

Análise Comparativa de Modelos de Propagação e Qualidade de Experiência em Redes 5G: Implicações para o Planejamento de Redes Urbanas

Antonio Wilker O. de Sena¹, Gleison de O. Medeiros¹, João Victor C. Carmona¹

¹Faculdade de Sistemas de Informação
Universidade Federal do Sul e Sudeste do Pará (UNIFESSPA)
Folha 17, Quadra 04, Marabá-PA - Brasil

wilkersena, gleison, jvictor@unifesspa.edu.br

Abstract. This work investigates the efficiency of different path loss models in fifth-generation (5G) mobile networks, focusing on analyzing their impact on the user's Quality of Experience (QoE). Three propagation models were analyzed: Log Distance, Three Log Distance, and Cost 231, using simulations in a virtual environment with the NS-3 simulator. The QoE metrics used were the Mean Opinion Score (MOS) and the Peak Signal-to-Noise Ratio (PSNR). The results indicated that the Cost 231 model demonstrated the best performance in ultra-dense scenarios, maintaining communication quality and user experience even with a high density of users. The Log Distance model, on the other hand, showed good performance only in low-density scenarios, while the Three Log Distance model exhibited inconsistent results.

Resumo. Este trabalho investiga a eficiência de diferentes modelos de propagação em redes móveis de quinta geração (5G), com foco na análise do impacto desses modelos na qualidade da experiência do usuário (QoE). Três modelos de propagação foram analisados: Log Distance, Three Log Distance e Cost 231, utilizando simulações em ambiente virtual com o simulador NS-3. As métricas de QoE utilizadas foram o Mean Opinion Score (MOS) e o Peak Signal-to-Noise Ratio (PSNR). Os resultados indicaram que o modelo Cost 231 demonstrou o melhor desempenho em cenários ultra-densos, mantendo a qualidade da comunicação e da experiência do usuário, mesmo com alta densidade de usuários. O modelo Log Distance, por outro lado, apresentou um bom desempenho apenas em cenários de baixa densidade de usuários, enquanto o Three Log Distance apresentou desempenho inconsistente.

1. Introdução

O avanço das tecnologias de comunicação tem transformado profundamente a maneira como pessoas e dispositivos se conectam ao mundo. Com a crescente digitalização de serviços e o aumento na utilização de dispositivos móveis, a demanda por redes de comunicação de alta capacidade e baixa latência se tornou indispensável. As redes de quinta geração (5G) surgiram como uma solução promissora para atender a essa demanda, proporcionando velocidades de transmissão significativamente maiores, maior densidade de conexões simultâneas e latências reduzidas. Esses avanços tornam possível

a implementação de tecnologias como Internet das Coisas (IoT), veículos autônomos, cidades inteligentes e aplicações de realidade aumentada [Giordani et al. 2020].

A popularização do 5G é acompanhada por desafios técnicos, especialmente relacionados à propagação do sinal. Devido às características de suas frequências mais altas, o 5G apresenta maior suscetibilidade à atenuação do sinal, causada pela distância e por barreiras físicas no ambiente, como edifícios e árvores. Essas limitações impactam diretamente a cobertura, a confiabilidade da comunicação e a qualidade da experiência (QoE) percebida pelos usuários finais. Em áreas de alta densidade populacional, onde o uso simultâneo de dispositivos é intenso, esses problemas se tornam ainda mais críticos, exigindo soluções específicas para otimizar a transmissão de sinal [Haykin 2008].

No contexto brasileiro, a relevância do 5G é ainda maior, considerando que a maioria dos usuários depende exclusivamente de dispositivos móveis para acessar a internet, especialmente em regiões onde a infraestrutura fixa é limitada. Segundo o CETIC [CETIC 2022], 62% dos brasileiros utilizam seus celulares como principal meio de acesso à rede, e em algumas regiões, como o Norte e o Nordeste, esse índice pode ultrapassar 70%. Esses números evidenciam a importância de planejar e otimizar redes móveis que atendam adequadamente às necessidades de conexão de um público diverso e em rápida expansão.

