



Recomendação de rotas consciente de QoE com Atenção e Comunicação

Rosana de Oliveira Santos¹ , Carlos Eduardo da Silva Santos² ,
Ciro José Almeida Macedo³ , Antonio Oliveira-Jr^{1,4} 

¹Instituto de Informática – Universidade Federal de Goiás, Goiânia-GO, Brasil

²Instituto Federal de Educação, Ciência e Tecnologia do Tocantins, Palmas-TO, Brasil

³Instituto Federal de Goiás, Cidade de Goiás-GO, Brasil

⁴Fraunhofer Portugal AICOS, Porto, Portugal

rosanasantos@discente.ufg.br, carlosedu@ifto.edu.br,

ciro.macedo@ifg.edu.br, antoniojr@ufg.br

Abstract. *Location-based Games with Augmented Reality (LBGAR) impose dynamic communication requirements, making Quality of Experience (QoE) sensitive to network conditions along the player's path. This work proposes an urban itinerary (routes) recommendation model that integrates game scoring and the Attention and Communication-aware QoE (QoE-CAC) metric, considering 5G resources and user attention. To solve this problem, an ACO-based heuristic algorithm is proposed. Experiments with real network data demonstrate that the balanced approach (RotaCAC-0.5) offers a better trade-off between scoring and perceived QoE compared to non-QoE-aware strategies.*

Resumo. *Jogos Baseados em Localização com Realidade Aumentada (JBLRA) impõem requisitos dinâmicos de comunicação, tornando a Qualidade de Experiência (QoE) sensível às condições da rede ao longo da trajetória do jogador. Este trabalho propõe um modelo de recomendação de itinerários urbanos (rotas) que integra a pontuação do jogo e a métrica QoE Consciente de Atenção e Comunicação (QoE-CAC), considerando recursos 5G e a atenção do usuário, resolvido por um algoritmo heurístico baseado em Ant Colony Optimization (ACO). Experimentos com dados reais de rede demonstram que a abordagem equilibrada (RotaCAC-0.5) oferece um melhor compromisso entre a pontuação e a QoE percebida frente a estratégias não conscientes de QoE.*

1. Introdução

Nos últimos anos, Jogos Baseados em Localização com Realidade Aumentada (JBLRA) têm atraído milhões de usuários, transformando espaços urbanos em campos de interação digital. Aplicações pioneiras como *Ingress* [Hodson 2012] e *Pokémon Go* [Shea et al. 2017, Laato et al. 2024] consolidaram o uso de geolocalização e sobreposição de elementos virtuais para criar experiências imersivas em tempo real. Neste cenário, a integração da tecnologia de Realidade Aumentada (RA) com a infraestrutura de comunicação da Quinta Geração de Redes Móveis Celulares (5G) promete elevar o realismo e a interatividade a novos patamares de alta velocidade e ultrabaixa latência

[Ansari et al. 2022]. Contudo, a imersão em JBLRA é sensível a flutuações no desempenho das redes móveis, onde requisitos dinâmicos de comunicação tornam a QoE do jogador dependente das condições de rede ao longo de sua trajetória [Xu 2022, Xu et al. 2026]. Dessa forma, a satisfação do usuário não advém apenas das recompensas do jogo, mas da fluidez com que os elementos virtuais são renderizados e manipulados durante a movimentação do jogador.

Embora a busca pelo melhor itinerário seja um tema clássico de otimização [Tregel et al. 2018], os modelos tradicionais de recomendação de rotas priorizam a distância e o tempo, desconsiderando a qualidade dos recursos tecnológicos disponíveis em cada *Ponto de Interesse* (POI). Em JBLRA, o *streaming* de objetos RA exige recursos de rede adequados; caso contrário, a QoE é comprometida. Surge, assim, a necessidade de investigar como os recursos da infraestrutura de comunicação influenciam a seleção de rotas, podendo atuar como restritores ou facilitadores na escolha da próxima parada. A Figura 1 ilustra a ideia geral deste trabalho. Propomos uma abor-

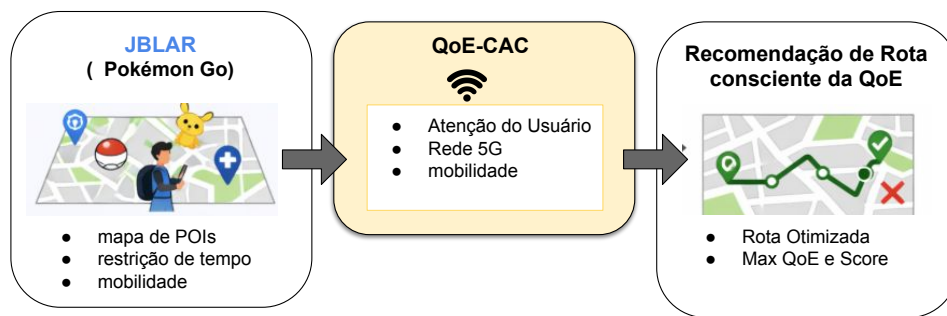


Figura 1. Visão geral do sistema de recomendação de rotas baseado em QoE para JBLRA

dagem de recomendação de rotas que busca melhorar a QoE, além do desempenho na pontuação geral do jogo. Para isso, utiliza-se a métrica QoE-CAC que avalia a satisfação do usuário com base nos KPIs de rede e no fator de atenção do usuário à imagem renderizada [de Oliveira Santos et al. 2025]. O problema de seleção de trajeto é formulado como uma variante do Problema de Orientação (do inglês, *Orienteering Problem (OP)*), visando responder as seguintes questões de pesquisa:

- Como a QoE-CAC percebida pode orientar dinamicamente a recomendação de rotas em cenários de alta mobilidade?
- Como melhorar a satisfação do usuário integrando a pontuação do jogo e a QoE-CAC sob restrições de tempo?

