

MACCA: Controle Adaptativo de Taxa de Bits para Jogos em Nuvem no Sunshine

César de Paula Morais

Departamento de Ciência da Computação

Universidade Federal de Minas Gerais

Belo Horizonte, Brasil

cesarmorais@dcc.ufmg.br

Dr. Luiz Filipe Menezes Vieira

Departamento de Ciência da Computação

Universidade Federal de Minas Gerais

Belo Horizonte, Brasil

lfvieira@dcc.ufmg.br

Abstract—Jogos em nuvem impõem requisitos rigorosos de latência e de perda de pacotes que a rede doméstica raramente respeita de forma consistente, comprometendo a experiência do usuário sob variações súbitas de capacidade. Este artigo investiga a aplicação de um controlador adaptativo de taxa de bits ao servidor open-source *Sunshine*, denominado MACCA, baseado em um esquema *Additive Increase, Multiplicative Decrease* (AIMD) estendido com duas primitivas do algoritmo CUBIC: a curva cúbica de recuperação após reduções de taxa e o mecanismo de *fast convergence*. O controlador proposto opera exclusivamente a partir do RTT mantido pela biblioteca ENet no canal de controle, sem qualquer modificação no protocolo Moonlight ou cooperação adicional do cliente. Foi avaliado em uma campanha experimental envolvendo seis cenários de degradação de rede emulada e dois controladores de referência. Os resultados mostraram que a abordagem proposta reduz o pico de RTT em cinco dos seis cenários, com a maior queda atingindo 43%, e o tempo total acumulado em *stall* em cinco dos seis cenários, com queda de até 61%, ao custo de uma elevação sistemática do RTT mediano. Esses achados caracterizam um trade-off entre desempenho na cauda da distribuição de latência e desempenho no regime estacionário, e indicam que algoritmos de controle de congestionamento projetados para amostragem densa exigem ajuste estrutural, e não apenas reparamentização, ao serem transpostos para regimes de cadência reduzida.

Index Terms—jogos em nuvem, controle de congestionamento, taxa de bits adaptativa, AIMD, CUBIC, MACCA, Sunshine, streaming de jogos.

I. INTRODUÇÃO

Em cloud gaming, o servidor executa o jogo e transmite ao cliente apenas o vídeo codificado, permitindo o acesso a títulos de alto custo computacional em dispositivos modestos. Essa separação transfere para a rede o ônus de sustentar uma experiência tradicionalmente local ao usuário, impondo requisitos rigorosos: latência de ida e volta inferior a 100 ms para jogos de ação e taxa de perda abaixo de 1% [1]. A rede doméstica raramente respeita esses limiares de forma consistente, e qualquer variação súbita de capacidade manifesta-se imediatamente como travamento visual ou perda de sincronia. As plataformas comerciais dominantes contornam parcialmente o problema com investimento maciço em infraestrutura, ao custo de um modelo operacional baseado em assinatura, catálogo restrito ao licenciamento da operadora, hardware proprietário e ausência de controle do usuário sobre a sessão.

O *Sunshine* [2] é um servidor open-source de *streaming* de jogos compatível com o protocolo NVIDIA GameStream e cliente Moonlight [3], mantido sob a licença GPL-3.0, e constitui-se como a alternativa *self-hosted* mais adotada. Atualmente, opera com taxa de bits negociada uma única vez ao início da sessão, sem qualquer mecanismo de reação a degradação observada do canal. Diante de restrições de banda, o comportamento resultante combina estouro de *buffer* no gargalo, inflação contínua do RTT e cascatas sucessivas de quadros IDR. Os trabalhos correlatos mais próximos [4]–[6] resolvem o problema do controle adaptativo de taxa de bits em contextos próprios, mas todos pressupõem extensão do protocolo de *streaming*, cooperação ativa do cliente ou sincronização de relógio, requisitos incompatíveis com o protocolo Moonlight e sua base instalada.

Neste artigo, propomos e avaliamos o MACCA (*Multi-state AIMD with Cubic Convergence Adaptation*), um controlador adaptativo de taxa de bits para o servidor Sunshine, baseado exclusivamente em sinais já disponíveis no servidor e sem qualquer modificação no cliente. O controlador estende um esquema AIMD clássico com duas primitivas do algoritmo CUBIC [7]: a curva cúbica de recuperação após reduções de taxa e o mecanismo de *fast convergence* para atualização do teto de referência. As contribuições são três. *Primeiro*, o projeto e a implementação do controlador, integrado à árvore de código do Sunshine. *Segundo*, uma campanha experimental sobre seis cenários de degradação de rede e três controladores, em que o AIMD CUBIC reduz o pico de RTT em cinco dos seis cenários, com a maior queda alcançando 43%, e o tempo total acumulado em *stall* em cinco dos seis cenários, com queda de até 61%, ao custo de uma elevação sistemática do RTT mediano e sem dominar a referência adaptativa em todas as dimensões. Esse resultado caracteriza um trade-off entre cauda e regime estacionário da distribuição de latência que se mostra fundamental para o posicionamento de controladores adaptativos em jogos em nuvem. *Terceiro*, um achado estrutural sobre a adaptação do CUBIC a regimes de cadência reduzida: a forma literal da curva, projetada para amostragem por ACK, mostra-se empiricamente inferior à variante simplificada aqui adotada quando aplicada a 1 Hz, indicando que algoritmos de controle de congestionamento entre regimes de cadência distintos exigem ajuste estrutural, e

não apenas reparametrização.

A diferenciação em relação ao estado da arte concentra-se na ausência de requisitos sobre o cliente e o protocolo, discutida em detalhe no Capítulo II.

O Capítulo II apresenta o referencial teórico e o posicionamento contra os trabalhos correlatos. O Capítulo III descreve o controlador proposto. O Capítulo IV detalha o *testbed* físico, os cenários de degradação e o protocolo experimental. O Capítulo V apresenta os resultados, incluindo a análise de sensibilidade ao design da curva. O Capítulo VI retoma os achados centrais e discute trabalhos futuros.

II. REFERENCIAL TEÓRICO

Esta seção apresenta uma revisão sistemática da literatura relevante para controle adaptativo de taxa de bits em jogos em nuvem. A revisão foi estruturada em seis eixos temáticos complementares, conduzidos do mais geral ao mais específico: caracterização do problema de rede em jogos em nuvem, codecs de vídeo e reconfiguração em tempo de execução, controle de congestionamento na herança do TCP, controle adaptativo para mídia em tempo real, o trabalho mais próximo da contribuição proposta, e o servidor *Sunshine* como plataforma de contribuição.

A. Jogos em Nuvem como Problema de Rede

Jogos em nuvem (*cloud gaming*) consistem em executar o jogo em um servidor remoto, capturar a saída de vídeo do jogo, codificá-la em tempo real e transmiti-la a um cliente leve, que decodifica e exibe os quadros enquanto envia comandos de entrada de volta ao servidor. A arquitetura delega ao servidor a carga computacional (GPU, codec), reduzindo o cliente a um decodificador de vídeo — viabilizando jogos de alto custo em hardware modesto.

Esta separação, no entanto, impõe requisitos rigorosos ao canal de rede. A revisão sistemática conduzida por Baldovino [1], abrangendo 33 estudos publicados entre 2017 e 2022, consolida os limiares tradicionalmente adotados pela literatura para caracterizar as condições necessárias à operação adequada de sistemas de *cloud gaming*: latência de ida e volta inferior a 100 ms para jogos de ação, taxa de perda inferior a 1%, e tempo de resposta total (*response time*) entre 100 e 150 ms. Acima desses limiares, a experiência do usuário degrada de forma perceptível e, em casos extremos, torna o jogo injogável.

A importância desses limiares está associada a uma característica fundamental do próprio meio. Diferentemente do *streaming* de vídeo sob demanda, em que *buffers* de alguns segundos conseguem mascarar variações da rede de forma praticamente transparente ao usuário, aplicações de *cloud gaming* operam com *buffers* reduzidos, geralmente limitados a um ou dois quadros, para manter a interatividade. Como consequência, atrasos, perdas de pacotes ou variações na latência (*jitter*) são rapidamente refletidos na qualidade percebida, manifestando-se na forma de travamentos, *tearing* ou perda de sincronização.