Um dos principais aspectos a serem considerados no planejamento de redes 5G é a escolha de modelos de propagação (*Path Loss*), que descrevem a atenuação do sinal conforme ele se desloca do transmissor ao receptor. Esses modelos são essenciais para prever o desempenho da rede, otimizar o posicionamento de estações base e garantir que os usuários tenham uma experiência de comunicação estável e de alta qualidade. Modelos como *Log Distance*, *Three Log Distance* e *Cost 231* foram amplamente estudados em diferentes cenários, mas suas aplicações em ambientes de alta densidade de usuários, como os simulados neste estudo, ainda apresentam lacunas de conhecimento [Bezerra 2017, Silva 2020].

Este artigo tem como objetivo preencher essas lacunas ao avaliar o desempenho dos modelos de propagação mencionados em um cenário de rede 5G simulado, com foco na análise de métricas de qualidade de experiência (QoE), como *Mean Opinion Score* (MOS) e *Peak Signal-to-Noise Ratio* (PSNR). Os resultados obtidos buscam contribuir para o planejamento eficiente de redes móveis, otimizando a cobertura e a confiabilidade do 5G, mesmo em contextos desafiadores.

2. Fundamentação Teórica

2.1. Redes 5G

As redes 5G representam uma evolução significativa em comparação às gerações anteriores, oferecendo melhorias em termos de velocidade, latência e conectividade. Essas redes foram projetadas para atender aos requisitos estabelecidos pelo [(ITU) 2020], que incluem taxas de dados de até 20 Gbps em cenários ideais, latências inferiores a 1 ms e suporte para até 1 milhão de dispositivos conectados por quilômetro quadrado.

Além de permitir a criação de novos serviços, como automação industrial, telemedicina e cidades inteligentes, o 5G utiliza frequências mais altas, conhecidas como ondas milimétricas (*mmWave*). Embora essas frequências proporcionem maior largura

de banda e capacidade, também apresentam maior atenuação de sinal, especialmente em ambientes urbanos densos. Isso torna o planejamento da cobertura e o uso de modelos de propagação de sinal indispensáveis, por exemplo, em serviços críticos como veículos autônomos [Giordani et al. 2020, Haykin 2008].

2.2. Arquitetura C-RAN

A **arquitetura C-RAN** tem ganhado destaque nas redes 5G devido à sua flexibilidade e capacidade de gerenciar de forma mais eficiente a comunicação em ambientes densos. Ao centralizar o processamento de sinais em unidades de nuvem, essa arquitetura permite que as estações base se tornem mais simples e eficientes, reduzindo custos e complexidade operacional [Zhang et al. 2019]. A utilização de técnicas avançadas como *MIMO* e *beamforming* também é facilitada com a centralização do processamento, melhorando a eficiência espectral e a QoE em áreas de alta densidade de usuários.

A implementação da arquitetura C-RAN no 5G também é essencial para a utilização eficiente de espectro, especialmente considerando a alta demanda por dados. Segundo [Feng et al. 2021], a combinação de C-RAN com tecnologias de redes 5G, como *beamforming* adaptativo e *network slicing*, pode melhorar significativamente a qualidade da experiência, especialmente em áreas congestionadas. Essa abordagem ajuda a reduzir a latência e otimiza o tráfego de dados, o que é essencial para serviços críticos.

2.3. Path Loss

A perda de propagação (*path loss*) é definida como a redução da potência do sinal à medida que ele se propaga por um meio. Esse fenômeno ocorre devido à absorção, reflexão, difração e espalhamento do sinal, e é influenciado por fatores como frequência, distância e características do ambiente [Haykin 2008]. A análise e modelagem da perda de propagação são fundamentais para o planejamento de redes sem fio, pois permitem prever a intensidade do sinal em diferentes cenários e otimizar a alocação de recursos [Bezerra 2017].