As principais contribuições desta pesquisa são: (i) um método de recomendação de rotas baseado no OP que integra QoE consciente de recursos 5G e fatores de atenção (QoE-CAC); (ii) a aplicação da métrica QoE-CAC em um cenário prático de JBLRA; (iii) a realização de experimentos utilizando o *dataset* RACA [Raca et al. 2020] para analisar o impacto da volatilidade da rede na satisfação final do jogador; e (iv) a disponibilização

pública da implementação do modelo de otimização e dos dados experimentais em repositório GitHub ¹.

O restante deste artigo está organizado da seguinte forma: a Seção 2 discute os trabalhos relacionados; a Seção 3 detalha a fundamentação e a formalização do problema; a Seção 4 descreve os experimentos e resultados; e a Seção 5 encerra com as considerações finais e os próximos passos do trabalho.

2. Trabalhos Relacionados

A recomendação de trajetórias em JBLRA pode ser modelada a partir do OP, no qual se busca selecionar um subconjunto de POIs a serem visitados dentro de um orçamento limitado de tempo ou distância, maximizando uma função de recompensa [Lim et al. 2016] [Shen et al. 2025, Vansteenwegen et al. 2019]. Um levantamento recente sobre OP demonstra a ampla evolução do modelo, incluindo extensões dinâmicas, dependentes do tempo e orientadas à informação, tornando-o adequado para aplicações sensíveis ao contexto, como jogos móveis [Shen et al. 2025].

Especificamente no contexto de JBLRA, alguns trabalhos investigam a otimização de rotas em jogos. [Tregel et al. 2018] propõe uma abordagem inicial para maximizar as recompensas dentro de um orçamento de tempo. Posteriormente, os mesmos autores estendem a ideia do trabalho, formalizando o problema como uma generalização do *Orienteering Problem with Time Windows* (OPTW) e utilizando meta-heurísticas como *Simulated Annealing* e algoritmos evolucionários para soluções em tempo real [Tregel et al. 2021]. Contudo, essas abordagens não consideram explicitamente aspectos dinâmicos da qualidade da comunicação, nem métricas avançadas de QoE, tratando a rede como um elemento implícito.

Paralelamente, avanços significativos têm sido observados na área de jogos imersivos em nuvem. O trabalho de [Lee et al. 2025] propõe modelos de QoE para jogos de realidade virtual em nuvem, utilizando estudos subjetivos com usuários e questionários de *Mean Opinion Score* (MOS) para ajustar dinamicamente parâmetros de *streaming* (como resolução, taxa de quadros e codificação). Os autores demonstram que a adaptação baseada em QoE pode melhorar significativamente a qualidade geral percebida em redes congestionadas. Embora essa pesquisa seja relevante, ela se restringe a cenários de mobilidade limitada dentro de ambientes controlados. Além disso, a avaliação de QoE por meio de questionários *Mean Opinion Score* (MOS) apresenta limitações práticas em contextos dinâmicos, uma vez que requer coleta de feedback subjetivo pós-experiência, dificultando a otimização em tempo real durante a mobilidade urbana.

De forma complementar, [Baena et al. 2024] analisam o papel das redes 5G em *cloud gaming* (CG), identificando fatores críticos na experiência do usuário de CG e comparando o desempenho com tecnologias legadas (4G/LTE e Wi-Fi) em cenários reais. O estudo evidencia o potencial das redes 5G (inclusive no *cell edge*) para suportar aplicações interativas exigentes ao utilizar a arquitetura MEC (*Mobile Edge Computing*) [Baena et al. 2024]. Contudo, essa pesquisa concentra-se na avaliação de desempenho da infraestrutura de rede, sem propor mecanismos de otimização orientados ao usuário ou considerar aspectos cognitivos ou de atenção à imagem.

¹<https://github.com/LABORA-INF-UFG/Rota-CAC-recommendation>

[Almeida et al. 2025] investigam mecanismos de alocação de recursos conscientes de atenção para aplicações de *VR Cloud Gaming* (VR-CG). Os autores propõem o VR-GX, uma formulação matemática que incorpora os níveis de atenção do usuário para otimizar a QoE, ajustando dinamicamente a resolução dos objetos virtuais com base no *Field of View* (FoV) e nas especificações 3GPP, focando em uma infraestrutura estática de estações base. Como os próprios autores indicam, a transposição dessa lógica para cenários de mobilidade urbana e planejamento de trajetórias permanece um desafio em aberto [Almeida et al. 2025].

Raca *et al.* apresentam um dataset público de 5G que reúne métricas de rede em cenários estáticos e de mobilidade, incluindo aplicações categorizadas como *video streaming* (*Netflix* e *Amazon Prime*) e arquivos de *download* [Raca et al. 2020]. O trabalho fornece indicadores de desempenho como latência, vazão, qualidade de canal e contexto de mobilidade, permitindo análises mais realistas sobre a variabilidade da rede em ambientes urbanos. Essa contribuição é relevante para pesquisas em QoE, pois disponibiliza dados empíricos que podem ser utilizados na modelagem de sistemas sensíveis às condições de rede, como jogos JBLRA.

A literatura explora também a integração entre a otimização de rotas turísticas e os recursos de rede. Em [Esper et al. 2025], os autores propõem a recomendação de itinerários personalizados em cenários de turismo inteligente, considerando simultaneamente o planejamento de rotas e a alocação de recursos de computação de borda (MEC). As métricas adotadas no trabalho refletem predominantemente aspectos sistêmicos de eficiência e alocação de recursos de rede ao longo do percurso. Diferentemente dessas abordagens, o presente trabalho adota uma métrica de QoE consciente de comunicação e atenção, voltada à experiência percebida pelo usuário em aplicações imersivas.