Hong et al. [8] avaliaram três jogos executados a 720p sobre o *GamingAnywhere* e observaram que o MOS (*Mean Opinion Score*) tende a saturar em torno de 2 Mbit s^{-1} . Acima desse valor, aumentos na taxa de bits produzem ganhos perceptuais limitados; abaixo dele, a qualidade percebida se deteriora rapidamente. Esse comportamento reforça a importância de considerar métricas de cauda, como valores de pico e percentis elevados (p99), em vez de medidas centrais como a mediana, abordagem que será retomada no Capítulo IV.

Como o processo de codificação é executado no servidor, este possui controle direto sobre a principal variável reconfigurável do pipeline: a taxa de bits-alvo do codificador. O servidor constitui, portanto, o ponto mais natural para a implementação da política de adaptação, dispensando mecanismos adicionais de cooperação por parte do cliente ou da infraestrutura de rede. Essa observação motiva o recorte adotado neste trabalho, detalhado no Capítulo III.

B. Codecs de Vídeo e Reconfiguração em Tempo de Execução

A compressão de vídeo em jogos em nuvem é dominada pelos padrões H.264, HEVC (H.265) e, mais recentemente, AV1, todos baseados em predição temporal entre quadros. Três tipos de quadros compõem um fluxo típico: quadros-I (*intra-coded*), codificados de forma independente; quadros-P (*predicted*), que dependem de quadros anteriores; e quadros-B (*bidirectional*), ausentes em jogos em nuvem por exigirem *buffer* adiante. Dentro da categoria de quadros-I, os quadros IDR (*Instantaneous Decoder Refresh*) zeram a referência do decodificador, isolando o erro de propagação após perdas — funcionando como mecanismo de recuperação de último recurso quando outras escadas de proteção (FEC, retransmissão seletiva) falham.

Entretanto, o custo dos quadros IDR é alto: por carregarem todo o conteúdo do quadro de forma independente, IDRs são substancialmente maiores que quadros-P, gerando picos abruptos no tráfego de saída. Quando o canal já se encontra próximo da saturação, a inserção de um IDR pode provocar enfileiramento no gargalo, elevando o RTT (*round-trip time*) e desencadeando uma cascata: o cliente, ao não receber o IDR a tempo, solicita outro, perpetuando o ciclo. Reduzir a frequência de IDRs é, portanto, um objetivo indireto, mas relevante, do controle adaptativo de taxa de bits.

A reconfiguração dinâmica da taxa de bits do codificador é suportada pelos principais *encoders* de hardware modernos. O trabalho de Hong et al. [8] foi pioneiro em estender o servidor open-source *GamingAnywhere* (GA) — antecessor direto do *Sunshine* — com suporte a reconfiguração de codec em tempo de execução, antes indisponível na plataforma. O presente trabalho herda diretamente esta linha: opera sobre uma plataforma open-source sucessora do GA e contribui exatamente com a política de decisão que aciona essa reconfiguração — não com a reconfiguração em si, que o *Sunshine* já suporta.

C. Controle de Congestionamento: do TCP ao Streaming

O controle de congestionamento na Internet é historicamente baseado no TCP. A família clássica de algoritmos TCP — incluindo Reno, NewReno e SACK — segue a política AIMD (*Additive Increase, Multiplicative Decrease*), em que a janela de congestionamento cresce de forma aditiva na ausência de perdas e é reduzida multiplicativamente quando uma perda é detectada. Embora estável e amplamente estudada, essa estratégia apresenta limitações em redes com alto produto banda-atraso. Em um enlace de 10 Gbit s^{-1} e RTT de 100 ms, por exemplo, o TCP clássico levaria aproximadamente 1,4 horas para recuperar a taxa de transmissão após uma única perda, o que o torna inadequado para diversas aplicações práticas [7].

Para contornar essa limitação, Ha, Rhee e Xu propuseram o algoritmo CUBIC [7], que substitui o crescimento linear da janela por uma função cúbica dependente do tempo transcorrido desde a última redução:

$$B(t) = C \cdot (t - K)^3 + W_{\max} \quad (1)$$

onde $W_{\max}$ representa o tamanho da janela imediatamente antes da última perda, K corresponde ao instante em que a curva retorna a esse valor, e C é uma constante que determina a taxa de crescimento. Para $t < K$, a curva é côncava e promove uma recuperação rápida em direção ao valor anteriormente alcançado. Nas proximidades de $t = K$, o crescimento torna-se mais gradual, enquanto para $t > K$ a curva assume formato convexo e passa a explorar capacidades adicionais da rede. Dessa forma, o CUBIC combina recuperação rápida após perdas com uma expansão mais cuidadosa acima do último ponto de operação conhecido.

CUBIC introduz adicionalmente o mecanismo de *fast convergence* (Equação 3.7 do trabalho original), que reduz $W_{\max}$ quando uma nova redução é disparada antes da recuperação completa. O efeito é prático: em cenários de congestionamento sustentado, em que a capacidade real do caminho está abaixo do último $W_{\max}$ conhecido, o algoritmo deixa de mirar um teto obsoleto, convergindo para a capacidade efetiva.

CUBIC é o algoritmo de controle de congestionamento *default* no kernel Linux desde a versão 2.6.18 (2006) e também o mais implantado na Internet. Sua relevância para este trabalho é dupla. Em primeiro lugar, o CUBIC fornece uma estratégia de recuperação amplamente estudada na literatura, capaz de substituir a heurística de crescimento utilizada pelo controlador de referência previamente avaliado. Além disso, o mecanismo de *fast convergence* contribui para evitar a persistência de valores máximos incompatíveis com a capacidade efetiva do caminho em situações de congestionamento prolongado. A adaptação desses mecanismos ao contexto de mídia em tempo real é apresentada no Capítulo III.

D. Controle Adaptativo para Mídia em Tempo Real

O controle de congestionamento em fluxos de mídia em tempo real sobre UDP — em que retransmissão é inviável e o sinal de perda chega tardio — exige sinais distintos do TCP.

Dois trabalhos estabelecem o estado da arte fora do contexto específico de jogos em nuvem.

1) *GCC — Google Congestion Control*: O algoritmo GCC, descrito por Carlucci et al. [6], é o controlador de congestionamento utilizado pelo WebRTC e incorporado em aplicações como Chromium e Google Hangouts. Diferentemente do TCP clássico, o GCC não utiliza a perda de pacotes como principal sinal de congestionamento. Em vez disso, baseia-se na variação do atraso unidirecional entre pacotes consecutivos para detectar o início da formação de filas, ajustando a taxa de envio por meio de uma política AIMD. Essa abordagem prioriza a manutenção de baixa latência em detrimento da máxima utilização da largura de banda, característica desejável em aplicações sensíveis a atraso, como videoconferência e cloud gaming.

O GCC reforça algumas das premissas adotadas neste trabalho. Em primeiro lugar, indica que, em aplicações de mídia em tempo real, sinais baseados em atraso tendem a ser mais adequados do que sinais baseados em perda. Além disso, mostra que estratégias inspiradas em AIMD continuam sendo eficazes quando adaptadas às características da aplicação. Por fim, demonstra que o controle pode ser implementado inteiramente do lado do remetente, exigindo apenas os mecanismos de *feedback* já disponíveis. No WebRTC, esse papel é desempenhado pelo RTCP; no Sunshine, utiliza-se o RTT mantido pela biblioteca ENet no canal de controle do protocolo Moonlight.

A principal diferença em relação à abordagem proposta está na granularidade do controle. Enquanto o GCC opera em nível de pacote e recebe *feedback* contínuo do receptor, o controlador desenvolvido neste trabalho atua em nível de quadro e utiliza amostras de RTT obtidas a cada ciclo de decisão. Essa escolha decorre das características do protocolo de streaming empregado e do custo associado a modificações no protocolo Moonlight.

