

Análise do impacto da qualidade de rede na experiência do jogador em jogos de realidade virtual

Victor Gabriel Araujo Barbosa¹, Daniel Henriques César Miranda Soares¹,
Vinicius Rodrigues Oliveira¹, Sergio Carneiro², Ricardo Mello²,
Paulo H. L. Rettore^{1,3}, Jose Marcos Nogueira¹, Daniel Fernandes Macedo¹

¹Departamento de Computação
Universidade Federal de Minas Gerais (UFMG) – MG – Brasil.

²Departamento de Engenharia Elétrica
Universidade Federal do Espírito Santo (UFES) – ES – Brasil.

³Departamento de Computação Aplicada
Universidade Federal de Lavras (UFLA), Lavras - Brasil.

{victorgab, danielhenriques, viniciusr01}@ufmg.br

{rettore, jmarcos, damacedo}@ufmg.br

{sergio.carneiro, ricardo.c.mello}@ufes.br

Abstract. *Cloud gaming in VR tends to be more demanding than traditional cloud gaming, as it combines responsiveness and visual quality requirements with additional immersion constraints. Motivated by this scenario, this work investigates whether it is possible to identify relationships between players' reported QoE and QoS metrics in a VR cloud gaming service, considering delay, jitter, and loss for both the received video and the client commands. To this end, a testbed was set up based on SteamVR streaming, and we recorded QoE on a 7-point ACR scale with 54 participants and 776 instances. The results indicate consistent relationships between QoE and QoS, with effects mainly on video jitter and loss, as well as on delay, while command loss proved irrelevant. Effects associated with profile and behavior were observed, including lower QoE among players with higher weekly playtime, higher QoE with recency (familiarity level), and a decline with warm-up. The analysis also suggests that the most severe constraints arise when aiming for maximum QoE, and that different profiles may prioritize video or commands.*

Resumo. *O cloud gaming em VR tende a ser mais exigente do que o cloud gaming tradicional, pois combina requisitos de responsividade e de qualidade visual com restrições adicionais de imersão. Motivado por esse cenário, este trabalho investiga se é possível identificar relações entre a QoE relatada por jogadores e aspectos da QoS em um serviço de cloud gaming VR, considerando métricas de delay, jitter e perda, tanto no vídeo recebido quanto nos comandos enviados pelo cliente. Para isso, foi montada uma testbed baseada em streaming SteamVR e registramos a QoE em escala ACR de 7 pontos com 54 participantes e 776 instâncias. Os resultados apontam relações consistentes entre QoE e QoS, com significância principalmente para jitter e perda de vídeo, além de efeitos sobre delay, enquanto a perda de comandos não se mostrou relevante. Foram*

observados efeitos associados ao perfil e ao comportamento, como menor QoE entre jogadores com maior tempo semanal, aumento de QoE com a recência (nível de familiaridade) e queda com o aquecimento. A análise também sugere que as restrições mais severas ocorrem ao buscar níveis máximos de QoE e que diferentes perfis podem priorizar o vídeo ou os comandos.

1. Introdução

A indústria de jogos digitais tem apresentado crescimento expressivo, alcançando um faturamento global de 224 bilhões de dólares em 2024 e superando, em conjunto, os mercados de música e de cinema [PwC 2025]. Entretanto, o acesso aos jogos em sua forma mais recente é limitado pelo alto custo dos componentes de *hardware*, agravado pelo aumento contínuo dos requisitos de sistema e pela adoção de tecnologias como *Ray Tracing*, restritas a arquiteturas recentes [Arena 2025, Corsair Explorer 2025, Steam Store 2025]. Esse cenário é intensificado pela disputa por recursos produtivos com o setor de *data centers*, o que impacta diretamente a disponibilidade de componentes para o mercado consumidor [Abinee 2025, Micron Technology, Inc. 2025].

Diante dessas limitações, o *cloud gaming* (CG) surge como uma alternativa de baixo custo e maior acessibilidade, ao permitir a execução e o *streaming* de jogos a partir de servidores remotos. No entanto, a qualidade da experiência do usuário depende fortemente de parâmetros de rede, como latência, largura de banda, perda de pacotes e *jitter*, que podem comprometer a interatividade e a fidelidade da experiência [Soares et al. 2023]. Embora avanços recentes e a popularização de serviços comerciais tenham consolidado o CG tradicional como uma solução viável [Dario Andric 2024], sua aplicação a jogos de realidade virtual (VR) ainda representa um desafio, dado o maior grau de exigência em termos de *hardware* e de condições de rede [Li et al. 2020].

Nesse contexto, este trabalho investiga a relação entre métricas de Qualidade de Serviço (QoS) e a satisfação do usuário, expressa por indicadores de Qualidade de Experiência (QoE), em um cenário de *cloud gaming* voltado a jogos de realidade virtual. Por meio de uma análise estatística, busca-se identificar correlações entre parâmetros de rede e a percepção do usuário, contribuindo para a compreensão dos fatores que influenciam a experiência em CG VR e fornecendo subsídios para o desenvolvimento de mecanismos de adaptação e otimização orientados à experiência do usuário.

2. Referencial Teórico

Esta seção apresenta os fundamentos teóricos de Qualidade de Experiência, *cloud gaming* (CG), realidade virtual e *cloud gaming* VR, bem como os métodos estatísticos adotados neste estudo.