Além dos trabalhos mencionados, destacamos nossa contribuição anterior intitulada *QoE-CAC: métrica de QoE em Sistemas de Comunicação Imersiva Consciente de Atenção e Comunicação* [de Oliveira Santos et al. 2025]. Nesse artigo, propusemos uma métrica inovadora de Qualidade de Experiência (QoE-CAC), capaz de integrar fatores cognitivos de atenção do usuário e parâmetros de comunicação, como *downlink*, *uplink* *Bit Error Probability* (BEP) e prejuízo da latência para avaliar a experiência em sistemas imersivos. A validação experimental demonstrou que a métrica captura de forma mais precisa a percepção do usuário em cenários de comunicação sensível ao contexto. O presente trabalho expande essa linha de pesquisa ao aplicar a métrica QoE-CAC no problema de recomendação de rotas em JBLRA, incorporando restrições de mobilidade urbana e recursos dinâmicos de Rede 5G. Dessa forma, estabelecemos um elo direto entre a formulação teórica da métrica e sua aplicação prática em ambientes de alta interatividade, avançando o estado da arte na integração entre planejamento de rotas, comunicação móvel e fatores cognitivos de atenção.

Por fim, esta pesquisa diferencia-se da literatura existente ao propor um modelo de recomendação de rotas para JBLRA, fundamentado na métrica QoE-CAC. Diferentemente das abordagens correlatas, a proposta integra explicitamente o orçamento de tempo do jogador, a relevância dos POIs, as condições dinâmicas da rede 5G e o fator de atenção do usuário. O modelo formula um problema de otimização multiobjetivo que maximiza simultaneamente a QoE percebida e a pontuação do jogador, estabelecendo uma convergência entre planejamento de rotas e a métrica de experiência.

A Tabela 1 sintetiza a comparação entre os principais trabalhos correlatos e a abordagem proposta, destacando as dimensões técnicas abordadas por cada um. A pesquisa preenche uma lacuna importante ao consolidar a otimização de trajetórias (OP) com métricas de QoE sensíveis à atenção e ao dinamismo das redes 5G em cenários de mobilidade urbana.

Tabela 1. Comparando os trabalhos relacionados

| Referência | OP | JBLRA | Mobilidade | Métrica de QoE |
|-----------------------|----|-------|-------------------|---|
| [Tregel et al. 2021] | ✓ | ✓ | Dinâmica | × |
| [Lee et al. 2025] | × | × | Estática | Questionário MOS |
| [Baena et al. 2024] | × | × | Estática | Resolução e latência |
| [Almeida et al. 2025] | × | × | Estática | Resolução, taxa de erro e fator de atenção |
| [Esper et al. 2025] | ✓ | × | Dinâmica | UE associada a alocação de recursos |
| [Raca et al. 2020] | × | × | Dinâmica/Estática | sem métrica própria |
| Este trabalho | ✓ | ✓ | Dinâmica | latência, <i>downlink</i> , <i>uplink</i> BEP e atenção |

3. Fundamentos e Definição do problema

Nesta seção, apresentamos os elementos fundamentais e a formalização do problema de recomendação de rotas para JBLRA. O cenário de estudo baseia-se em uma aplicação de realidade aumentada (como o *Pokémon Go*) operada sobre a malha urbana de uma cidade. O ambiente contém diversos POIs, onde o usuário interage com elementos virtuais 3D renderizados em tempo real via rede móvel. O problema consiste em, dado um ponto de origem e um orçamento de tempo T_{budget} fornecido pelo usuário, recomendar uma rota que maximize simultaneamente a pontuação do jogo e a QoE percebida.

A Figura 2 ilustra a sistemática do problema. O usuário informa sua posição inicial e o orçamento de tempo disponível. O sistema recomenda uma rota que maximize simultaneamente a pontuação do jogo (valor dos Pokémons capturados) e a QoE-CAC nos POIs visitados. As barras verticais amarelas indicam o nível de QoE-CAC (maior ou menor) em cada ponto.