2) *ABRAGame*: O algoritmo ABRAGame, proposto por Armendariz e Joskowicz [5], representa o trabalho mais recente em controle adaptativo de taxa de bits especificamente voltado a jogos em nuvem. O sinal central é *latência cumulativa em uma janela deslizante de 500 ms*, calculado no cliente a partir de medições de atraso unidirecional amostradas a cada 20 ms. A política prioriza explicitamente *estabilidade sobre qualidade*: aceita reduções agressivas de resolução em troca de evitar travamentos e quadros congelados, alinhando-se à assimetria de QoE identificada por Hong et al. [8].

ABRAGame reforça a importância de métricas baseadas em atraso em aplicações de cloud gaming e a prioridade atribuída à estabilidade percebida pelo usuário. A principal diferença em relação à abordagem proposta neste trabalho está no requisito de sincronização entre os relógios do cliente e do servidor. O cálculo do atraso unidirecional pressupõe que ambos estejam sincronizados, condição difícil de garantir em redes domésticas e indisponível no protocolo Moonlight sem modificações adicionais. Em contraste, nossa abordagem opera exclusivamente sobre RTT, métrica mantida pela biblioteca ENet no canal de controle e já exposta pelo Sunshine, dispensando qualquer

cooperação adicional do cliente.

E. O Trabalho Mais Próximo: C³G

Dentre os trabalhos relacionados, o mais próximo da abordagem proposta é o C³G (*Congestion Control for Cloud Gaming over UDP based on Round-Trip Video Latency*), de Alós et al. [4]. O C³G é um controlador de taxa de bits do lado servidor, baseado em latência e inspirado em conceitos do algoritmo BBR (*Bottleneck Bandwidth and RTT*), tendo sido implementado sobre a plataforma de cloud gaming PlayGiga.

Seu sinal principal, denominado *Round-Trip Video Latency* (RTVL), corresponde a uma estimativa, calculada por quadro, do tempo transcorrido entre o início da codificação no servidor e a chegada da confirmação correspondente do cliente. A partir dessa métrica, o controlador combina uma fase reativa, responsável por reduzir a taxa de bits quando o RTVL excede determinados limiares, com uma fase proativa, em que informações de estados previamente observados orientam novas sondagens de taxa.

Embora compartilhe com o C³G a utilização de sinais de atraso para controle adaptativo no servidor, a abordagem proposta neste trabalho difere em alguns aspectos importantes. Enquanto o C³G depende do envio de confirmações associadas a cada quadro de vídeo, exigindo modificações no protocolo de *streaming*, nossa implementação utiliza apenas o RTT já mantido pela biblioteca ENet no canal de controle do Moonlight. Além disso, a proposta é incorporada ao Sunshine, um projeto open-source amplamente utilizado pela comunidade de cloud gaming self-hosted, em contraste com a plataforma proprietária PlayGiga utilizada pelos autores.

Outra diferença está no mecanismo de recuperação após reduções de taxa. Em vez da heurística baseada em um dicionário de estados empregada pelo C³G, adotamos a curva de crescimento do algoritmo CUBIC [7], amplamente estudada na literatura de controle de congestionamento. Por fim, o compromisso entre utilização do canal e picos de atraso discutido por Alós et al. é mantido como referência para a avaliação experimental, permitindo comparar os resultados obtidos com aqueles reportados pelo estado da arte.

F. O Servidor Sunshine

O *Sunshine* é um servidor open-source de *streaming* de jogos compatível com o protocolo NVIDIA GameStream e cliente Moonlight, mantido sob a licença GPL-3.0 pela comunidade LizardByte. Surgiu como uma alternativa open-source mais recente ao GamingAnywhere — plataforma alvo do trabalho de Hong et al. [8] —, oferecendo suporte oferecendo suporte multiplataforma e múltiplos mecanismos de captura e codificação de vídeo. Sua posição como alternativa *self-hosted* a plataformas comerciais como GeForce NOW e Xbox Cloud Gaming torna-o um veículo de impacto direto para contribuições em jogos em nuvem.

O pipeline interno do Sunshine encadeia captura de tela, codificação, encapsulamento e envio sobre UDP — vídeo com proteção Reed-Solomon (FEC) e canal de controle sobre ENet —, com a taxa de bits do codificador negociada uma

única vez ao início da sessão por meio do protocolo RTSP. Após a negociação inicial, o servidor opera com taxa de bits fixa: não há, na linha base, qualquer mecanismo de reação a degradação observada do canal. Essa limitação motiva a proposta apresentada neste trabalho.

proposta e sua integração na arquitetura do Sunshine; o Capítulo IV detalha o protocolo experimental de avaliação.

III. CONTRIBUIÇÃO

Este capítulo apresenta o MACCA, controlador adaptativo de taxa de bits proposto para o Sunshine. A exposição segue cinco eixos: o recorte do problema e as decisões de projeto que o delimitam; a visão geral da política de controle; o detalhamento do algoritmo de detecção e atuação; a justificativa para a cadência de decisão e o uso de histerese; e, por fim, a descrição da integração do controlador na arquitetura do Sunshine.

A. Recorte do Problema

A política de controle proposta foi delimitada por três decisões de projeto que precedem qualquer escolha algorítmica. A primeira estabelece que toda a lógica opera no servidor, utilizando apenas sinais já disponíveis no Sunshine, sem modificações no protocolo Moonlight nem cooperação adicional do cliente. Essa restrição é motivada por questões práticas: o Sunshine compartilha o protocolo com clientes Moonlight de terceiros, cuja evolução está fora do controle do projeto, tornando inviável qualquer requisito de extensão. A segunda decisão é a adoção do RTT como sinal único, em contraposição a métricas que exigiriam sincronização de relógio ou *feedback* adicional por quadro. O RTT é mantido continuamente pela biblioteca ENet no canal de controle e já é exposto pelo Sunshine, o que o torna o sinal de menor custo operacional disponível.

A terceira decisão consiste em priorizar métricas de cauda da distribuição de latência, como picos, p99 e eventos de *stall*, em detrimento de medidas centrais como a mediana (p50). Essa escolha decorre da assimetria de QoE discutida no Capítulo II: ganhos acima do patamar de saturação do MOS são marginais, enquanto degradações abaixo dele comprometem significativamente a jogabilidade.

Esse recorte diferencia diretamente o presente trabalho do estado da arte mais próximo. O C³G de Alós et al. [4] também opera no servidor, mas depende do envio de confirmação por quadro de vídeo, exigindo extensão do protocolo. O ABRAGame de Armendariz e Joskowicz [5] opera majoritariamente no cliente e pressupõe sincronização de relógio para o cálculo de atraso unidirecional. O GCC de Carlucci et al. [6] opera por pacote sobre *feedback* RTCP contínuo, granularidade incompatível com o canal de controle do Moonlight. Cada uma dessas abordagens é viável em seu ambiente original; nenhuma é diretamente transplantável ao Sunshine sem custos arquiteturais substanciais.

B. Visão Geral do Controlador

O MACCA é uma política de controle baseada em *Additive Increase, Multiplicative Decrease* (AIMD), complementada




Fig. 1. Máquina de estados do controlador MACCA. A cada amostra de RTT (setas cinzas), o controlador transita entre os estados *estável* e *congestionado* conforme o RTT ultrapassa o limiar τ_{cong} ou retorna abaixo de $\tau_{\text{cong}} - m$, onde m é a margem de histerese. A cada ciclo de decisão a 1 Hz (setas azuis), e desde que o *streak* de duração mínima associado (h_{down} para decrementos, h_{up} para incrementos) tenha sido acumulado, o controlador atua sobre a taxa de bits-alvo do codificador: *decrecendo* a partir de *congestionado*; *recuperando* ou *sondando* a partir de *estável*, conforme a amostra $B(t)$ da curva cúbica de recuperação esteja abaixo ou acima do teto L . Os rótulos da fila inferior persistem até o próximo ciclo de decisão.

por dois mecanismos do algoritmo CUBIC [7]: a curva cúbica de recuperação após reduções de taxa e o mecanismo de *fast convergence* para atualização do teto de referência. O controlador é organizado como uma máquina de estados composta por cinco estados (*estável*, *congestionado*, *decrecendo*, *recuperando* e *sondando*), sendo avaliado periodicamente a partir de amostras de RTT obtidas durante a transmissão.