2.1. Qualidade de Experiência (QoE)

A QoE representa a percepção subjetiva do usuário quanto à qualidade de um serviço, indo além de métricas puramente técnicas. Em *cloud gaming*, parâmetros de rede, como *delay*, *jitter*, perda de pacotes e largura de banda, influenciam diretamente a experiência do jogador, podendo resultar em atrasos de comando, degradação visual e travamentos. Estudos indicam que a QoE não é adequadamente explicada

por métricas de QoS isoladas, pois correlações entre parâmetros de rede podem alterar significativamente a percepção do usuário, gerando divergências entre avaliações objetivas e subjetivas [Soares et al. 2023, Bekar et al. 2023, Ahmad et al. 2023]. Para avaliação experimental, este trabalho segue as diretrizes da recomendação ITU-T P.809 [International Telecommunication Union 2018].

2.2. Cloud Gaming

No CG tradicional (Figura 1), a aplicação é executada remotamente, enquanto o cliente atua como terminal de *streaming*, recebendo o vídeo renderizado e enviando os comandos do usuário. Essa arquitetura reduz a exigência de *hardware* local, mas torna a QoE altamente dependente das condições de rede entre o cliente e o servidor [International Telecommunication Union 2018]. Para mitigar degradações, plataformas de CG utilizam mecanismos adaptativos, como ajustes dinâmicos de *bitrate* e de taxa de quadros, além de estratégias de alocação de recursos e de proteção contra perdas [Zadtootaghaj et al. 2018, Wu et al. 2015, Slivar et al. 2019].




Figura 1. Arquitetura de *cloud gaming* de alto nível.




Figura 2. *Cloud gaming* VR via Steam.

2.3. VR e Cloud Gaming VR

A realidade virtual proporciona experiências imersivas por meio de *headsets* e de rastreamento de movimento, sendo particularmente sensível à latência *motion-to-photon*, *jitter* e perda de pacotes [Giraldi et al. 2003, Stauffert et al. 2020]. Jogos em VR demandam altas taxas de quadros e resoluções elevadas, o que motiva o uso de *cloud gaming* em VR (Figura 2) para reduzir os requisitos de *hardware* locais [Li et al. 2020]. Contudo, essa modalidade impõe exigências ainda mais rigorosas às condições de rede, intensificando o impacto de degradações na QoE [Lee et al. 2024, Rossi et al. 2024, International Telecommunication Union 2018].

2.4. Métodos estatísticos

A análise dos dados baseou-se em técnicas estatísticas descritivas e inferenciais, com foco na modelagem de relações lineares e na análise de correlações robustas. A regressão linear modela a relação entre uma variável dependente Y e uma variável independente X , assumindo uma relação linear expressa por:

$$Y = \beta_0 + \beta_1 X + \epsilon \quad (1)$$

Onde β_0 é o intercepto, β_1 é o coeficiente angular e ϵ representa o termo de erro. Os parâmetros são estimados pelo método dos Mínimos Quadrados Ordinários (OLS), que minimiza a soma dos quadrados dos resíduos:

$$\min_{\beta} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

Neste trabalho, o OLS foi utilizado por assumir, *a priori*, a existência de relações lineares significativas entre as variáveis analisadas, sendo também empregado para a visualização de tendências nos dados. Reconhece-se, contudo, que a regressão logística ordinal constitui uma abordagem mais adequada para análises *a posteriori*. Para avaliar associações monotônicas entre variáveis, foi utilizado o Coeficiente de Correlação de Spearman (ρ), uma medida não-paramétrica baseada nos postos das observações, definida como:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (3)$$

Onde d_i é a diferença entre os postos de cada observação e n é o número de observações. O coeficiente de Spearman foi adotado por sua robustez a valores extremos e por ser adequado à análise de variáveis ordinais, como os escores de QoE.

3. Trabalhos Relacionados

Esta seção revisa trabalhos relevantes em *cloud gaming* (CG) tradicional e em realidade virtual (VR), com foco na Qualidade de Experiência (QoE) e na relação entre QoE e Qualidade de Serviço (QoS), destacando a escassez de estudos que abordem *cloud gaming* em VR sob essa perspectiva.

3.1. QoE em *cloud gaming* tradicional

Diversos trabalhos investigam a relação entre métricas de QoS e QoE no CG tradicional. Em [Ahmad et al. 2023], os autores demonstram que correlações entre parâmetros de rede, como *delay*, *jitter* e perda, produzem impactos mais expressivos na QoE do que a análise isolada dessas métricas, resultado corroborado por [Soares et al. 2023]. Esses estudos evidenciam limitações dos modelos objetivos quando há forte correlação entre os parâmetros de QoS, reforçando a necessidade de abordagens mais robustas.

A otimização da QoE em cenários multiusuários é abordada em [Slivar et al. 2019], que propõe um *framework* de alocação de recursos orientado à QoE, demonstrando ganhos significativos em comparação a abordagens que ignoram a percepção do usuário, especialmente sob restrições de largura de banda. Outros trabalhos analisam o impacto de parâmetros de *streaming* na QoE. Em [Zadtootaghaj et al. 2018], os autores exploram o compromisso entre FPS e *bitrate*, demonstrando que limitar a taxa de quadros pode melhorar a experiência em condições de baixa banda. Em contraste, [Wu et al. 2015] defende o uso de altas taxas de quadros, propondo mecanismos adaptativos que combinam priorização de quadros e FEC para sustentar a qualidade em redes móveis.

3.2. QoE em *cloud gaming* para VR

Estudos sobre QoE em *cloud gaming* para VR ainda são incipientes. Em [Jumani et al. 2025], a QoE é inferida a partir das expressões faciais dos usuários, com

foco na modelagem do estado do jogador, sem analisar diretamente sua relação com as métricas de QoS. Já [Lee et al. 2025] investiga a correlação entre QoE e QoS em CG para VR com usuários reais, porém com uma amostra limitada e configurações de rede menos representativas de ambientes residenciais.