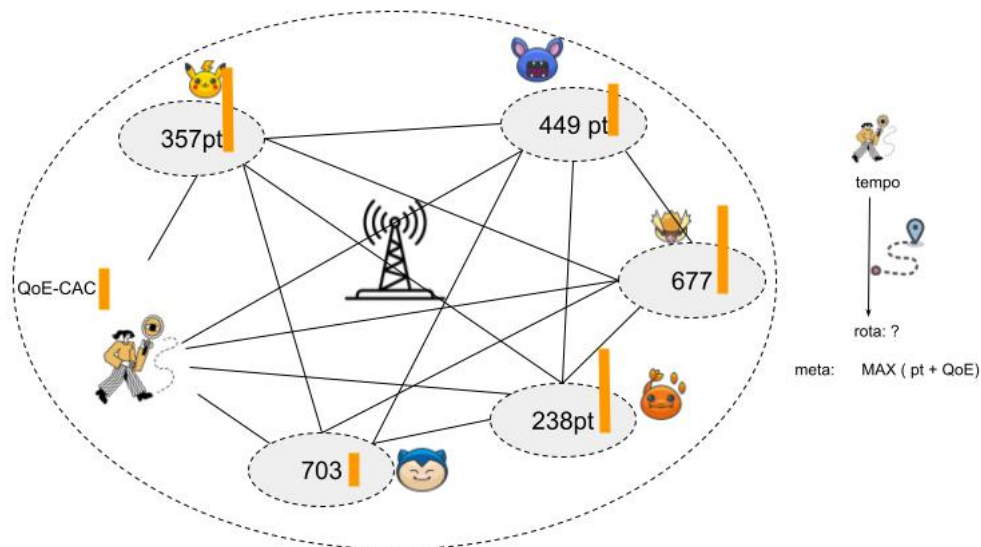


Figura 2. Modelo Sistemático do Problema das Rotas no Jogo Pokémon Go

Definição 1: Pontos de Interesse - POIs

Para uma cidade específica com n POIs, consideramos um grafo não orientado $G = (\mathcal{V}, \mathcal{A})$, onde $\mathcal{V} = \{v_1, \dots, v_n\}$ é o conjunto de vértices que representam os POIs; e $\mathcal{A} = \{(v_i, v_j) \mid v_i, v_j \in \mathcal{V}\}$ é o conjunto de arestas que conectam os vértices. Para cada aresta $(v_i, v_j) \in \mathcal{A}$, associa-se um tempo de deslocamento $\mathcal{T}_u^{Desloc}(v_i, v_j)$ (em segundos) entre os vértices v_i e v_j . Cada POI $v_i \in \mathcal{V}$ é caracterizado pelos seguintes atributos:

- (i) o Pokémon presente e a ser capturado pelo jogador no POI (v_i), denotado por $poke(v_i) \in \mathbb{Z}$;
- (ii) o tempo em segundos que o usuário jogador u leva para visitar o POI (v_i) e capturar o Pokémon, denotado por $\mathcal{T}_u^{Visita}(v_i)$;
- (iii) as coordenadas geográficas do POI (v_i), expressas em latitude e longitude e denotadas por $Lat(v_i)$ e $Long(v_i)$;
- (iv) e a QoE-CAC sob o POI (v_i), denotada por $\mathcal{Q}^{CAC}(v_i)$.

Definição 2: as unidades de Infraestrutura de borda UInPb

A cidade possui unidades de Infraestrutura de Borda, aqui denominadas de UInPb, espalhadas por pontos estratégicos e que são responsáveis por prover recursos tecnológicos do tipo computação e comunicação de rede 5G aos provedores de serviço, como o jogo do Pokémon Go. A distribuição das UInPb na cidade ocorre de forma que cada POI (v_i) pode utilizar recursos da UInPb mais próxima.

Definição 3: a QoE-CAC

Para quantificar a QoE em cada POI, utilizamos a métrica \mathcal{Q}^{CAC} , adaptada de [Du et al. 2023, de Oliveira Santos et al. 2025] definida pela Equação 1:

$$\mathcal{Q}^{CAC}(v_i) = (1 - \tau(I_{v_i}^{Lat})) \times \tau(R_{v_i}^D) \times (1 - \tau(E_{v_i})) \times \sum_{n=1}^{N_{O,v_i}} K_{n,v_i} \ln \left(\frac{P_{n,v_i}^{(R)}}{P^{(R)}} \right) \quad (1)$$

onde $I_{v_i}^{Lat}$ é o valor associado ao prejuízo da latência, $R_{v_i}^D$ é a taxa de *downlink*, E_{v_i} é a taxa de *uplink* BEP, K_{n,v_i} é o valor da atenção do usuário no POI v_i ao objeto n , $P^{(R)}$ é a capacidade de renderização mínima disponível, $P_{n,v_i}^{(R)}$ é a capacidade de renderização para visualizar o objeto n contido na mídia imersiva, N_{O,v_i} denota o número de objetos virtuais que o usuário u visualiza durante a transmissão do serviço no POI v_i [Du et al. 2023].

Para ajustar as grandezas, os valores foram normalizados para eliminar o efeito de magnitude, conforme a Equação 2, em que t_{min} e t_{max} são os limites mínimo e máximo, respectivamente, fornecidos para cada uma das métricas da Equação 1.

$$\tau(t) = \frac{t - t_{min}}{t_{max} - t_{min}} \quad (2)$$

O prejuízo da latência $I_{v_i}^{Lat}$ é calculado conforme a Equação 3, em que o prejuízo $I_{v_i}^{Lat} \in [0, 1]$, com $I_{v_i}^{Lat} = 0$ significando maior qualidade (zero prejuízo) e $I_{v_i}^{Lat} = 1$ significando pior qualidade, isto é, prejuízo total [Krogfoss et al. 2020].

$$I_{v_i}^{Lat} = \frac{1 + e^{-b}}{1 + e^{b\frac{t-a}{a}}}, \text{ onde } t \text{ é a latência total} \quad (3)$$

Definição 4: O elemento Pokémon

Seja $\mathcal{P} = \{p_1, \dots, p_x\}$ o conjunto de Pokémons. Cada p_i é uma tupla $(v(p_i), nome(p_i))$, onde $v(p_i) \in \mathbb{Z}^+$ representa o valor (pontuação) do Pokémon.

Definição 5: O Custo

O custo total $\mathcal{C}_{i,j}$ associado ao arco (v_i, v_j) é definido pela soma do tempo de visita no POI de origem v_i com o tempo de deslocamento até o destino v_j :

$$\mathcal{C}_{i,j} = \mathcal{T}_u^{Visita}(v_i) + \mathcal{T}_u^{Desloc}(v_i, v_j)$$

Definição 6: A penalidade do POI

Seja \mathcal{P}_i a penalidade associada ao tempo de visitação ao POI v_i , incrementando um tempo adicional (atraso) λ quando ocorrer uma visita em um POI v_i com \mathcal{Q}^{CAC} abaixo de um valor mínimo θ .

$$\mathcal{P}_i = \begin{cases} (1 - \mathcal{Q}^{CAC}(v_i)) \cdot \lambda, & \text{se } \mathcal{Q}^{CAC}(v_i) < \theta \\ 0, & \text{se } \mathcal{Q}^{CAC}(v_i) \geq \theta \end{cases} \quad (4)$$

, onde θ representa o valor crítico de aceitação para a \mathcal{Q}^{CAC} no POI v_i e λ é um valor de atraso em segundos .