As amostras de RTT são coletadas continuamente ao longo da transmissão e utilizadas para atualizar os contadores de duração contínua acima e abaixo dos limiares configurados. As decisões de controle, entretanto, são tomadas em uma cadência fixa de 1 Hz, desacoplada da taxa de quadros do codificador. Em cada ciclo de decisão, o controlador determina se a taxa de bits-alvo deve ser mantida, reduzida ou aumentada. Reduções são disparadas quando o RTT permanece acima do limiar por um intervalo correspondente à histerese configurada, enquanto aumentos ocorrem após períodos sustentados abaixo do limiar e seguem a curva cúbica do CUBIC para definir a magnitude do incremento.

C. Algoritmo

1) *Sinal e Detecção*: O controlador recebe, a cada quadro codificado, uma amostra de RTT proveniente da biblioteca ENet [9]. A partir dessa amostra, dois contadores de duração são mantidos. O primeiro, denominado *streak* de congestão, registra o início da janela contínua mais recente em que o RTT permanece acima do limiar de referência τ_{cong} ; é reiniciado sempre que uma amostra retorna a valores aceitáveis. O segundo, denominado *streak* de via livre, registra simetricamente o início da janela contínua em que o RTT permanece abaixo de $\tau_{\text{cong}} - m$, onde m é uma margem de histerese introduzida pela razão discutida adiante. Os dois contadores são atualizados continuamente, mas não disparam decisões por si só.

2) *Decremento Multiplicativo com Fast Convergence*: Quando o *streak* de congestão atinge uma duração mínima h_{down} , o controlador aplica uma redução multiplicativa à taxa atual:

$$\text{kbps}_{\text{novo}} \leftarrow \max(\beta \cdot \text{kbps}, \text{kbps}_{\text{min}}) \quad (2)$$

onde $\beta \in (0, 1)$ é o fator de retenção e kbps_{min} é o piso de operação. Adota-se $\beta = 0,7$, valor utilizado no controlador AIMD de referência e mantido nesta versão para isolar o efeito das demais alterações.

Antes da redução propriamente dita, o teto de recuperação L (último valor conhecido considerado seguro) é atualizado. Em condições normais, em que a taxa atual ainda corresponde ao último patamar estável, L recebe o valor da taxa atual. Em condições de congestionamento persistente, em que uma nova redução é disparada antes que o controlador tenha recuperado o patamar anterior, situação caracterizada por $\text{kbps} < L$ no instante do disparo, L é atualizado segundo o mecanismo de fast convergence do CUBIC:

$$L \leftarrow \text{kbps} \cdot \frac{1 + \beta}{2} \quad (3)$$

Esse ajuste retira do controlador a expectativa de retornar a um teto que se mostrou inalcançável, fazendo-o convergir para uma estimativa progressivamente mais próxima da capacidade efetiva do canal. Em cenários de constrição prolongada, o mecanismo evita que a curva de recuperação descrita a seguir fique perpetuamente apontando para um valor obsoleto.

3) *Curva de Recuperação Cúbica*: Quando o *streak* de via livre atinge uma duração mínima h_{up} , o controlador aplica um incremento à taxa atual. A magnitude do incremento é determinada por uma amostragem da curva cúbica de recuperação do CUBIC [7]:

$$B(t) = C \cdot (t - K)^3 + L \quad (4)$$

onde t é o tempo decorrido em segundos desde a última redução, L é o teto de recuperação definido por (3), K é o tempo nominal de recuperação até L , e $C = (1 - \beta) \cdot L / K^3$. A nova taxa-alvo é $B(t)$, restrita ao intervalo $[\text{kbps}, \text{kbps}_{\text{max}}]$, de modo que a curva nunca conduz a uma redução, apenas a manutenção ou crescimento.

A forma de $B(t)$ é a mesma do CUBIC original, descrita no Capítulo II: côncava para $t < K$, recuperando rapidamente em direção a L ; aproximadamente estável próximo de $t = K$; e convexa para $t > K$, sondando de forma cautelosa, e depois acelerada, taxas acima do último patamar conhecido. Para o presente trabalho, adotou-se $K = 15$ s, valor calibrado empiricamente para que a fase de sondagem inicie em uma escala compatível com a duração típica de janelas de constrição nos cenários avaliados.

Variações na ancoragem temporal de t e na regra de reinício do *streak* de via livre após crescimentos foram avaliadas empiricamente, com resultados que motivam a forma adotada aqui; essa análise é apresentada no Capítulo V, Seção V-D.




Fig. 2. Curva de recuperação $B(t)$ amostrada pelo controlador MACCA para dois valores do parâmetro K (5 s e 15 s), com $\beta = 0,7$ e $L = 10\,000$ kbps. A região côncava ($t < K$) promove recuperação rápida em direção ao teto L ; a região convexa ($t > K$) realiza sondagem cautelosa de capacidade adicional.

D. Cadência de Decisão e Histerese

Duas decisões de projeto merecem justificativa explícita por afetarem diretamente o comportamento dinâmico do controlador: a cadência de avaliação a 1 Hz e o uso de histerese nos disparos de decremento e incremento.

A cadência de 1 Hz é menor que a taxa de quadros do codificador (tipicamente 60 Hz) por escolha deliberada. Reconfigurações sucessivas e próximas no tempo da taxa do codificador introduzem custos que vão da reinicialização de contextos internos do *encoder* ao envio de quadros IDR não planejados, ambos potencialmente capazes de agravar a própria condição de congestionamento que o controlador busca aliviar. Espaçar as decisões em intervalos de um segundo permite que cada atuação se propague pelo *buffer* do gargalo e manifeste seu efeito no RTT antes que a próxima decisão seja tomada, evitando ciclos de realimentação curtos.

A histerese é um mecanismo clássico em sistemas de controle utilizado para evitar oscilações em torno de um limiar de decisão. No controlador proposto, ela é introduzida em dois níveis. Primeiro, exige-se que a condição de disparo (RTT sustentadamente acima ou abaixo do limiar) persista por uma duração mínima — h_{down} para decrementos e h_{up} para incrementos — antes que qualquer atuação ocorra. Esse requisito filtra picos transitórios de RTT, comuns em redes domésticas, que sob um critério instantâneo poderiam provocar uma sequência indesejada de cortes e recuperações.

Além disso, o controlador utiliza limiares distintos para identificar congestionamento e recuperação. Enquanto a entrada em congestionamento é caracterizada por RTT acima de τ_{cong} , a condição de via livre exige que o RTT permaneça abaixo de $\tau_{\text{cong}} - m$, onde m é uma margem de histerese. Dessa forma, pequenas oscilações do RTT em torno do limiar não fazem o controlador alternar continuamente entre os dois estados, permitindo que variações compatíveis com o ruído natural da rede sejam absorvidas sem disparar atuações desnecessárias.

Os valores adotados para todos os parâmetros do controlador

TABLE I
PARÂMETROS DO CONTROLADOR MACCA ADOTADOS NA CAMPANHA EXPERIMENTAL.

Parâmetro	Símbolo	Valor
Limiar de RTT (congestionamento)	τ_{cong}	100 ms
Margem de histerese	m	20 ms
Histerese de decremento	h_{down}	2000 ms
Histerese de incremento	h_{up}	1000 ms
Fator de retenção	β	0,70
Tempo nominal de recuperação	K	15 s
<i>Fast convergence</i>	—	ativo
Intervalo de decisão	—	1000 ms
Taxa mínima	kbps_{min}	1000 kbit s ⁻¹
Taxa máxima	kbps_{max}	inicial da sessão

são sintetizados na Tabela I. A escolha de cada valor seguiu a calibração empírica conduzida ao longo do desenvolvimento e descrita parcialmente no Capítulo IV.

E. Integração no Sunshine

A política de controle foi implementada como uma classe isolada em `src/bitrate_controller.{h, cpp}`, contendo exclusivamente lógica de decisão, sem qualquer acoplamento a mecanismos de entrada ou saída do servidor. A classe expõe um único método de atualização, `on_sample`, que recebe uma estrutura com a amostra de RTT corrente e retorna, opcionalmente, uma nova taxa de bits-alvo quando uma decisão de atuação é tomada. Essa separação preserva a testabilidade do componente, viabilizando cobertura por testes unitários em *gtest* [10] sob `tests/` sem necessidade de infraestrutura de rede.