Trabalhos sobre experiências imersivas, como [Tran et al. 2017], destacam que a QoE em VR envolve dimensões adicionais, incluindo *presence* e *cybersickness*, o que reforça a complexidade da análise de QoE e a influência de fatores como o dispositivo e o tipo de conteúdo em cenários de CG VR.

3.3. Lacuna e posicionamento do trabalho

Apesar dos avanços na CG tradicional, há uma lacuna significativa na literatura quanto à análise estatística da relação entre QoE e QoS em *cloud gaming* para VR, especialmente considerando amostras de usuários maiores e cenários mais próximos da realidade residencial. Neste contexto, o presente trabalho contribui ao investigar, estatisticamente, a relação entre métricas de QoE e parâmetros de QoS em um ambiente de CG VR, com base em dados coletados de 54 participantes, fornecendo subsídios para o desenvolvimento de mecanismos de adaptação orientados à experiência do usuário.

Tabela 1. Trabalhos Relacionados.

Literatura	Ctx.	# jog.	# jogos	QoE/QoS	Modelos
[Ahmad et al. 2023]	CG Trad.	N/I	N/I	Sim	NetEm corr.
[Slivar et al. 2019]	CG Trad.	N/I	N/I	Ind.	Aloc. QoE
[Zadtootaghaj et al. 2018]	CG Trad.	N/I	2	Não	QoE (FPS/BR)
[Wu et al. 2015]	CG Trad.	N/I	N/I	Não	APHIS + FEC
[Tran et al. 2017]	VR Vídeo	N/I	N/I	Não	QoE multi-dim.
[Jumani et al. 2025]	CG VR	N/I	N/I	Não	Exp. facial
[Lee et al. 2025]	CG VR	12	N/I	Sim	Corr. QoE/QoS
Este trabalho	CG VR	54	1	Sim	Análise est.

4. Metodologia

A recomendação P.809 da ITU [International Telecommunication Union 2018] descreve os principais fatores que influenciam a QoE do usuário. Este documento categoriza esses fatores em três níveis distintos: (i) a plataforma de jogos, que se refere à qualidade de saída; (ii) a dinâmica do jogo, que abrange a qualidade de interação; e (iii) a imersão do jogador, relacionada aos conceitos de engajamento. Nosso estudo foca no primeiro nível, diretamente influenciado pelos recursos de rede e de computação.

Além disso, o documento da ITU fornece diretrizes para a metodologia de avaliação da QoE em contextos de jogos, o que inclui nosso cenário. A abordagem recomendada envolve a participação de jogadores em sessões curtas (partidas) de jogo, com duração entre 90 e 180 segundos, seguida da coleta de *feedback* sobre a QoE percebida. Para avaliar a experiência do usuário, a ITU sugere o uso de uma Escala de Categoria Absoluta (ACR), uma escala contínua de sete pontos que abrange categorias que vão de "extremamente ruim" a "ideal," representando todo o espectro de experiências do usuário: extremamente ruim, péssima, ruim, razoável, boa, excelente e ideal.

Dessa forma, neste trabalho, propomos um testbed para a experimentação de conceitos de *cloud gaming* em VR. Nossa *testbed* é composta por um servidor executando

Windows 10 com o serviço de streaming da SteamVR, equipado com um processador i7-7700, 16 GB de memória RAM DDR4 e uma placa gráfica RTX 3060. Nosso *testbed* é exatamente como mostrado na Figura 2 na seção 2, exceto que nosso roteador é Wi-Fi 5. No próprio servidor, como a tela não é bloqueada durante o streaming, utilizamos o Clumsy para introduzir degradação na rede, coletar dados de rede e registrar a avaliação do jogador sobre a partida (QoE). O *delay* varia de 0 a 50 ms (em incrementos de 5 ms), o *jitter* varia de 0 a 10 ms (em incrementos de 2 ms) e a perda de pacotes varia de 0% a 3% (em incrementos de 0,5%). Esses parâmetros baseiam-se em [Soares et al. 2023], com reduções empíricas de *delay* e *jitter* devido à maior exigência do VR. Embora a resolução Full HD continue popular como a mais amplamente adotada, conforme observado em [Soares et al. 2023, Steam 2020]. O testbed de VR pode transmitir em até 120 quadros por segundo em duas telas de 1440p (uma por olho), para evitar o *cybersickness* [Lee et al. 2024], porém a resolução e a taxa variam de acordo com o jogo. Half-Life: Alyx utiliza 1440p e 72 Hz.

Após a montagem e a utilização pronta, elaboramos um experimento com o intuito de investigar a relação entre as condições de rede e a experiência do usuário. Não estabelecemos critérios de exclusão para participação no experimento, buscando a maior diversidade de opiniões possível. A exceção consiste em indivíduos que, por questões de saúde, são incapazes de cumprir sua parte no experimento: deficientes visuais, pessoas com labirintite, tetraplégicos, entre outros. Em outras palavras, o público-alvo era qualquer pessoa capaz de operar o VR e jogar Half-Life: Alyx.

