelo modelo. Após o treinamento, será utilizado o Erro Médio Quadrático (EMQ) para a avaliação do modelo. Por fim, como base nas métricas de avaliação, será possível interpretar os resultados e fazer conclusões do modelo de regressão linear em conjunto com as variáveis estudadas.

### 3.6 Visualização da nota de qualidade

Os dados são disponibilizados em uma interface Android, produzida pela IDE do *Android Studio*. Entretanto, os algoritmos de análise e de IA estão construídos em linguagem Python, que é incompatível com o Android. Por este motivo, é adotado o Chaquopy, um *plugin* para *Android Studio* que permite integrar codificações Python em projetos *Android* (DOUTOV *et al.*, 2022).

## 4. AVALIAÇÃO

Para avaliar o uso do algoritmo de avaliação de similaridade estrutural em cenário real, utilizando rede de dados para a transmissão do conteúdo multimídia, o SSIM (*Structural Similarity Index*) foi combinado com um algoritmo de PSNR (*Peak Signal-to-Noise Ratio*), que avalia o impacto dos ruídos da rede sobre os conteúdos transmitidos. O PSNR expressa a relação sinal-ruído de pico, utilizado para definir a relação entre a máxima energia de um sinal e o ruído que afeta sua representação fidedigna (SARA *et al.*, 2019).

Para validar a proposta indicada na metodologia, foi realizada a montagem experimental para estudar o desempenho dos sistemas métricos de multimídia PSNR (*Peak Signal-to-Noise Ratio*), SSIM (*Structural Similarity Index*) e a validação através do modelo de regressão linear.

As amostras de sequência de teste padrão, estabelecido com o uso de uma mídia construída para fornecer os indicadores, foram utilizadas no experimento. A configuração de modulação inclui esquema de modulação de amplitude em quadratura (16QAM) com taxa de código de 1/2. A simulação

de canal foi realizada para examinar o impacto dos erros de transmissão no desempenho de qualidade de aplicativos multimídia em canais sem fio.

A sequência de teste está no formato YUV (4:2:0), *Common Intermediate Format* (CIF) de resolução 352x288 com 30 fps, composta por 300 quadros. A escolha das amostras de teste é feita para observar o desempenho das métricas em amplas amostras de vídeo com diferentes atividades temporais. A análise temporal das amostras da sequência de teste foi avaliada usando o algoritmo de característica de movimento de mídia, discutido em (BROSS *et al.*, 2021).

As simulações de canal foram realizadas usando *error traces* que modelam o canal sem fio. As simulações foram realizadas em várias configurações de *bitrates*, com as seguintes definições: 1,92Mbps, 3,84Mbps, 5,76Mbps e 7,68Mbps. Estas configurações representam diferentes condições de rede para facilitar uma análise de desempenho de melhor qualidade.

Na extremidade receptora, o decodificador reconstrói o fluxo de mídia de teste compactado na ordem apropriada. A informação do cabeçalho é decodificada primeiro no fluxo de mídia de teste decodificado, seguido pelo quadro de reconstrução idêntico ao quadro original previsto gerado no codificador. O quadro previsto é então adicionado à diferença relativa para criar uma réplica aproximada do quadro original. Em caso de perdas, o algoritmo de ocultação de erros é aplicado para ocultar os dados perdidos, prevendo e reconstruindo os dados perdidos a partir das informações decodificadas anteriormente. O *setup* experimental é apresentado na Fig. 3.

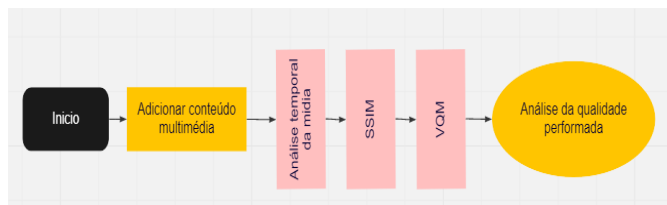


Fig. 3. Setup do experimento

A análise temporal estima a atividade temporal das amostras de sequência de teste. O desempenho de qualidade dos mediastreams é analisado usando as ferramentas SSIM e de distorção de conteúdo multimídia utilizando filtro Sobel. O processo de calibração SSIM compreende um sistema automatizado de medição de qualidade de vídeo objetivo.