A integração com o restante do servidor ocorre em `src/stream.cpp`, no laço principal de transmissão de vídeo. A cada quadro codificado, a *thread* de *broadcast* consulta o RTT corrente fornecido pela biblioteca ENet e invoca `on_sample`; quando o controlador retorna uma nova taxa-alvo, a *thread* aciona o mecanismo de reconfiguração do codificador.

Os parâmetros do controlador foram expostos ao usuário em `src/config.cpp`, junto aos demais parâmetros de *streaming*. A escolha de tornar os parâmetros configuráveis, em vez de fixá-los no código, decorre da expectativa de que diferentes perfis de uso, tipos de jogo e condições típicas de rede do usuário possam exigir calibrações próprias, e do reconhecimento de que a campanha experimental conduzida neste trabalho cobre apenas um subconjunto desses cenários. As mensagens visíveis ao usuário adotam `boost::locale::translate` para internacionalização, em conformidade com a convenção do projeto. O código segue as diretrizes de formatação do `.clang-format` do repositório e foi submetido como contribuição ao projeto *upstream*.

IV. METODOLOGIA

Este capítulo apresenta o ambiente experimental e os procedimentos utilizados para avaliar o controlador proposto.

TABLE II
ESPECIFICAÇÕES DO TESTBED EXPERIMENTAL.

Componente	Especificação
CPU (servidor)	AMD Ryzen 7 7700 (8 núcleos, 16 threads)
RAM (servidor)	32 GB
GPU (servidor)	NVIDIA GeForce RTX 4070 SUPER
Codificador	NVENC
Sistema operacional	Fedora Linux 43
Kernel	Linux 6.19
Interface de rede (servidor)	Ethernet 1 Gbps
Cliente	Smartphone Android, <i>Moonlight</i>
Conexão do cliente	Wi-Fi, mesma rede local

A. Testbed e Carga de Trabalho

O servidor de *streaming* executa o Sunshine sobre o hardware descrito na Tabela II.

A degradação de rede foi emulada no servidor via `tc` [11] com disciplina HTB, aplicada à interface de saída `eno1`. Essa abordagem permite limitar a capacidade do enlace de forma determinística e reproduzível, sem introduzir atrasos artificiais que poderiam confundir o sinal de RTT utilizado pelo controlador. Os *scripts* de *shaping* adotados estão disponíveis no repositório do projeto.

A carga de trabalho utilizada em todas as sessões foi o jogo *Celeste*, escolhido por três motivos complementares. O primeiro é o perfil de *rendering* leve: o estilo visual 2D mantém a taxa de bits demandada pelo codificador em patamares relativamente estáveis, evitando que a variação do canal seja confundida com variação do conteúdo. O segundo é a sensibilidade do *gameplay* à latência: a mecânica baseia-se em saltos de precisão e janelas curtas de reação, condição em que travamentos e atrasos são imediatamente perceptíveis ao operador. O terceiro é a previsibilidade do comportamento entre sessões, característica desejável para que diferenças observadas entre controladores possam ser atribuídas ao próprio controlador, e não ao conteúdo exibido.

B. Cenários de Avaliação

Foram definidos seis cenários de degradação de rede, sintetizados na Tabela III, escolhidos para cobrir as principais formas em que um canal doméstico pode degradar ao longo de uma sessão de jogo. Os cenários variam em três dimensões complementares: a forma da degradação (queda abrupta, em degraus, em janelas alternadas, ou contínua); a severidade da constrição (de 16 Mbit s^{-1} até 4 Mbit s^{-1}); e a duração total do período sob *shaping* (de janelas curtas de 30 s a constrições contínuas de 160 s). Fora das janelas indicadas, o enlace opera sem restrição imposta pelo `tc`, ou seja, na capacidade nativa de 1 Gbit s^{-1} .

O cenário A representa uma queda abrupta e prolongada, testando a capacidade do controlador de reagir a um corte único e sustentado. O cenário B aplica degraus sucessivos de severidade crescente, exigindo do controlador adaptações encadeadas em curto intervalo. O cenário C aplica dois patamares mais longos, simulando uma transição entre regimes de banda. O cenário D alterna entre quatro janelas curtas de constrição

TABLE III
CENÁRIOS DE DEGRADAÇÃO DE REDE UTILIZADOS NA CAMPANHA EXPERIMENTAL. FORA DAS JANELAS INDICADAS, O CANAL OPERA SEM RESTRIÇÃO.

Cenário	Capacidade	Janela de shaping
A	8 Mbps	80–160 s
B	16 / 12 / 8 Mbps	60–90 / 90–120 / 120–160 s
C	14 / 10 Mbps	40–120 / 120–200 s
D	10 Mbps	30–60 / 90–120 / 150–180 / 210–240 s
E	4 Mbps	40–200 s
F	6 Mbps	0–160 s

e períodos de recuperação, testando o comportamento do controlador em ciclos de degradação e restauração. Os cenários E e F representam constrições contínuas, severa e moderada respectivamente, em que o controlador deve estabilizar a operação dentro do envelope imposto pela rede.

C. Controladores Comparados

Três controladores foram avaliados, identificados como referência fixa, AIMD de base e MACCA. O controlador de referência fixa corresponde ao comportamento original do Sunshine, em que a taxa de bits é negociada uma única vez ao início da sessão e mantida constante até o fim. O controlador AIMD de base aplica corte multiplicativo com fator $\beta = 0,7$ ao detectar congestionamento e cresce em duas fases (“ $\times \gamma$ depois $+\Delta$ ”), sem o mecanismo de *fast convergence*; corresponde à versão do controlador adaptativo que antecedeu a contribuição apresentada neste trabalho. O controlador MACCA corresponde à contribuição descrita no Capítulo III, com os parâmetros sintetizados na Tabela I.

D. Instrumentação e Métricas

A coleta de dados em *runtime* é realizada pelo próprio Sunshine por meio de uma extensão de instrumentação desenvolvida durante este trabalho. A cada amostra de RTT recebida da biblioteca ENet, um registro é exportado para um arquivo CSV contendo o instante de amostragem, o RTT, a variância do RTT, o tempo de envio do quadro mais recente, o tamanho do quadro codificado, a taxa de bits-alvo corrente, o estado do controlador e indicadores de eventos relevantes (envio de quadro IDR, requisição de IDR pelo cliente). A taxa de amostragem é a própria taxa de quadros do codificador, tipicamente próxima de 60 Hz.

A partir do CSV de cada sessão são derivadas as métricas agregadas reportadas no Capítulo V. As métricas de latência incluem o pico de RTT, os percentis 50, 95 e 99 da distribuição, e a fração do tempo total em que o RTT excede o limiar de 100 ms estabelecido como referência para jogos de ação [1]. As métricas de throughput incluem a taxa de bits média sustentada durante a janela de *shaping* e o uso do canal, definido como a razão entre essa média e a capacidade imposta pela emulação. As métricas de continuidade incluem a contagem de *stalls*, definidos como intervalos consecutivos superiores a 100 ms sem entrega de quadros ao cliente, o tempo total acumulado em *stall*, e a contagem de quadros

IDR emitidos durante a sessão. Esta última é utilizada como indicador indireto de recuperação após perdas que escaparam aos mecanismos de FEC.

Adicionalmente, ao final de cada sessão o operador registrou três avaliações subjetivas em escala de 1 a 5, em que 1 corresponde à melhor avaliação: *latência percebida*, *qualidade visual* e *estabilidade*.

E. Protocolo de Execução

A campanha experimental do controlador MACCA compreendeu uma execução para cada combinação de controlador e cenário, totalizando seis novas execuções. Os resultados correspondentes aos controladores fixo e AIMD de base foram reaproveitados de uma campanha anterior realizada sobre o mesmo *testbed* e com a mesma configuração do servidor, em razão da baixa variabilidade observada entre repetições.