Divulgamos a possibilidade de participação na pesquisa à comunidade acadêmica, principalmente por meio de redes sociais e da ajuda de colaboradores. Além disso, coletamos outros dados levando o testbed a um evento de jogos e repetindo o experimento em condições idênticas. Para participar do experimento, o indivíduo também precisava preencher um questionário com algumas perguntas, a fim de identificar seu perfil. Os itens consistiam em perguntas sobre os hábitos de jogo do participante, como a quantidade de horas em cada modalidade (jogos tradicionais, jogos de VR), quais dispositivos usam para jogar, bem como identificadores (idade, gênero, nome). O experimento ocorre da seguinte maneira:

Os participantes eram levados ao laboratório e recebiam instruções sobre o experimento (avaliar o QoE), sem período prévio de adaptação ao ambiente. Em seguida, colocavam o *headset* e os controles e começavam uma partida inicial de *Half-Life: Alyx* em condições ideais, para criar uma base de comparação. A partir daí, as sessões alternavam partidas com rede normal e adulterada, sendo que apenas as partidas adulteradas geravam dados: ao final de cada uma, o participante reportava sua avaliação de QoE e *cybersickness*, e então jogava novamente uma partida em condição normal. As sessões duravam conforme a vontade do participante e a bateria do equipamento, podendo haver múltiplas partidas e retornos ao laboratório. Não houve sigilo, e o progresso no jogo era contínuo entre partidas e sessões, garantindo exposição a diferentes situações ao longo do tempo.

Para selecionar os parâmetros de rede, foi criada uma lista com todas as combinações possíveis de *delay*, *jitter* e perda, ajustando o *jitter* para 0 quando o *delay* era 0 e adicionando ainda 25% de triplas zeradas. Essa lista era então embaralhada e salva em um arquivo. A cada partida adulterada, o programa sorteava duas triplas, aplicando

uma aos comandos e outra ao vídeo, e lidava com a limitação do Clumsy (um único *delay* para *upload/download*) ao aplicar o menor *delay* quando ambos eram não nulos. Após cada partida, as triplas efetivamente usadas eram registradas na base e removidas da lista, garantindo que todas as combinações fossem exploradas; ao esgotar, uma nova lista era gerada.

5. Avaliação dos Dados

Ao todo, obtivemos 54 participantes e 776 partidas, com as instâncias coletadas ao longo de 2025. Das 54 pessoas, é notável que 46 são homens e 8 são mulheres, com idade média de 22 anos; a maior concentração está no intervalo de 16 a 22 anos (31 participantes). Em jogos tradicionais, 22 declararam jogar mais de 8 horas por semana e 36 jogam ao menos 5 horas semanais, enquanto apenas 5 relataram jogar nenhuma ou menos de 1 hora por semana. Quanto ao VR, 49 afirmaram não possuir *headset* e 3 declararam possuir um dispositivo da linha *Meta Quest*. Além disso, 51 disseram não jogar jogos de VR, e os demais relataram entre 1 e 3 horas semanais. Por fim, 39 participantes indicaram jogar com mouse e teclado, 9 com controle/manete e 2 com celular, e ninguém marcou *headset* de VR como dispositivo de jogo, o que sugere um preenchimento incorreto desse item por parte dos poucos participantes que jogam VR.

Sobre as partidas, a distribuição das instâncias obtidas reflete o procedimento de coleta estabelecido na seção anterior, com parâmetros de rede zerados presentes cerca de 3 vezes mais do que os outros, que eram homogêneos entre si. Existe um total de 26 instâncias (menos de 5%) em que as condições de jogo eram idênticas às da partida regular, com todos os parâmetros zerados simultaneamente. Dessas instâncias, é notável que, embora na maioria das vezes (15 instâncias) os participantes tenham corretamente notado esse fato e avaliado a partida com QoE "ideal", 8 partidas foram avaliadas com QoE "excelente" e 3 com QoE "bom".

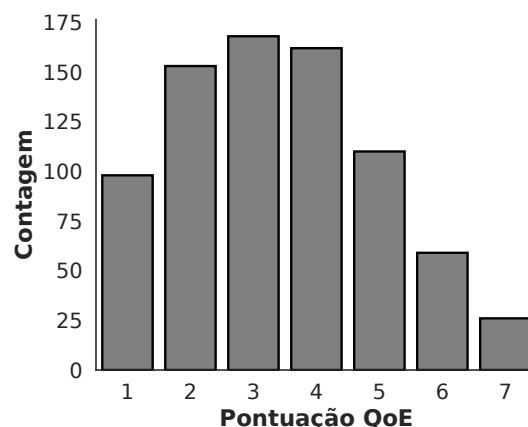


Figura 3. Distribuição de Avaliações.

Notamos que, de modo geral, a distribuição das avaliações tende a ser mais negativa, como mostra a Figura 3. E também é interessante observar que a maior parte das avaliações foi realizada por uma pequena parcela dos jogadores, conforme mostra a Figura 4.

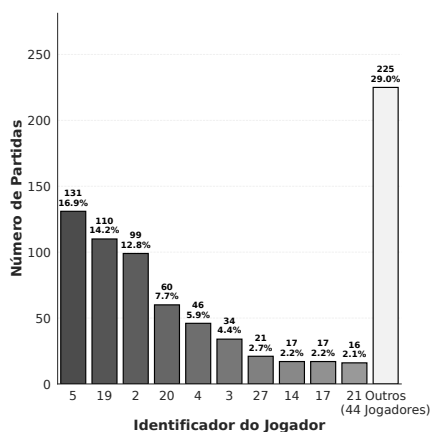


Figura 4. Distribuição de Avaliações por jogador.