2.3.1. Modelos de Propagação Analisados

Log Distance Este modelo descreve a relação entre a perda de propagação e a distância por meio de uma relação logarítmica [Silva 2020]:

$$PL(d) = PL(d_0) + 10n \log_{10} \left(\frac{d}{d_0} \right),$$

onde $PL(d)$ é a perda de percurso (dB), $PL(d_0)$ é a perda de percurso na distância de referência d_0 , n é o expoente do percurso, d é a distância entre transmissor e receptor, e d_0 é a distância de referência.

Three Log Distance Este modelo é uma extensão do Log Distance, adaptando-se a diferentes regiões de propagação [Bezerra 2017]:

$$PL(d) = \{ PL_1(d), d \leq d_1, PL_2(d), d_1 < d \leq d_2, PL_3(d), d > d_2,$$

onde PL_1 , PL_2 e PL_3 seguem a fórmula do Log Distance, mas com diferentes expoentes n .

Cost 231 O modelo COST 231 é amplamente utilizado em ambientes urbanos e suburbanos. Ele é dado por:

$$PL = 46.3 + 33.9 \log_{10}(f) - 13.82 \log_{10}(h_b) - a(h_m) + [44.9 - 6.55 \log_{10}(h_b)] \log_{10}(d) + C$$

Onde:

- f : Frequência (MHz);
- h_b : Altura da antena transmissora (m);
- h_m : Altura da antena receptora (m);
- d : Distância entre transmissor e receptor (km);
- $a(h_m)$: Fator de correção para altura da antena receptora, definido como:

$$a(h_m) = (1.1 \log_{10} f - 0.7)h_m - (1.56 \log_{10} f - 0.8)$$

- C : Constante de correção (0 para ambientes suburbanos, 3 para urbanos).

3. Trabalhos Relacionados

A análise de modelos de propagação e sua influência na QoE do usuário é um tema amplamente discutido na literatura. Estudos prévios têm explorado diferentes abordagens para modelar a perda de propagação e avaliar seus impactos, com ênfase em redes de alta frequência, como o 5G. Contudo, ainda há lacunas ao avaliar esses modelos em cenários densos, com métricas objetivas e subjetivas de QoE.

3.1. Estudos Relevantes

Em [Bezerra 2017], os autores utilizam técnicas de ajuste de curvas para otimizar a escolha de modelos de propagação em ondas milimétricas (*mmWave*). Dados experimentais foram coletados para avaliar diferentes modelos, sendo as previsões validadas por métricas de intensidade de sinal. Apesar de contribuir para a análise em frequências elevadas, o estudo não considera métricas como MOS ou PSNR, limitando sua aplicação em avaliações de QoE.

Já em [Silva 2020], os autores compararam diversos modelos de *path loss* (incluindo Log Distance e Cost 231) em cenários reais de transmissão. Seu foco foi na identificação do modelo mais eficiente e na proposta de melhorias. Embora abrangente, o estudo foi restrito a ambientes com baixa densidade de usuários e não analisou métricas de QoE.

Em [Huang et al. 2022], os autores propuseram o uso de redes neurais para prever perdas de propagação e avaliar a QoE em serviços de streaming de vídeo. Essa abordagem demonstrou alta precisão nas previsões em comparação com métodos tradicionais, mas o foco em inteligência artificial desvia da análise detalhada de modelos matemáticos em cenários densos [Huang et al. 2022].

Por fim, em [Medeiros 2020], os autores desenvolveram um *framework* para balanceamento de carga em redes C-RAN, utilizando previsões de QoE para otimizar a alocação de recursos. Embora relevante, sua abordagem é voltada para a arquitetura de rede, sem explorar modelos de propagação ou a relação direta entre *path loss* e QoE.