Em todas as execuções, o jogo *Celeste* foi utilizado como carga de trabalho, seguindo uma sequência de fases pré-determinada com duração aproximada de quatro minutos. O tráfego do enlace foi submetido aos cenários de *shaping* descritos na Tabela III, iniciados no instante zero da sessão. Ao término de cada execução, foram registradas as avaliações subjetivas descritas na seção anterior, e os dados exportados pelo Sunshine foram armazenados para posterior análise.

F. Uso de Inteligência Artificial como Ferramenta de Pesquisa

Ferramentas de inteligência artificial baseadas em LLM foram empregadas em dois pontos do trabalho. O primeiro foi o apoio à implementação em C++ do controlador e de sua integração ao Sunshine, incluindo o ajuste de testes em *gtest* e a conformidade com as convenções de estilo do projeto *upstream*. Todo o código produzido com esse apoio foi revisado, compilado e testado pelo pesquisador antes de qualquer submissão ao repositório *upstream*, e nenhuma alteração foi incorporada sem verificação.

O segundo foi a estruturação de uma base de conhecimento local, em formato Markdown compatível com o *Obsidian*, utilizada como apoio à navegação do material bibliográfico, da documentação interna do Sunshine, e do registro das iterações de *design* do controlador. A base é composta por análises individuais (de *papers* lidos, de subsistemas do Sunshine e de Linux, e de cada iteração de projeto), com referências cruzadas via *wikilinks* que permitem visualização em grafo. A síntese inicial de cada arquivo foi auxiliada por IA a partir da leitura primária do material pelo pesquisador, com edições e validações subsequentes realizadas manualmente.

O uso de IA neste trabalho restringiu-se ao apoio à implementação de código e à estruturação da base de conhecimento de pesquisa, ambos sob revisão e validação do pesquisador. As decisões de projeto, a análise dos resultados experimentais e as conclusões apresentadas são de autoria própria.

V. RESULTADOS

A. Visão Geral

A Tabela IV sintetiza, para cada par (controlador, cenário), as métricas agregadas definidas no Capítulo IV. A Figura 3 visualiza as principais delas em forma comparativa.

Três observações orientam a discussão subsequente. Primeiro, o controlador MACCA apresenta o menor pico de RTT em cinco dos seis cenários (A, B, C, D, E), com a maior redução ocorrendo no cenário A (1786 para 1025 ms, queda de 43%). Segundo, o mesmo controlador eleva o RTT mediano (p50) em todos os cenários, passando de 4–5 ms no controlador AIMD de base para 12–23 ms no MACCA. Terceiro, a comparação com a referência sem ABR é categórica: o tempo total acumulado em *stall* cai entre 90% e 100% nos dois controladores adaptativos relativamente ao caso sem controle, com 40 s–150 s de *stall* por sessão de quatro minutos no controlador fixo. A ausência de ABR é consistentemente a pior experiência, independentemente da forma da degradação.

B. Análise por Cenário

A análise cenário a cenário esclarece em quais regimes cada controlador opera melhor. A Figura 4 reúne as trajetórias de RTT ao longo das sessões, com o perfil de *shaping* sobreposto como referência visual.

Cenário A (queda abrupta). A queda súbita de banda livre para 8 Mbit s^{-1} em $t = 80 \text{ s}$ expõe o ganho mais nítido do controlador MACCA. O pico de RTT cai 43% em relação ao AIMD de base (1025 vs. 1786 ms), e o número de *stalls* é reduzido a zero. A combinação da curva cúbica de recuperação com o mecanismo de *fast convergence* absorve a restrição sem que o codificador chegue a congelar. O controlador AIMD de base, ainda que apresente p95 substancialmente menor (55 vs. 183 ms), exibe um pico de cauda próximo do observado sem ABR.

Cenário B (degraus sucessivos). A redução gradual em três degraus (16 / 12 / 8 Mbps) é o cenário em que o controlador AIMD de base mais se beneficia de sua simplicidade. A diferença no pico de RTT entre os dois controladores adaptativos é pequena (575 vs. 532 ms, queda de 7% no MACCA). O regime estacionário, porém, é claramente superior no AIMD de base, com p50 de 4 ms contra 18 ms do AIMD CUBIC, e essa vantagem se reflete na avaliação subjetiva amplamente favorável (1 / 1 / 2 vs. 3 / 2 / 2). O p95 do MACCA (123 ms) é, contudo, menor que o do AIMD de base (194 ms), indicando que a contenção de picos isolados ocorre mesmo nesse cenário em que o regime estacionário é a dimensão dominante da percepção.

Cenário C (dois patamares). A transição lenta entre 14 e 10 Mbit s^{-1} expõe um padrão similar ao do cenário B. O MACCA reduz o pico em 13%, mas o AIMD de base alcança a única avaliação subjetiva perfeita da campanha (1 / 1 / 1). O p95 do MACCA (298 ms) é mais que o dobro do AIMD de base (116 ms), e essa elevação do regime estacionário é percebida pelo operador como degradação visual ainda que os eventos de cauda sejam menos frequentes.

TABLE IV

RESULTADOS AGREGADOS DA CAMPANHA EXPERIMENTAL. VALORES EM NEGRITO INDICAM O MELHOR DESEMPENHO ENTRE OS TRÊS CONTROLADORES NO RESPECTIVO CENÁRIO; AS COLUNAS DE DECREMENTOS, INCREMENTOS E QUADROS IDR REGISTRAM ATIVIDADE DO CONTROLADOR E NÃO ADMITEM ORDENAÇÃO DIRETA. PARA AS AVALIAÇÕES SUBJETIVAS (ESCALA 1 = MELHOR, 5 = PIOR), O DESTAQUE MARCA O CONTROLADOR SUBJETIVAMENTE PREFERIDO, CONFORME MENOR SOMA DAS TRÊS NOTAS.

Cenário	Controlador	Pico (ms)	p99 (ms)	p95 (ms)	p50 (ms)	Decr.	Incr.	Stalls	T. stall (ms)	IDR	lat/qual/estab
A	sem ABR	1854	1801	1723	4	0	0	43	49 337	10	5 / 1 / 5
	AIMD de base	1786	1713	55	4	7	25	4	4408	35	3 / 1 / 3
	MACCA	1025	913	183	16	9	82	0	0	97	3 / 2 / 3
B	sem ABR	1551	1481	1323	5	0	0	50	43 550	27	4 / 1 / 4
	AIMD de base	575	544	194	4	7	22	0	0	30	1 / 1 / 2
	MACCA	532	486	123	18	7	67	0	0	78	3 / 2 / 2
C	sem ABR	1565	1541	1481	6	0	0	107	87 452	104	4 / 1 / 4
	AIMD de base	733	504	116	5	7	28	0	0	36	1 / 1 / 1
	MACCA	639	566	298	13	12	115	0	0	133	2 / 1 / 3
D	sem ABR	1583	1531	1442	16	0	0	103	91 501	97	4 / 1 / 3
	AIMD de base	1156	877	117	5	7	31	0	0	39	2 / 1 / 2
	MACCA	998	979	522	12	16	161	0	0	186	3 / 1 / 3
E	sem ABR	3788	3630	3435	22	0	0	59	135 167	5	5 / 1 / 5
	AIMD de base	3808	3533	3354	5	16	25	5	11 010	43	3 / 3 / 3
	MACCA	3311	3185	2980	23	16	128	2	4306	151	3 / 3 / 4
F	sem ABR	2536	2453	2308	22	0	0	100	148 855	72	5 / 1 / 4
	AIMD de base	1602	1551	263	5	13	33	2	2852	50	3 / 2 / 3
	MACCA	1863	1832	477	12	17	128	4	5961	156	2 / 1 / 2




Fig. 3. Comparação entre os três controladores nos seis cenários, agrupada por métrica. Da esquerda para a direita: pico de RTT, percentil 99, percentil 95, tempo total acumulado em *stall*, e contagem de quadros IDR emitidos.