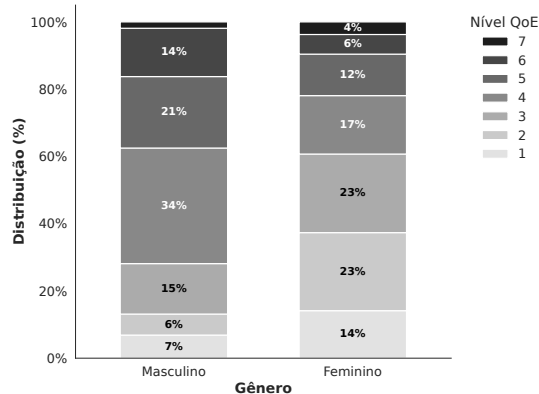


Figura 5. Distribuição de QoE por gênero.

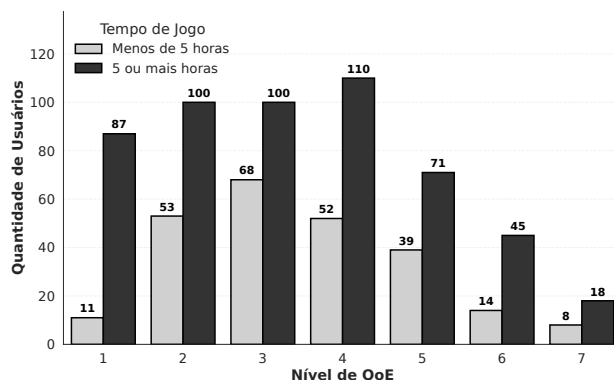


Figura 6. Distribuição de QoE em função do tempo de jogo.

Conforme mostra a Figura 5, notamos uma particularidade interessante nos dados: as mulheres tendem a ser mais balanceadas em suas avaliações do que os homens, que tendem a avaliar de forma mais negativa. Contudo, essa observação exige cautela devido ao tamanho reduzido da amostra feminina (8 participantes). Ademais, encontramos diferenças na distribuição de QoE entre pessoas que jogam 5 horas ou mais por semana e pessoas que jogam menos de 5 horas por semana, como ilustrado na Figura 6. Observa-se que, para jogadores com 5 ou mais horas semanais, há maior concentração de avaliações nos níveis iniciais de QoE (especialmente entre 1 e 4), enquanto o grupo com menos de 5 horas apresenta uma distribuição relativamente mais “centralizada” (com maior peso em valores intermediários). Uma explicação plausível é que jogadores mais experientes tendem a ser mais exigentes, percebendo com mais facilidade artefatos e limitações do serviço (como instabilidades, piora na imagem, variações na taxa de quadros e atrasos de controle), o que pode reduzir suas avaliações, mesmo quando a qualidade média aparenta ser aceitável. A adoção do limiar de 5 horas se deve por sua proximidade com a mediana, permitindo a divisão do conjunto de dados em duas subamostras balanceadas para contrastar os jogadores de perfil mais intensivo com os mais casuais.

5.1. Relação entre variáveis (explicabilidade)

Para avaliar a relação entre as variáveis observadas nos experimentos e a QoE, criamos duas *features*: aquecimento e recência. O aquecimento, definido entre 0 e 1, representa linearmente a posição da partida dentro da sessão (do início ao fim), buscando capturar a habituação do participante ao VR no mesmo dia, enquanto a recência segue o mesmo princípio em escala global, considerando todas as partidas do participante. A normalização 0-1 foi aplicada para mitigar disparidades no tempo de jogo bruto. Em seguida, utilizamos regressão OLS (*Ordinary Least Squares*) via *statsmodels* do *python* para investigar relações lineares, e o coeficiente de Spearman (via *pandas*) para medir correlações com maior robustez, especialmente por lidar com *rankings* e por se adequar a variáveis ordinais, como a QoE; por fim, para visualização, plotamos tendências por regressão linear com a biblioteca *seaborn*.

Tabela 2. Resultados da Regressão OLS (Variável Dep.: QoE).

	Impacto (1 unidade)	Desvio Padrão	<i>t</i>	$P > t $	[0.025 – 0.975]	
const	1.2513	0.103	12.132	0.000	1.049	1.454
JitterVideo	-0.0425	0.008	-5.114	0.000	-0.059	-0.026
JitterComandos	-0.0409	0.008	-4.896	0.000	-0.057	-0.025
PerdaVideo	-0.3753	0.028	-13.493	0.000	-0.430	-0.321
PerdaComandos	-0.0270	0.028	-0.966	0.334	-0.082	0.028
DelayVideo	-0.0117	0.002	-6.453	0.000	-0.015	-0.008
DelayComandos	-0.0095	0.002	-5.442	0.000	-0.013	-0.006
Aquecimento	-0.3503	0.111	-3.161	0.002	-0.568	-0.133
Recência	0.3173	0.114	2.775	0.006	0.093	0.542
Tempo Jogo (Trad.)	-0.0044	0.010	-0.436	0.663	-0.024	0.015

Metadados da Regressão:

Observações.: 771	R^2 : 0.403	Estatística-F: 57.13
R^2 Ajustado: 0.396	AIC: 1759	Probabilidade (F): 1.98×10^{-79}

Os resultados do OLS podem ser observados na Tabela 2. Os principais pontos de interesse são os dados da regressão: Impacto refere à influência de uma unidade (1.0) de uma variável no QoE (em Z Score); O Desvio Padrão do impacto; A estatística T da variável, que é um coeficiente derivado da divisão do impacto pelo desvio padrão; $P > |t|$, que é a chance em porcentagem da variável ser apenas ruído; e o intervalo de 95% de confiança para o valor do impacto. Além disso, a biblioteca *statmodels* fornece metadados sobre a regressão linear.