Os trabalhos discutidos abordam diferentes aspectos da análise de propagação de sinal e QoE, mas apresentam limitações que este estudo busca superar. As principais diferenças são:

- Este estudo avalia diretamente a eficiência de três modelos de *path loss* (*Log Distance*, *Three Log Distance* e *Cost 231*) em cenários simulados de alta densidade de usuários;
- A análise é feita com base em métricas de QoE, como MOS e PSNR, enquanto muitos estudos anteriores focam apenas em intensidade de sinal; e
- O ambiente simulado permite controlar variáveis como densidade de usuários e configurações de rede, possibilitando uma comparação direta entre os modelos.

4. Metodologia

A metodologia deste estudo foi baseada em simulações realizadas em um ambiente controlado com o uso do simulador de redes NS-3. O objetivo principal foi avaliar o desempenho dos modelos de propagação *Log Distance*, *Three Log Distance* e *Cost 231* em cenários 5G baseados em uma arquitetura C-RAN. A simulação foi projetada para refletir condições realistas de consumo de *streaming* de vídeo em alta definição.

4.1. Cenários Simulados

A simulação foi configurada para três cenários diferentes, variando a quantidade de usuários (UEs) para observar como o consumo simultâneo de *streaming* de vídeos afeta a qualidade da comunicação e a eficiência dos modelos de propagação.

Tabela 1. Parâmetros de Simulação

Parâmetro	Valor
Número de BBUs	6
Fronthaul Link	10 Gbps Full Duplex
Fronthaul Delay	100 μ s
Número de RRHs	18
Área de Cobertura	1000m x 1000m
Distância entre RRHs	200m
Potência RRH	46 dBm
Bandwidth	20 MHz
Sistema de Alocação	FDD
Alocação de UEs	RandomBox PositionAllocator
Modelos de Propagação	Log Distance, Three Log Distance, Cost 231
Número de UEs	70, 80, 100
Potência UE	18 dBm
Velocidade de Mobilidade	30% a 30 km/h 70% a 3 km/h
Tempo de Simulação	30000s
Aplicação	RTP Streaming (UHD Video)

Cenário 1: Densidade de 70 UEs Este cenário simula um ambiente com 70 usuários distribuídos aleatoriamente em uma área de 1000m². A simulação foi configurada para ter uma quantidade de dispositivos moderada, permitindo avaliar como os modelos de propagação performam em uma rede com uso médio de dados.

Cenário 2: Densidade de 80 UEs Com 80 usuários distribuídos igualmente pela área de cobertura, este cenário busca testar a performance da rede em condições mais desafadoras, com um aumento de 14% na quantidade de usuários em relação ao cenário anterior.

Cenário 3: Densidade de 100 UEs Neste cenário, 100 UEs são posicionados de maneira aleatória em uma área de 1000m². Este é o cenário de testes de maior densidade de usuários, simulando uma rede 5G mais congestionada.

Os parâmetros gerais de simulação foram definidos conforme Tabela 1.

4.2. Métricas de Avaliação

As métricas de avaliação utilizadas para este estudo foram:

- **Mean Opinion Score(MOS):**A métrica MOS é uma medida subjetiva que classifica a qualidade da experiência de um usuário, com valores variando de 1 (péssimo) a 5 (excelente). No contexto de redes móveis, o MOS é amplamente utilizado para avaliar a qualidade de voz e vídeo.
- **Peak Signal-to-Noise Ratio (PSNR):**O PSNR é uma métrica objetiva amplamente utilizada para medir a qualidade de imagens e vídeos, com valores mais altos indicando melhor qualidade de sinal.

A Tabela 2 apresenta a correlação entre PSNR e MOS.

MOS	Qualidade	PSNR (dB)
5	Excelente	> 37
4	Bom	31–37
3	Regular	25–30
2	Ruim	20–24
1	Péssimo	< 20

Tabela 2. Correlação entre MOS e PSNR.