Cenário D (janelas curtas alternadas). O padrão de quatro janelas de 30 s de constrição alternadas com períodos livres é o que mais desafia o MACCA. A cada janela livre, o controlador inicia uma sondagem cúbica agressiva; a cada nova constrição, dispara uma cascata de cortes. O resultado é um p95 explodido (522 vs. 117 ms do AIMD de base) e uma sensação de instabilidade, caracterizada pelas 161 atuações de incremento ao longo da sessão. O pico de RTT é levemente menor no MACCA (998 vs. 1156 ms), mas a vantagem é eclipsada pela piora do regime estacionário.

Cenário E (constrição pesada longa). A restrição para 4 Mbit s⁻¹ sustentada por 160 s é o cenário mais severo da campanha, e aquele em que o argumento favorável ao MACCA se sustenta com maior força. O pico de RTT cai de 3808 para 3311 ms (13%), e o tempo total em *stall* é reduzido de 11.0 s para 4.3 s, queda de 61%. O controlador sem ABR sofre 135 s de *stall* acumulado sobre os 160 s de constrição, equivalente

a 84% do período: do ponto de vista do jogador, a sessão é efetivamente tornada injogável.

Cenário F (constrição moderada contínua). A restrição para 6 Mbit s⁻¹ ativa desde $t = 0$ é o único cenário em que o MACCA regride relativamente ao AIMD de base. O pico de RTT sobe 16% (1602 para 1863 ms) e o tempo em *stall* é mais que dobrado. O diagnóstico é estrutural: como a constrição existe desde o início da sessão, o controlador nunca chega a operar em uma fase não restrita; o teto de recuperação *last_known_good* é inicializado com o valor negociado de sessão (próximo de 19 Mbit s⁻¹) e a curva inicial de recuperação fica apontada para esse teto fictício, jamais alcançável. O mecanismo de *fast convergence* corrige progressivamente o teto à medida que cascatas sucessivas ocorrem, mas a primeira janela de recuperação é desperdiçada buscando uma capacidade que nunca esteve disponível. Vale notar, contudo, que a avaliação subjetiva no cenário F favorece




Fig. 4. Trajetórias de RTT ao longo das sessões nos seis cenários, para cada controlador. As regiões sombreadas indicam as janelas de *shaping* ativas. A escala de tempo é a duração da sessão (240 s); a escala de RTT é logarítmica para preservar a visibilidade simultânea do regime estacionário e dos picos.

o MACCA (2 / 1 / 2 vs. 3 / 2 / 3 do AIMD de base), evidenciando que pico de RTT e percepção subjetiva não se alinham de forma mecânica.

C. Trade-off entre Métricas de Cauda e de Regime Estacionário

A análise conjunta dos resultados revela um trade-off sistemático entre métricas de cauda da distribuição de latência (pico, p99 e eventos de *stall*) e métricas do regime estacionário

(mediana e percentis intermediários). A Figura 5 sintetiza esse comportamento em uma única representação.

O agrupamento dos pontos por controlador é nítido. O AIMD de base concentra-se em medianas próximas de 4–5 ms, mas apresenta picos que cobrem praticamente todo o eixo vertical, alcançando valores superiores a 3.5s no cenário E. O MACCA, por sua vez, opera com medianas mais elevadas (12–23 ms), porém limita de forma mais consistente os eventos de cauda. Nenhum dos dois controladores domina




Fig. 5. Trade-off entre pico de RTT (cauda) e mediana de RTT (regime estacionário). Cada ponto representa um par (controlador, cenário). Eixos em escala logarítmica. O canto inferior-esquerdo representa o ideal.

o outro simultaneamente nos dois eixos, de modo que ambos contribuem para a fronteira de Pareto observada.

A Figura 6 reforça essa interpretação ao apresentar as distribuições cumulativas empíricas do RTT. As curvas do AIMD de base concentram grande parte das amostras em RTTs baixos, mas exibem caudas mais longas. Já o MACCA apresenta um piso mais elevado, porém com menor dispersão dos valores extremos. Em todos os cenários, as curvas dos dois controladores cruzam-se em torno de 100 ms.

Em síntese, o MACCA privilegia a contenção dos eventos extremos ao custo de uma elevação do RTT típico, enquanto o AIMD de base favorece o regime estacionário em detrimento de menor proteção contra picos de latência. A escolha entre ambos corresponde, portanto, a uma decisão de projeto sobre qual região da distribuição se deseja priorizar, e não a um juízo absoluto sobre qualidade.

D. Análise de Sensibilidade ao Design da Curva

A curva de recuperação cúbica adotada na contribuição (Capítulo III) foi escolhida após avaliação empírica de duas variantes alternativas, ambas mais fiéis à formulação original do algoritmo CUBIC [7]. A primeira variante, identificada como 5b, ancora o tempo decorrido t da curva no instante de retorno do RTT à condição de via livre (`rtt_clear_since`) em vez do instante da última redução (`last_decrease_at`). A motivação era teórica: o $t - K$ da curva pretende medir o tempo desde que o canal está genuinamente livre, e `rtt_clear_since` captura isso melhor que `last_decrease_at`, contaminado pelo tempo de drenagem do *buffer*. A segunda variante, identificada como 5c, mantém a âncora em `last_decrease_at` mas deixa de reinicializar o *streak* de via livre após cada incremento bem-sucedido, permitindo que t acumule monotonicamente entre cortes. Essa é a interpretação literal do parágrafo §3.1 do trabalho original do CUBIC.

TABLE V
PICO DE RTT (EM MS) SOB TRÊS VARIANTES DE DESIGN DA CURVA DE RECUPERAÇÃO. A FORMA FINAL É A ADOTADA NA CONTRIBUIÇÃO. VARIANTES REGREDIRAM EM TODOS OS CASOS AVALIADOS.

Variante	A K=5 s	A K=15 s	E K=15 s
Forma final (Idea 5)	796	1221	2305
Variante 5b	1105 (+39%)	1313 (+8%)	3192 (+39%)
Variante 5c	1116 (+40%)	1264 (+4%)	3013 (+31%)

A Tabela V apresenta o pico de RTT obtido em sessões repetidas dos cenários A e E com cada variante, mantidos os demais parâmetros.

A regressão é sistemática nos cenários estrangidos, particularmente no cenário E, em que ambas as variantes elevam o pico em mais de 30% relativamente à forma final. O diagnóstico é estrutural. A curva cúbica do CUBIC original foi formulada para amostragem por ACK, regime em que cada atualização da janela aplica um delta pequeno acumulado ao longo de muitas iterações por segundo. No controlador aqui proposto, a curva é amostrada a uma cadência de 1 Hz, em que cada atualização aplica o delta integral entre dois instantes de decisão. As variantes mais fiéis ao paper original mostram *overshoot* sistemático: o controlador cresce mais do que o canal pode absorver, dispara congestionamento novamente, e permanece em ciclo. A variante final, ao reinicializar o *streak* de via livre após cada crescimento, impõe um intervalo mínimo de espera entre crescimentos sucessivos, o que funciona como uma forma implícita de filtragem temporal ausente na formulação original.

Esse achado tem alcance maior que a presente contribuição. Algoritmos de controle de congestionamento projetados para amostragem densa não são, em geral, transponíveis a regimes de cadência reduzida sem ajuste estrutural. No caso do CUBIC, a adaptação que se mostrou empiricamente superior é também a mais simples, contradizendo a intuição de que maior fidelidade ao paper original implicaria melhor desempenho.

E. Avaliação Subjetiva

A Figura 7 apresenta as três avaliações subjetivas registradas ao final de cada sessão.

A avaliação subjetiva contradiz parcialmente a ordenação sugerida pelas métricas de cauda. O controlador AIMD de base recebe avaliações estritamente melhores nos cenários B, C e D, apesar de seu pico de RTT ser igual ou pior que o do AIMD CUBIC nesses mesmos cenários. O MACCA, por sua vez, recebe avaliação subjetiva claramente superior no cenário F, em que perde nos picos de RTT. Nos cenários A e E as avaliações são próximas. A leitura natural é que o regime estacionário (refletido em p50 e p95) tem peso perceptual maior que eventos de cauda isolados, exceto quando esses eventos ocorrem em magnitude e frequência elevadas, como no cenário E.