Entre as estatísticas do modelo encontrado, estão: Observações, que é o número de instâncias observadas; R^2 , que indica quanto do comportamento dos dados a regressão consegue explicar, em porcentagem; R^2 ajustado, que é uma alternativa ao anterior, que não aumenta em valor ao adicionar variáveis não informativas; Estatística-F, que é um valor que reflete o quão melhor que apenas chutar a média a regressão é; A Probabilidade de F, que é a chance do padrão encontrado nos dados ser apenas ruído; e o número AIC, que é apenas uma métrica de comparação para modelos (menor é melhor).

O modelo OLS (Tabela 2) revela que as métricas de desempenho e o contexto da sessão (aquecimento e recência) possuem impacto estatisticamente significativo ($P > |t| < 0,05$) no QoE. Em contraste, a perda de comandos e as horas semanais em jogos tradicionais não apresentam relação direta ($P > |t| > 0,05$). As métricas mais significativas para o QoE, por unidade, são o *jitter* e a perda de vídeo. No caso, isso significa que 1% de perda de vídeo é bem mais significativo que 1 ms de *jitter*, que, por

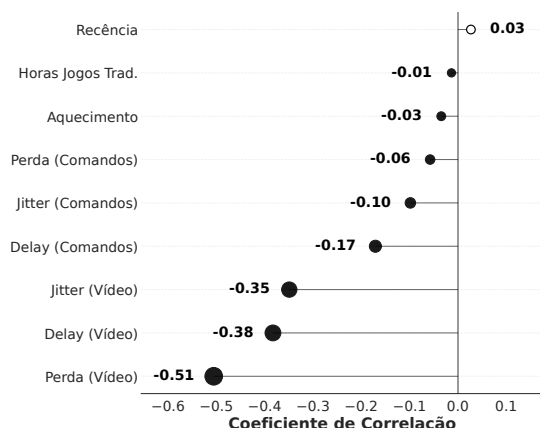


Figura 7. Correlação com o QoE (Spearman).

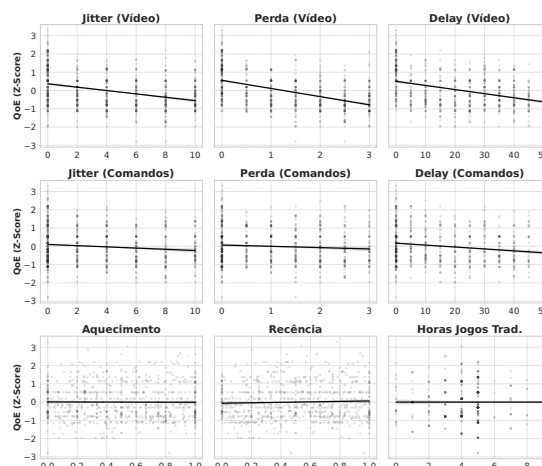


Figura 8. Matriz de Tendências (Regressão Linear).

sua vez, é bem mais impactante que 1 ms de *delay*. Se considerarmos todo o intervalo das métricas, a perda de vídeo e o *delay* de vídeo têm os maiores impactos. Isso também pode ser visualizado na Figura 8 e é suplementado pelo resultado na Figura 7.

5.2. Pontos de Corte

Realizamos uma análise para identificar, para cada nível de QoE, qual é o maior nível de cada métrica em que ao menos um jogador classificou a instância como tendo esse nível de QoE. Buscamos, com essa análise, identificar os pontos de corte e os requisitos estritos para cada nível de qualidade da experiência. Em outras palavras, buscamos "critérios de rejeição": valores acima dos quais a experiência não atinge um determinado patamar de qualidade, segundo os jogadores. Embora seja o efeito conjunto das métricas que defina a qualidade da experiência, esses pontos de corte são importantes porque permitem inferir um teto para o QoE em uma dada partida.

Os resultados dessa análise encontram-se na Tabela 3. Como se pode observar, não temos critérios de rejeição para o *jitter*, e as outras métricas também não apresentam nenhum até o QoE 7. Nele, pode-se notar que, para que a experiência seja considerada ideal, o *delay* de comandos e de vídeo pode ser, no máximo, de 15 e 30 milissegundos, respectivamente. A perda de comandos e vídeo pode ser de 2,5% e 2%, respectivamente.

Tabela 3. Limites superiores por nível de QoE (geral e por perfil de horas semanais)

Grupo	QoE	Jitter V.	Jitter C.	Perda V.	Perda C.	Delay V.	Delay C.
Todos	1-6	10	10	3.00	3.00	50	50
	7	10	10	2.00	2.50	30	15
<5h	1	8	10	3.00	3.00	50	50
	2-5	10	10	3.00	3.00	50	50
	6	10	8	3.00	2.50	50	50
	7	10	0	2.00	2.00	30	10
≥ 5h	1-5	10	10	3.00	3.00	50	50
	6	8	10	3.00	3.00	40	45
	7	8	10	1.50	2.50	15	15

Pontos de Corte por Perfil de Jogador: Repetimos a análise separando os participantes novamente pelo tempo semanal em jogos tradicionais ($< 5h$ e $\geq 5h$), com os resultados na Tabela 3. A comparação evidencia prioridades distintas: o grupo com menos de 5 horas é mais exigente com a responsividade, apresentando pontos de corte para *jitter*, perda e *delay* de comandos sempre iguais ou mais rigorosos que os de vídeo. Em contrapartida, os jogadores com 5 horas ou mais demonstram o comportamento oposto, estabelecendo limites iguais ou mais estritos para a qualidade visual. Vale ressaltar que o ponto de corte do *jitter* (8 ms) para QoE 1 no grupo < 5 horas foi excluído da análise. Assume-se que esse valor anômalo decorre da esparsidade das instâncias, uma vez que não há um limite superior de degradação para a avaliação mínima.