O recurso é definido como a quantidade de informação extraída de uma sub-região espaço-temporal do fluxo de mídia. Considera-se recurso nesta pesquisa as funções do espaço e do tempo que caracterizam mudanças nas propriedades espaciais, temporais e de crominância dos fluxos de mídia.

Os parâmetros de qualidade do VQM que medem distorções na qualidade de vídeo devido a ganhos e perdas nos valores de recursos são calculados comparando recursos extraídos do fluxo de mídia processado calibrado com recursos extraídos do fluxo de mídia original. O diferencial da comparação retrata a mudança perceptiva na qualidade multimídia. A magnitude do comprometimento varia de 0 a 100, feita pelos algoritmos SSIM e VQM variam entre 0 e 1, onde quanto maiores os valores de SSIM, melhor o desempenho da qualidade, e

quando o VQM indica o valor zero, significa que o conteúdo manteve-se íntegro.

Os resultados obtidos nas ferramentas de avaliação de qualidade e SSIM foram analisados para avaliação de desempenho. Com base na análise comparativa, o VQM é econômico, eficiente em termos de tempo, flexível, capaz de realizar avaliações repetitivas com facilidade, menos complexo no cálculo e amplamente empregado para avaliação objetiva da qualidade de vídeo em comparação com SSIM.

Dois cenários experimentais de codificação diferentes foram aplicados no estudo. Nestes cenários, um estático e um dinâmico, foi utilizado um vídeo cuja informação de sua estrutura é conhecida para ser confrontada com o conteúdo transmitido.

As taxas de bits foram distribuídas com base no nível de atividade temporal das sequências de teste. Os experimentos foram repetidos em diferentes condições de canal de 1,92Mb/s, 3,84Mb/s, 5,76Mb/s e 7,68Mb/s para avaliação efetiva e avaliação da consistência dos sistemas de desempenho de qualidade. A Fig. 4 apresenta o desempenho de qualidade para a sequência de teste.




Fig. 4. Performance do PSNR

As Figuras 5 e 6 apresentam os resultados dos testes obtidos da métrica de avaliação de qualidade SSIM nos cenários estático e dinâmico. Observou-se que na alocação de taxas de bits de 1,92Mb/s, os valores SSIM correspondentes para os cenários de teste são 99,09% e 99,02%, respectivamente.

Foi ainda observado que, à medida que as taxas de bits aumentam de 1,92 Mb/s para 3,84 Mb/s, os valores SSIM correspondentes para a sequência de teste também aumentam de 99,09% e 99,02% para 99,42% e 99,10%, respectivamente conforme apresentado nas Figuras 5 e 6. O desempenho da consistência também foi observado a partir dos resultados obtidos com a ferramenta de avaliação de qualidade SSIM.

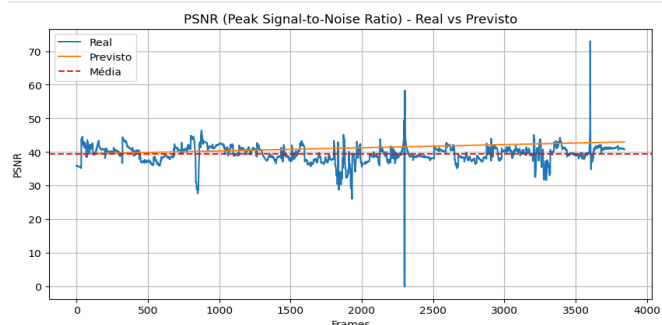


Fig. 5. Performance do PSNR em cenário estático

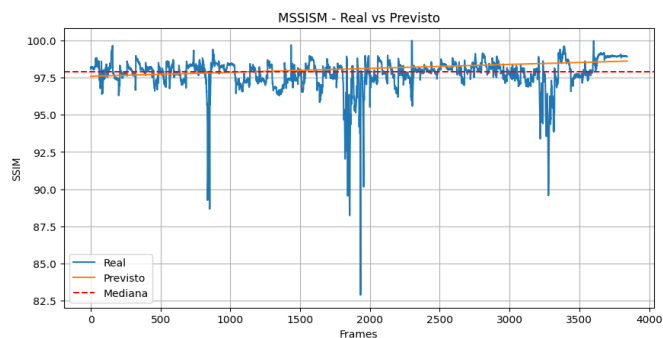


Fig. 6. Performance do SSIM em cenário dinâmico

A análise de desempenho de qualidade média para a sequência de vídeo de teste é apresentada na Tabela 2. Os resultados apresentados são referentes aos conjuntos de testes realizados sobre o conteúdo multimídia demonstram que a medida que as taxas de bits aumentam, o desempenho de qualidade também melhora correspondentemente.