3.1. Formulação do Problema de Recomendação de Rotas em JBLRA

O problema de recomendação de rotas em JBLRA é modelado como uma variante do Problema de Orientação (OP). Dado o grafo $G = (\mathcal{V}, \mathcal{A})$ representando o conjunto de POIs a serem visitados, o orçamento de tempo T_{budget} de um jogador e um POI inicial v_i , nossa meta é recomendar uma rota $R = (v_i, \dots, v_m)$, onde $m \leq N$, que maximize o *score* dado pela função da Equação 5, respeitando o limite de tempo T_{budget} . Formalmente, temos:

$$\text{Maximizar } Z = \sum_{i=1}^{N-1} \sum_{j=i+1}^N x_{ij} ((1 - \eta) \cdot \tau(v(pokee(v_i))) + \eta \cdot \tau(\mathcal{Q}^{CAC}(v_i))) \quad (5)$$

sujeito a:

$$\sum_{i=1}^{N-1} \sum_{j=i+1}^N x_{ij} \cdot (\mathcal{C}_{i,j} + \mathcal{P}_i) \leq T_{budget} \quad (6)$$

$$\sum_{j=2}^N x_{1j} = 1 \quad (7)$$

$$\sum_{i=1}^{N-1} x_{ik} = \sum_{j=2}^N x_{kj} = y_k, \quad \forall k \in \{2, \dots, N-1\} \quad (8)$$

$$u_i - u_j + 1 \leq (N-1)(1 - x_{ij}), \quad \forall i, j \in \{2, \dots, N\} \quad (9)$$

A Equação 5 resolve o problema multiobjetivo, maximizando a satisfação do jogador ao combinar os valores de pontuação ($v(\text{poke}(v_i))$) e a qualidade dos recursos tecnológicos ($Q^{\text{CAC}}(v_i)$) associados ao POI v_i . Ambos os valores foram normalizados utilizando a Equação 2. Definimos a variável de decisão binária x_{ij} , que assume o valor 1 se o jogador percorre o trajeto entre os POIs v_i e v_j , e 0 caso contrário. O parâmetro $\eta \in [0, 1]$ corresponde ao peso associado ao interesse no desempenho do jogo e à experiência do usuário. O ajuste dos pesos pode ser utilizado para avaliar um cenário com foco total na Q^{CAC} (caso em que $\eta = 1$), foco na pontuação do jogo (caso em que $\eta = 0$) ou um equilíbrio entre eles ($\eta = 0.5$). Adotamos, na Equação 5, a abordagem *a priori* de função linear agregada, reconhecida na literatura para resolução de problemas multiobjetivos [Coello et al. 2007], na qual os objetivos $f_1(x) = \tau(v(\text{poke}(v_i)))$ e $f_2(x) = \tau(Q^{\text{CAC}}(v_i))$ são combinados com pesos $w_1 = (1 - \eta)$ e $w_2 = \eta$, satisfazendo $\sum_{i=1}^2 w_i = 1$. A Equação 5 é sujeita às restrições 6 a 9. A Equação 6 garante que a soma do tempo de deslocamento entre os pontos e o tempo de interação em cada POI, incluindo o tempo de atraso por penalidade, não ultrapasse o orçamento de tempo (T_{budget}) do jogador. A Equação 7 assegura que a rota recomendada inicie obrigatoriamente no ponto de origem (v_i). A Equação 8 garante que, para cada POI intermediário k , se o jogador entrar no ponto, ele deve necessariamente sair dele, mantendo a integridade do caminho e garantindo que cada local seja visitado no máximo uma vez. A Equação 9 evita a criação de sub-rotas fechadas que não estejam conectadas à origem, garantindo que a solução seja um caminho contínuo único.

4. Experimentos e Resultados

O problema de Recomendação de Rotas JBLRA é claramente um tipo de Problema de Orientação multiobjetivo [Chao et al. 1996, Vansteenwegen et al. 2019], pertencente à classe de problemas NP-Hard. Sendo assim, para solucionar o problema, buscamos soluções aproximadas que envolvem heurísticas para a recomendação das rotas. O ACO foi escolhido por seu desempenho consolidado em variantes do OP [Dorigo et al. 2006].

No Algoritmo 1, o pseudo-código detalha os passos do algoritmo RotaCAC proposto: uma abordagem baseada na heurística ACO [Dorigo et al. 2006] para otimização das rotas, considerando a métrica QoE-CAC [de Oliveira Santos et al. 2025]. Cada variante do RotaCAC, internamente, busca pelas rotas, seguindo a heurística ACO clássica para resolver o problema multiobjetivo da Equação 5, além de acrescentar um fator de penalidade P_i (conforme definido na Equação 4) ao aplicar um atraso λ ao percurso, sempre que um POI v_i , com Q^{CAC} inferior a um *threshold* θ , for visitado.

Foram ajustados os valores de $\alpha=1$, $\beta=3$, $\rho=0.1$, seguindo padrões consolidados para ACO em problemas de roteamento [Dorigo et al. 2006]. Além disso, utilizamos $\lambda = 60s$ e $\theta = 0.2$, calibrados a partir dos *traces* de mobilidade urbana do *dataset* RACA [Raca et al. 2020], que registram interrupções médias de sinal nessa faixa de duração. O fator de penalidade é um tempo acrescido ao tempo de visitaç o em um POI, refletindo a realidade de atraso em cen rios de jogos, onde os POIs nos quais os recursos de Rede est o abaixo da QoE fazem com que o jogador passe v rios segundos tentando melhorar a qualidade do sinal a fim de concluir a renderiza o da imagem 3D. O custo computacional do RotaCAC   $\mathcal{O}(K \cdot n^2)$; com $K=20$ formigas, $n=25$ POIs e 50 itera es ACO.