Comparando os dois grupos de forma cruzada, observamos que também ocorre uma disparidade entre eles: os jogadores com menos de 5 horas sempre tem pontos de corte iguais ou mais estritos em métricas de comandos do que os com 5 ou mais horas, com a exceção do QoE 6 no que se refere ao *delay* dos comandos. O oposto ocorre quanto às métricas de vídeo: jogadores com 5 ou mais horas tem pontos de corte sempre tão ou mais estritos que os com menos de 5. Isso sugere uma diferença de prioridades entre os grupos: jogadores com muitas horas semanais parecem priorizar uma alta qualidade do vídeo, enquanto os com poucas horas preferem uma alta qualidade dos comandos.

5.3. Avaliação de fatores externos

Uma das hipóteses que tínhamos era que, como a tecnologia de realidade virtual é muito incomum e oferece experiências diferentes das de computadores e consoles, os participantes que não tinham familiaridade iriam exibir algum tipo de efeito de adaptação, no qual avaliariam as partidas de forma exageradamente negativa ou positiva e, depois, estabilizariam. A análise OLS conduzida, como mostra a Tabela 2, indicou uma relação estatisticamente significativa entre a recência (nível de familiaridade) de uma partida e o QoE. Ela também mostrou que o tamanho do impacto pode variar bastante, dado que o intervalo de confiança é amplo. Algo similar ocorre com o aquecimento, embora, como visto na Figura 7, enquanto o aquecimento tenha uma influência negativa no QoE, a recência é uma influência positiva.

Ao observar a tendência do QoE em função da recência e do aquecimento, agrupados por jogador, notamos que as avaliações de alguns participantes tornaram-se mais negativas ao longo do tempo, enquanto as de outros tornaram-se mais positivas. Acreditamos que o efeito do aquecimento e da recência possa variar em intensidade e em sinal de acordo com o jogador, sendo altamente subjetivo, o que explicaria o intervalo de confiança amplo do seu impacto na Tabela 2.

5.4. Limitações encontradas

Devido à forma de geração das instâncias (sorteios independentes por métrica), houve abundância de combinações com significado semântico semelhante: rede moderadamente degradada, de modo que muitas condições produziram efeitos quase idênticos para o usuário, enquanto os cenários realmente distintos ficaram concentrados em uma fração pequena do conjunto. Isso também se reflete na baixa quantidade de amostras em condições ideais (apenas 26 partidas, menos de 4% do total), dificultando delimitar com precisão pontos de corte e requisitos estritos.

Além disso, o conjunto de dados é enviesado e desbalanceado: há poucas instâncias do grupo que joga menos de 5 horas semanais, o que torna incerto se certos limites observados (por exemplo, exigir *jitter* de comandos igual a 0 para QoE 7) são de fato restritivos ou decorrem da falta de exposições relevantes. A amostra também se concentra majoritariamente em homens de 16–22 anos que jogam pelo menos 5 horas semanais com mouse e teclado, com sub-representação de outros perfis e métodos de entrada. Por fim, a retenção foi desigual, com a maioria participando de uma única sessão e uma minoria com múltiplas sessões, que compõem grande parte do dataset (Figura 4). Esse desbalanceamento pode comprometer a generalização dos achados e introduz potencial dependência entre as observações. Adicionalmente, a modelagem via regressão OLS pode não ter capturado os impactos com precisão, sendo a regressão logística ordinal mais adequada à natureza ordinal do QoE.

6. Conclusão

Este trabalho investigou estatisticamente como as condições de rede afetam a QoE em *cloud gaming* VR, utilizando um *testbed* com *SteamVR* e degradações controladas de *delay*, *jitter* e perda aplicadas ao vídeo e aos comandos, com dados de 54 participantes e 776 partidas coletadas em 2025. Os resultados indicam associação da QoE principalmente com *jitter* (vídeo e comandos) e perda de vídeo, além de efeitos de *delay* (vídeo e comandos), enquanto a perda de comandos não se mostrou relevante. Também observamos influência de fatores comportamentais, como menor QoE em jogadores com mais horas semanais, aumento com a recência/familiaridade e queda com o aquecimento ao longo da sessão.

A análise de pontos de corte sugere que requisitos mais estritos se tornam evidentes, sobretudo ao buscar níveis máximos de QoE, e que diferentes perfis podem priorizar dimensões distintas (menos horas semanais, mais sensíveis aos comandos, e mais horas ao vídeo). Ainda assim, o estudo é preliminar e limitado por viés amostral (predomínio de homens jovens), baixa quantidade de instâncias ideais, sub-representação de perfis e retenção desigual entre os participantes. Adicionalmente, o impacto da taxa de quadros (FPS) não foi mensurado diretamente, sendo inferido apenas de forma indireta por meio de métricas de perda de pacotes.

Como trabalhos futuros, pretendemos ampliar a robustez do estudo com uma amostragem mais balanceada, um perfilamento mais detalhado dos participantes (incluindo hábitos e gêneros de jogos) e métricas adicionais de aceitabilidade (por exemplo, FPS, “jogaria novamente” e “recomendaria”), além de investigar como esses achados podem orientar mecanismos de adaptação, como a remediação por meio do ajuste de *bitrate*, para tornar o *cloud gaming* VR mais viável e acessível. Também consideramos essencial conhecer melhor o perfil de interação do jogador, pois acreditamos que as relações entre condições de rede e QoE tendem a ficar mais claras quando interpretadas à luz de preferências e estilos de jogo. Por exemplo, ao coletar os títulos mais jogados e mapeá-los em categorias, é possível associar o participante a perfis distintos (como jogadores de FPS, mais sensíveis à responsividade, versus jogadores que priorizam a fidelidade visual).