Esse padrão alinha-se às observações de QoE em jogos em nuvem discutidas no Capítulo II: a percepção do usuário é mais sensível à constância do que ao pico absoluto, contanto que




Fig. 6. Distribuição cumulativa empírica (CDF) do RTT por cenário e por controlador. A linha pontilhada marca o limiar de 100 ms.




Fig. 7. Avaliações subjetivas (escala 1 = melhor, 5 = pior) por cenário e por controlador, organizadas em três eixos: latência percebida, qualidade visual e estabilidade.

o pico permaneça abaixo de um limiar de tolerância. Quando esse limiar é ultrapassado, como no cenário E, a avaliação subjetiva se aproxima à medida que o desempenho objetivo se distingue.

VI. CONCLUSÃO

Este trabalho propôs e avaliou o MACCA, um controlador adaptativo de taxa de bits para o servidor de *streaming* de jogos em nuvem Sunshine. O controlador estende um esquema AIMD com duas primitivas do algoritmo CUBIC [7], a curva

cúbica de recuperação após reduções e o mecanismo de *fast convergence*, e opera exclusivamente a partir do RTT mantido pela biblioteca ENet no canal de controle, sem qualquer cooperação adicional do cliente. Avaliado contra um controlador de referência fixa e uma variante AIMD de base ao longo de seis cenários de degradação de rede, o controlador proposto reduz o pico de RTT em cinco dos seis cenários, com a maior queda alcançando 43% no cenário A, e o tempo total acumulado em *stall* em cinco dos seis cenários, com queda de 61% no cenário E. Esses ganhos são acompanhados de

uma elevação sistemática do RTT mediano, de 4–5 ms no AIMD de base para 12–23 ms no MACCA, configurando um trade-off explícito entre desempenho na cauda da distribuição de latência e desempenho no regime estacionário. Os dois controladores representam, portanto, escolhas de prioridade complementares, não soluções mutuamente dominantes.

A. Achados que Transcendem o Sunshine

A análise de sensibilidade ao design da curva (§V-D) isolou um achado de alcance maior que a contribuição imediata. Variantes mais fiéis à formulação original do CUBIC, incluindo a interpretação literal do parágrafo §3.1 do trabalho original, mostraram-se sistematicamente inferiores à forma final adotada neste trabalho. O diagnóstico é estrutural: a curva cúbica do CUBIC foi formulada para amostragem por ACK, regime em que pequenos deltas se acumulam ao longo de muitas iterações por segundo. Em controladores amostrados a cadências reduzidas, como o aqui proposto em 1 Hz, a curva passa a aplicar o delta integral entre instantes de decisão, e a fidelidade ao paper original deixa de ser empiricamente desejável. A transposição de algoritmos de controle de congestionamento entre regimes de cadência exige, portanto, ajuste estrutural, não apenas reparametrização.

Dois outros achados merecem destaque. O primeiro é que o RTT mantido server-side pela biblioteca ENet é, isoladamente, sinal suficiente para um controlador útil em jogos em nuvem, sem que sejam necessárias extensões de protocolo nem sincronização de relógio entre cliente e servidor. O segundo é que métricas de cauda (pico, percentil 99, eventos de *stall*) e métricas centrais (mediana, percentis intermediários) devem ser reportadas conjuntamente para caracterização correta de controladores adaptativos: nenhuma das duas isoladamente é suficiente para distinguir prioridades de projeto, e o desempenho subjetivo correlaciona de forma não-trivial com ambas.

B. Trabalhos Futuros

Cinco direções concretas emergem como continuação natural deste trabalho. A primeira é a introdução de uma memória de capacidade efetiva entre sessões, motivada pela regressão observada no cenário F. Naquele cenário, a curva inicial de recuperação fica apontada para o teto negociado de sessão, inalcançável dada a constrição ativa desde $t = 0$. Uma estimativa de capacidade carregada da sessão anterior permitiria que o controlador iniciasse com um teto `last_known_good` mais próximo da capacidade real do caminho, evitando a primeira cascata desperdiçada.

A segunda direção é a adoção de um sinal de detecção sub-segundo, possivelmente a partir do tempo de envio do quadro mais recente (`frame_send_ms`, já coletado na instrumentação atual). A latência de reação do controlador proposto é da ordem da histerese de decremento, e um sinal adicional que se manifeste antes da inflação do RTT pode encurtar o tempo entre o início do congestionamento e o corte de taxa.

A terceira direção é a introdução de um gatilho preditivo baseado em gradiente, na linha do controlador GCC para

WebRTC [6], capaz de antecipar a transição da fase de não-congestionamento para a fase de enfileiramento antes que o RTT cruze o limiar.

A quarta direção é a condução de uma avaliação subjetiva *crowdsourced*, segundo o protocolo de Hong et al. [8], em substituição às avaliações de operador único conduzidas neste trabalho. Esse formato permite quantificação estatística de Mean Opinion Score sob diferentes perfis de jogador, tipos de jogo, e condições de rede.

A quinta direção é a comparação direta do MACCA contra o GCC [6] e o ABRAGame [5] em um mesmo testbed, com a mesma instrumentação. Embora os trabalhos correlatos tenham reportado seu desempenho em ambientes próprios, a comparação cruzada em ambiente comum é a única forma robusta de posicionar o presente trabalho contra o estado da arte em métricas absolutas.

C. Impacto

O controlador proposto, juntamente com a instrumentação de coleta de métricas que o sustenta, será submetido como contribuição ao repositório *upstream* do Sunshine sob a licença GPL-3.0 do projeto. O testbed experimental, os *scripts* de geração de cenários, os dados de cada sessão e os *notebooks* de análise estão disponíveis para reprodução. As restrições metodológicas adotadas, como a execução única por cenário, a padronização da carga de trabalho em um único título e a avaliação subjetiva por um único operador, são documentadas ao longo do trabalho e abrem o caminho natural para as direções de trabalho futuro listadas acima.

REFERENCES

- [1] R. Baldovino, “An overview of the networking issues of cloud gaming: A literature review,” *Journal of Innovation Information Technology and Application (JINITA)*, vol. 4, no. 1, 2022.
- [2] LizardByte, “Sunshine: Self-hosted game stream host for Moonlight,” <https://github.com/LizardByte/Sunshine>, acessado em 2026.
- [3] Moonlight Game Streaming, “Moonlight: Open source implementation of NVIDIA’s GameStream protocol,” <https://moonlight-stream.org/>, acessado em 2026.
- [4] A. Alós, F. Morán, P. Carballeira, D. Berjón, and N. García, “Congestion control for cloud gaming over UDP based on round-trip video latency,” *IEEE Access*, vol. 7, pp. 78 882–78 897, 2019.
- [5] F. Armendariz and J. Joskowicz, “ABRAGame: Automatic bit rate adjustment for cloud gaming,” *Multimedia Tools and Applications*, 2025.
- [6] G. Carlucci, L. De Cicco, S. Holmer, and S. Mascolo, “Analysis and design of the Google congestion control for web real-time communication (WebRTC),” in *Proceedings of the 7th International Conference on Multimedia Systems (MMSys’16)*. ACM, 2016, pp. 1–12.
- [7] S. Ha, I. Rhee, and L. Xu, “CUBIC: A new TCP-friendly high-speed TCP variant,” *ACM SIGOPS Operating Systems Review*, vol. 42, no. 5, pp. 64–74, 2008.
- [8] H.-J. Hong, C.-F. Hsu, T.-H. Tsai, C.-Y. Huang, K.-T. Chen, and C.-H. Hsu, “Enabling adaptive cloud gaming in an open-source cloud gaming platform,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 25, no. 12, pp. 2078–2091, 2015.
- [9] L. Salzman, “ENet: A reliable UDP networking library,” <http://enet.bespin.org/>, acessado em 2026.
- [10] Google, “GoogleTest: Google’s C++ testing and mocking framework,” <https://github.com/google/googletest>, acessado em 2026.
- [11] Linux Foundation, “iproute2: utilities for controlling and monitoring various aspects of networking in the Linux kernel,” <https://wiki.linuxfoundation.org/networking/iproute2>, acessado em 2026.