Tabela 2. Performance do PSNR e SSIM

Modelo	MSE PSNR	MSE SSIM	Nota PSNR (%)	Nota SSIM (%)
Estático	9.26	6.98	91.01	94.3
Dinâmico	9.54	6.05	90.46	93.95

## 5. CONCLUSÃO

Este artigo buscou responder a seguinte questão de pesquisa: Como fornecer uma avaliação objetiva da qualidade do conteúdo multimídia a testadores sobre o impacto dos ruídos da rede utilizada na transmissão?

A aplicação de um método científico e sistemático no processo de resolução do problema proposto, permitiu experimentar métricas de avaliação da qualidade de conteúdos multimídia através das implementações dos algoritmos PSNR e SSIM.

Os resultados obtidos mostram que, para uma determinada taxa de bits de 3,84 Mb/s, na configuração de teste, a sequência de teste experimentou melhor desempenho de qualidade de 46,63 dB (PSNR) e 99,10% (SSIM) em comparação com desempenho de qualidade inferior de 36,18 dB (PSNR) e 90,40% (SSIM) experimentados pela sequência do teste. Como resultado, o conteúdo de mídia de alta atividade temporal requer taxas de bits significativamente mais altas para atingir um nível de qualidade semelhante com conteúdo de mídia de baixa atividade temporal.

Os *insights* obtidos nesta pesquisa podem ser aproveitados para fornecer soluções para os desafios enfrentados pelos provedores de serviços de mídia sem fio na avaliação e monitoramento da qualidade dos serviços multimídia para melhorar a experiência de comunicação multimídia sem fio.

## AGRADECIMENTOS

Este trabalho foi desenvolvido no CESAR - Manaus e UFAM – Universidade Federal do Amazonas, em parceria com a *Motorola Mobility* Comércio de Produtos Eletrônicos Ltda.,

nos termos da SUFRAMA – Superintendência da Zona Franca de Manaus, Lei Federal no. 8.387/1991.

## REFERÊNCIAS

- Bross, B., Chen, J., Ohm, J., Sullivan, G., Wang, Y. (2021). Developments in International Video Coding Standardization after AVC, with an Overview of Versatile Video Coding, Developments in International Video Coding Standardization After AVC With an Overview of Versatile Video Coding (VVC)", Proceedings of the Institute of Electrical and Electronics Engineers, 109(9), pp. 1-31.
- Dautov, R., Husom, E. J., Gonidis, F., Papatzelos, S., Malamas, N. (2022). Bridging the Gap Between Java and Python in Mobile Software Development to Enable MLOps. In 2022 18th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob) (pp. 363-368). IEEE.
- Macedo, M.; De Souza, M. (2022). Revisões de literatura em engenharia e gestão do conhecimento. In: Anais do Congresso Internacional de Conhecimento e Inovação-ciki.
- Sani, Y., Mauthe, A., Edwards, C. (2017). Adaptive Bitrate Selection: A Survey, in IEEE Communications Surveys & Tutorials, vol. 19, no. 4, pp. 2985-3014, Fourthquarter doi: 10.1109/COMST.2017.2725241.
- Sara, U., Akter, M., Uddin, M. (2019). Image quality assessment through FSIM, SSIM, MSE and PSNR—a comparative study. Journal of Computer and Communications, v. 7, n. 3, p. 8-18.
- Ukommi, U. (2020). Media Motion-Based Resource Distribution for Mobile Video Networking, Nigerian Journal of Technology (NIJOTECH), 39(4), pp. 1183-1189.
- Yan, C., Teng, T., Liu, Y., Zhang, Y., Wang, H., Ji, X. (2021). Precise no-reference image quality evaluation based on distortion identification. ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM), v. 17, n. 3s, p. 1-21.
- Yi, X., Walia, E., Babyn, P. (2019). Generative adversarial network in medical imaging: A review, Medical Image Analysis, Volume 58, 101552, ISSN 1361-8415, <https://doi.org/10.1016/j.media.2019.101552>.