Agradecimentos

Este trabalho foi financiado em parte pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001, pelo Con-

selho Nacional de Desenvolvimento Científico e Tecnológico – CNPq [444077/2024-3 e 407568/2025-5], pela FAPEMIG (agência de fomento do Estado de Minas Gerais) e pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), em conjunto com o Comitê Gestor da Internet no Brasil (CGI.br) [2018/23097-3, 2020/05182-3 e 2025/00513-5].

Referências

- Abinee (2025). Brazilian mobile phone market expected to be impacted by memory shortage later this year, warns Abinee. Institutional News. Accessed: Jan. 23, 2026.
- Ahmad, N., Wahab, A., Schormans, J., and Arnab, A. A. (2023). Significance of cross-correlated QoS configurations for validating the subjective and objective QoE of cloud gaming applications. *Future Internet*, 15(2).
- Arena, P. (2025). How much does a gamer PC cost? check out values and components. Online News Article. Accessed: Jan. 23, 2026.
- Bekar, T., Görmüş, S., Aydın, B., and Aydın, H. (2023). Q-Learning Algorithm Inspired Objective Function Optimization For IETF 6TiSCH Networks. In *SmartNets*. IEEE.
- Corsair Explorer (2025). Can your PC run 2025’s biggest AAA games? Technical Article. Accessed: Jan. 23, 2026.
- Dario Andric (2024). How many people use GeForce Now? — 2024 statistics.
- Giraldi, G., Silva, R., and de Oliveira, J. C. (2003). Introduction to virtual reality. Technical Report 06/2003, LNCC – National Laboratory for Scientific Computing. Scientific Visualization and Virtual Reality Laboratory; COMCIDIS Research Group.
- International Telecommunication Union (2018). ITU-T P809: Subjective evaluation methods for gaming quality. [Online; accessed 22-May-2022].
- Jumani, A. K., Shi, J., Laghari, A. A., Amin, M. A., Nabi, A. u., Narwani, K., and Zhang, Y. (2025). Quality of experience (qoe) in cloud gaming: A comparative analysis of deep learning techniques via facial emotions in a virtual reality environment. *Sensors*, 25(5).
- Lee, K.-Y., Singla, A., Cesar, P., and Hsu, C.-H. (2024). Adaptive cloud VR gaming optimized by gamer QoE models. *ACM Transactions on Multimedia Computing, Communications and Applications*.
- Lee, K.-Y., Singla, A., Cesar, P., and Hsu, C.-H. (2025). Adaptive cloud vr gaming optimized by gamer qoe models. *ACM Trans. Multimedia Comput. Commun. Appl.*, 21(9).
- Li, Y.-C., Hsu, C.-H., Lin, Y.-C., and Hsu, C.-H. (2020). Performance measurements on a cloud vr gaming platform. In *Proceedings of the 1st Workshop on Quality of Experience (QoE) in Visual Multimedia Applications*, New York, NY, USA. Association for Computing Machinery.
- Micron Technology, Inc. (2025). Micron announces exit of crucial consumer business. Investor Relations News Release. Accessed: Jan. 23, 2026.
- PwC (2025). Global entertainment & media outlook 2025–2029. Press Release. Accessed: Jan. 23, 2026.

- Rossi, H. S., Mitra, K., Larsson, S., Åhlund, C., and Cotanis, I. (2024). Subjective QoE assessment for virtual reality cloud-based first-person shooter game. In *ICC 2024-IEEE International Conference on Communications*, pages 4698–4703. IEEE.
- Slivar, I., Skorin-Kapov, L., and Suznjevic, M. (2019). QoE-aware resource allocation for multiple cloud gaming users sharing a bottleneck link. In *2019 22nd Conference on Innovation in Clouds, Internet and Networks and Workshops (ICIN)*, pages 118–123.
- Soares, D., Carvalho, M., and Macedo, D. F. (2023). A stacking learning-based QoE model for cloud gaming. In *NOMS 2023-2023 IEEE/IFIP Network Operations and Management Symposium*, pages 1–6.
- Stauffert, J.-P., Niebling, F., and Latoschik, M. E. (2020). Latency and cybersickness: Impact, causes, and measures. a review. *Frontiers in Virtual Reality*, 1.
- Steam (2020). Steam hardware survey. <https://store.steampowered.com/hwsurvey/Steam-Hardware-Software-Survey-Welcome-to-Steam>. [Online; accessed 27-March-2020].
- Steam Store (2025). Indiana jones and the great circle. https://store.steampowered.com/app/2677660/Indiana_Jones_and_the_Great_Circle/. System requirements and software specifications. Accessed: Jan. 23, 2026.
- Tran, H. T. T., Ngoc, N. P., Pham, C. T., Jung, Y. J., and Thang, T. C. (2017). A subjective study on qoe of 360 video for vr communication. In *2017 IEEE 19th International Workshop on Multimedia Signal Processing (MMSP)*, pages 1–6.
- Wu, J., Yuen, C., Cheung, N.-M., Chen, J., and Chen, C. W. (2015). Enabling adaptive high-frame-rate video streaming in mobile cloud gaming applications. *IEEE Transactions on Circuits and Systems for Video Technology*, 25(12):1988–2001.
- Zadtootaghaj, S., Schmidt, S., and Möller, S. (2018). Modeling gaming QoE: Towards the impact of frame rate and bit rate on cloud gaming. In *2018 Tenth International Conference on Quality of Multimedia Experience (QoMEX)*, pages 1–6.