Conforme a varia o do peso $\eta \in [0, 1]$ na Equa o 5, o algoritmo RotaCAC possui as seguintes variantes:

- **RotaCAC-1:** implementa o de ACO onde $\eta = 1$, priorizando a maximiza o da Q^{CAC} acumulada. Esta abordagem mant m foco na QoE;
- **RotaCAC-0:** implementa o de ACO com $\eta = 0$, que maximiza a pontua o do jogo;
- **RotaCAC-0.5:** implementa o de ACO com $\eta = 0.5$, buscando o equil brio entre a pontua o do jogo e a Q^{CAC} associada. Esta abordagem utiliza foco balanceado.

Algorithm 1 Algoritmo RotaCAC (Baseado em ACO)

Entrada: $G(\mathcal{V}, \mathcal{A})$, v_{start} , T_{budget} , Q^{CAC} , θ , λ , η , α , β

Sa da: Rota Otimizada R

- 1: Inicializar matriz de ferom nios τ_{ij} e visibilidade γ_{ij} baseada na Eq. 5
 - 2: **Enquanto** crit rio de parada n o atingido **fa a**
 - 3: **Para** cada formiga k **fa a**
 - 4: Construir rota R_k a partir de v_{start}
 - 5: Escolher pr ximo POI j com probabilidade $P_{ij} \propto (\tau_{ij})^\alpha \cdot (\gamma_{ij})^\beta$
 - 6: Calcular custo $C_{ij} = \mathcal{T}^{Visita} + \mathcal{T}^{Desloc}$
 - 7: **Se** $Q^{CAC}(v_i) < \theta$ **ent o**
 - 8: $C_{ij} \leftarrow C_{ij} + (1 - Q^{CAC}(v_i)) \cdot \lambda$ \triangleright Aplica o da Penalidade Eq. 4
 - 9: **end Se**
 - 10: Atualizar tempo acumulado e verificar T_{budget}
 - 11: **end Para**
 - 12: Atualizar ferom nios τ_{ij} (Global e Local)
 - 13: **end Enquanto**
 - 14: **Retornar** Melhor Rota R
-

4.1. DataSets

O cen rio experimental foi constru do a partir da integra o de dois conjuntos de dados distintos: um para o mapeamento geogr fico dos Pontos de Interesse (POIs) e outro para as m tricas de desempenho da Rede 5G. Al m disto, a lista de Pok mons utilizada   oriunda do dataset p blico dispon vel em ² que possui 1000 (mil) Pok mons.

Mapeamento Geogr fico e Custos de Deslocamento O mapeamento dos POIs foi realizado por meio de consultas   *Overpass API do OpenStreetMap*. A  rea geogr fica

²<https://pokemondb.net/go/pokedex>

de interesse foi delimitada por coordenadas específicas de latitude e longitude da cidade de Goiânia. Foram aplicados filtros para selecionar categorias de locais relevantes para jogos urbanos, tais como supermercados, parques, instituições de ensino e pontos turísticos [Lima 2023]. A conectividade entre os POIs foi modelada através do cálculo de distâncias geodésicas, utilizando o modelo WGS84 (*World Geodetic System*). O custo $\mathcal{C}_{i,j}$ (tempo de deslocamento) foi calculado assumindo uma velocidade média de caminhada de 5 km/h (aproximadamente 1,39 m/s), um valor padrão para deslocamento de pedestres em ambientes urbanos. O resultado deste processo gerou arquivos CSV que contêm a lista de POIs e a matriz de custos de deslocamento, servindo como base para os experimentos de otimização de rotas.

Dataset RACA: Os experimentos utilizam o *dataset* de [Raca et al. 2020]³, que fornece *traces* reais de mobilidade urbana com métricas de *downlink*, SNR e latência. A partir desses *traces*, a QoE-CAC foi calculada por *trace*, com BEP derivado do SNR via modelo QPSK; quando a latência era indisponível, adotou-se a média por cenário reportada em [Raca et al. 2020] (estático: 75 ms; mobilidade: 90 ms). Os valores resultantes foram atribuídos aos POIs do mapa de Goiânia, compondo o cenário experimental com até 214 POIs.

Parâmetros de QoE-CAC e RA: O fator de atenção foi modelado conforme o *dataset* UOAL⁴ [Du et al. 2023], que reflete a atenção do usuário a objetos em cenários de jogos, complementando os KPIs de rede extraídos do RACA para compor a métrica QoE-CAC.

4.2. Avaliação e Resultados

Os experimentos foram conduzidos utilizando a plataforma MATLAB R2022B, e a implementação foi executada em um sistema Intel(R) Xeon(R) E-2278G (3.40GHz, 32GB de RAM). Cada cenário de avaliação foi submetido a 30 execuções independentes, sendo os resultados analisados sob um intervalo de confiança de 95%. Implementamos, como *baseline*, o algoritmo *Greedy*, que busca o Ponto de Interesse (POI) mais próximo com a maior pontuação imediata. Esta abordagem é simples e comum em sistemas de recomendação não conscientes de rede.

A **eficiência** dos algoritmos propostos (variantes RotaCAC) e do *baseline* (*Greedy*) foi avaliada em termos de QoE e pontuação do jogo, considerando o **orçamento total de tempo** do percurso. As métricas de eficiência por tempo foram definidas como:

- **Eficiência de QoE por Tempo** (\mathcal{E}_{QCAC}): Razão entre Q^{CAC} acumulada e o tempo total da rota, medindo a qualidade da experiência por unidade de tempo. m é o número de POIs visitados na rota.

$$\mathcal{E}_{QCAC} = \frac{\sum_{i=1}^m Q^{CAC}(v_i)}{T_{total}} \quad (10)$$

- **Eficiência da Pontuação por Tempo** (\mathcal{E}_{Pontos}): Razão entre a pontuação acumulada ($v(poke(v_i))$) e o tempo total da rota, medindo os pontos por unidade de

³<https://github.com/uccmis/5Gdataset.git>

⁴<https://github.com/HongyangDu/User-Object-Attention-Level/blob/master/README.md>

tempo. m é o número de POIs visitados na rota.

$$\mathcal{E}_{Pontos} = \frac{\sum_{i=1}^m v(poke(v_i))}{T_{total}} \quad (11)$$

A Figura 3 evidencia a superioridade da eficiência das variantes RotaCAC comparadas à *baseline: Greedy* apresenta a pior solução por ignorar as condições da rede, o que prejudica sua Q^{CAC} . A variante RotaCAC-0 assume comportamento semelhante (baixa Q^{CAC}), apesar de alcançar ótima eficiência de pontos, que é seu foco. Por outro lado, o **RotaCAC-1** (foco na Q^{CAC}) se mostrou superior na eficiência da QoE, como esperado, mas obteve a menor pontuação no jogo. O principal resultado nessa avaliação reside na variante **RotaCAC-0.5**, que oferece o melhor **equilíbrio** entre pontuação e Q^{CAC} , sendo a estratégia indicada para um jogador que busca tanto o sucesso no jogo quanto uma experiência imersiva agradável. A Figura 4 ilustra os resultados comparativos dos totais




Figura 3. Eficiência da QoE e Eficiência de Pontos

de pontuação, de Q^{CAC} e de tamanho da rota (número de POIs visitados), distinguindo o desempenho bruto dos algoritmos. De forma geral, a análise indica que os algoritmos RotaCAC são mais eficazes na otimização das métricas principais (pontuação e Q^{CAC}) do que a abordagem Greedy simples, que tende a encontrar rotas mais curtas e menos eficientes em termos de valor agregado. Novamente, percebe-se o equilíbrio que o RotaCAC-0.5 estabelece nessa avaliação.

Finalmente, analisamos o impacto da inclusão da penalidade (P_i) por baixa Q^{CAC} , que é crucial para que as variantes RotaCAC evitem zonas de baixos recursos 5G, um fator dinâmico que o método *Greedy* ignora completamente. Na Figura 5, observamos que a penalidade de tempo (Cenário 2 versus Cenário 1) impõe padrões negativos na maioria dos algoritmos avaliados; a performance de todos os métodos, inclusive das variantes do ACO, é impactada negativamente, mas ainda mantendo vantagem sobre o Greedy, que é o mais afetado pela penalidade de tempo.




Figura 4. Resultados comparativos médios dos algoritmos (Greedy e RotaCAC) para Pontuação Total, QoE Total e Tamanho da Rota

Há uma correlação clara entre o *budget* de tempo e o tamanho da rota. Com a penalidade do tempo para os POIs com Q^{CAC} abaixo do limiar permitido, o *budget* de tempo é reduzido, forçando os algoritmos ACO-variantes a encontrarem rotas com melhor Q^{CAC} . Se isso não ocorrer, a tendência natural é recomendar uma rota mais curta, como podemos observar no caso do algoritmo *Greedy*: ele gera as rotas mais curtas em ambos os cenários. A variante RotaCAC-0.5 apresenta um excelente compromisso, mantendo um tamanho de rota elevado e equilibrando bem as métricas de pontuação e Q^{CAC} .




Figura 5. Resultados comparativos Tamanho da Rota, em cenários Sem Penalidade (Cenário 1) e Com Penalidade (Cenário 2).

5. Conclusão

Este trabalho investigou o problema de recomendação de rotas em JBLRA sob a perspectiva da QoE, propondo uma formulação que integra explicitamente fatores de comunicação, mobilidade e atenção do usuário por meio da métrica QoE-CAC. Diferentemente de abordagens tradicionais centradas apenas na distância ou na pontuação do jogo, o modelo proposto incorpora condições dinâmicas de rede 5G como critério decisório no planejamento de trajetórias.

Os resultados experimentais, conduzidos com dados reais de rede e cenários urbanos, demonstraram que estratégias de recomendação que ignoram a QoE tendem a produzir rotas menos eficientes em termos de experiência percebida, enquanto abordagens

que priorizam exclusivamente a QoE comprometem o desempenho no jogo. Nesse contexto, a variante RotaCAC-0.5 destacou-se por oferecer um compromisso equilibrado entre pontuação e qualidade de experiência, resultando em rotas mais estáveis e satisfatórias sob condições variáveis de latência, *downlink* e *uplink* BEP. Além disso, a introdução de uma penalidade temporal associada a POIs com baixa QoE mostrou-se eficaz para capturar efeitos práticos observados em cenários reais, como atrasos na renderização de objetos. Esses resultados evidenciam a viabilidade da QoE-CAC como critério de otimização em problemas de recomendação de rotas sensíveis à comunicação.

Cabe ressaltar que o objetivo central deste trabalho não é encontrar a solução ótima para o problema de rotas, mas avaliar a capacidade da métrica QoE-CAC de guiar o ACO na recomendação de rotas em JBLRA. Os resultados indicam que a QoE-CAC direciona a heurística para regiões de maior qualidade de experiência, validando sua aplicabilidade como critério de otimização em problemas de comunicação sensíveis ao contexto.

Como trabalhos futuros, pretende-se ampliar a avaliação comparativa com variantes de meta-heurísticas adicionais, como *Simulated Annealing* e algoritmos evolucionários, e estender o modelo para cenários multi-usuário com disputa concorrente pelos recursos de rede.

Referências

- Almeida, G., Esper, J. P., Nahum, C., Klautau, A., and Cardoso, K. V. (2025). Toward Scalable VR-Cloud Gaming: An Attention-aware Adaptive Resource Allocation Framework for 6G Networks. *arXiv preprint arXiv:2512.11667*.
- Ansari, S. Z. A., Shukla, V. K., Saxena, K., and Filomeno, B. (2022). Implementing virtual reality in entertainment industry. In *Cyber Intelligence and Information Retrieval: Proceedings of CIIR 2021*, pages 561–570. Springer.
- Baena, C., Fortes, S., Peñaherrera-Pulla, O. S., Baena, E., and Barco, R. (2024). Gaming in the Cloud: 5G as the Pillar for Future Gaming Approaches. *IEEE Communications Magazine*, 62(11):76–82.
- Chao, I.-M., Golden, B. L., and Wasil, E. A. (1996). The team orienteering problem. *European Journal of Operational Research*, 88(3):464 – 474.
- Coello, C. A. C., Lamont, G. B., and Veldhuizen, D. A. V. (2007). *Evolutionary algorithms for solving multi-objective problems*. Springer.
- de Oliveira Santos, R., Cipriano G. Junior, B., da S. Santos, C. E., Macedo, C. J. A., and de Oliveira-Jr., A. C. (2025). QoE-CAC: métrica de QoE em Sistemas de Comunicação Imersiva Consciente de Atenção e Comunicação. In *Anais do XLIII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT 2025)*, Natal, RN, Brazil.
- Dorigo, M., Birattari, M., and Stutzle, T. (2006). Ant colony optimization. *IEEE Computational Intelligence Magazine*, 1(4):28–39.
- Du, H., Liu, J., Niyato, D., Kang, J., Xiong, Z., Zhang, J., and Kim, D. I. (2023). Attention-Aware Resource Allocation and QoE Analysis for Metaverse xURLLC Services. *IEEE Journal on Selected Areas in Communications*, 41(7):2158–2175.

- Esper, J. P., Fraga, L. d. S., Viana, A. C., Cardoso, K. V., and Correa, S. L. (2025). + Tour: Recommending personalized itineraries for smart tourism. *Computer Networks*, 260:111118.
- Hodson, H. (2012). Google’s ingress game is a gold mine for augmented reality.
- Krogfoss, B., Duran, J., Pérez, P., and Bouwen, J. (2020). Quantifying the Value of 5G and Edge Cloud on QoE for AR/VR. *2020 Twelfth International Conference on Quality of Multimedia Experience (QoMEX)*, pages 1–4.
- Laato, S., Söbke, H., and Baer, M. F. (2024). Augmented future: tracing the trajectory of location-based augmented reality gaming for the next ten years. *i-com*, 23(2):189–203.
- Lee, K.-Y., Singla, A., Cesar, P., and Hsu, C.-H. (2025). Adaptive cloud VR gaming optimized by gamer QoE models. *ACM Transactions on Multimedia Computing, Communications and Applications*, 21(9):1–24.
- Lim, K. H., Wang, X., Chan, J., Karunasekera, S., Leckie, C., Chen, Y., Tan, C. L., Gao, F. Q., and Wee, T. K. (2016). Perstour: A personalized tour recommendation and planning system. In *HT (Extended Proceedings)*.
- Lima, E. d. F. (2023). Otimização de Roteiro de Coleta de Resíduos Sólidos Urbanos para a quadra 405 Norte, no município de Palmas-TO. *Biblioteca IFTO*.
- Raca, D., Leahy, D., Sreenan, C. J., and Quinlan, J. J. (2020). Beyond throughput, the next generation: A 5G dataset with channel and context metrics. In *Proceedings of the 11th ACM multimedia systems conference*, pages 303–308.
- Shea, R., Fu, D., Sun, A., Cai, C., Ma, X., Fan, X., Gong, W., and Liu, J. (2017). Location-based augmented reality with pervasive smartphone sensors: Inside and beyond pokemon go! *IEEE Access*, 5:9619–9631.
- Shen, S., Zhou, Y., Lei, Q., and Wu, Z. (2025). A survey of the orienteering problem: model evolution, algorithmic advances, and future directions. *arXiv preprint arXiv:2512.16865*.
- Tregel, T., Müller, P., Göbel, S., and Steinmetz, R. (2018). Where’s pikachu: Route optimization in location-based games. In *2018 10th International Conference on Virtual Worlds and Games for Serious Applications (VS-Games)*, pages 1–8. IEEE.
- Tregel, T., Müller, P. N., Göbel, S., and Steinmetz, R. (2021). Looking for charizard: applying the orienteering problem to location-based games. *The Visual Computer*, 37(1):31–45.
- Vansteenwegen, P., Souffriau, W., and Oudheusden, D. V. (2019). The orienteering problem: A survey. *European Journal of Operational Research*, 209.
- Xu, J. (2022). From augmented reality location-based games to the real-world metaverse. In *Extended abstracts of the 2022 annual symposium on computer-human interaction in play*, pages 364–366.
- Xu, J., Papangelis, K., and Tigwell, G. W. (2026). AR Location-Based Games: One Step Closer to the Real-World Metaverse. In *Handbook of the Metaverse*, pages 335–368. Springer.