4.3. Ferramentas Utilizadas

A simulação foi realizada no **NS-3**, um simulador de redes amplamente utilizado na academia e na indústria. O NS-3 permite simular diferentes topologias de rede, protocolos e cenários realistas de comunicação. Para a análise de QoE, utilizou-se o módulo **Eval-vid**, que permite avaliar o desempenho da transmissão de vídeo em redes móveis. Os dados foram gerados a partir das simulações de vídeo *streaming* em alta definição, com os seguintes parâmetros:

- Vídeo transmitido: "rush_field_cuts", 1080p e 30fps, disponível em <https://media.xiph.org/video/derf/>.

- Duração da simulação: 300s por cenário de configuração.
- Tráfego de fundo: 20% dos usuários transmitindo dados HTTP, simulando uma carga de rede adicional.

5. Discussão dos Resultados

Os resultados obtidos da simulação fornecem insights importantes sobre o comportamento dos modelos de propagação em cenários urbanos densos, especificamente nos modelos *Log Distance*, *Three Log Distance* e *Cost 231*. As imagens que ilustram os resultados podem ser encontradas nas Figuras 1 a 8 e demonstram mostram a relação entre a densidade de usuários e a QoE percebida.

5.1. Performance dos Modelos de Propagação

5.1.1. Log Distance

O modelo *Log Distance* apresentou um desempenho satisfatório, especialmente no cenário com menor densidade de usuários (70 UEs), conforme mostrado na Figura 1. O MOS médio foi classificado como "Bom"(4) na maior parte dos testes. No entanto, conforme observado na Figura 2, à medida que a densidade aumentou, o desempenho apresentou queda. O pior resultado foi observado com 80 UEs, enquanto com 100 UEs houve uma ligeira recuperação, embora ainda inferior ao desempenho inicial com 70 UEs, o que reflete os efeitos da sobrecarga na rede.

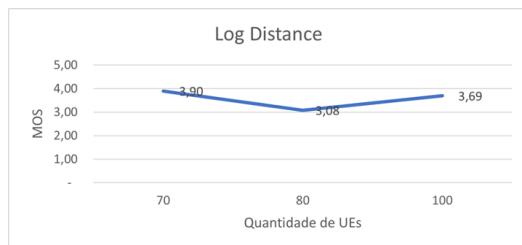


Figura 1. Relação MOS por UEs no modelo *log distance*

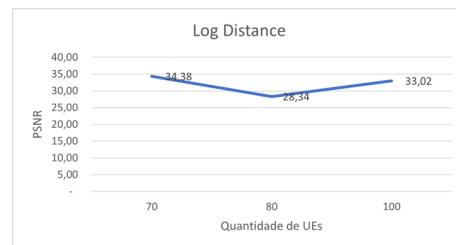


Figura 2. Relação PSNR por UEs no modelo *log distance*

5.1.2. Three Log Distance

O modelo *Three Log Distance* se comportou de maneira mais complexa. Para o cenário com 70 UEs, o desempenho foi comparável ao do *Log Distance*, mas apresentou maior variação na qualidade do sinal devido aos três diferentes parâmetros de distância. À medida que a densidade de usuários aumentou, houve uma leve melhora no desempenho, com pico observado em 80 UEs. Apesar de uma pequena queda posteriormente, o desempenho com 100 UEs ainda foi superior ao observado com 70 UEs, conforme mostram as Figuras 3 e 4.

5.1.3. Cost 231

O modelo *Cost 231*, por sua vez, demonstrou ser o mais robusto em cenários com alta densidade de usuários. Os resultados apresentados nas Figuras 5 e 6 indicam que, embora

o desempenho com 80 UEs tenha sido o mais baixo entre os cenários testados, o modelo apresentou um desempenho superior com 100 UEs em relação ao cenário inicial com 70 UEs, mantendo classificações de MOS entre 4 e 5 e valores de PSNR acima de 30 dB em grande parte da rede.

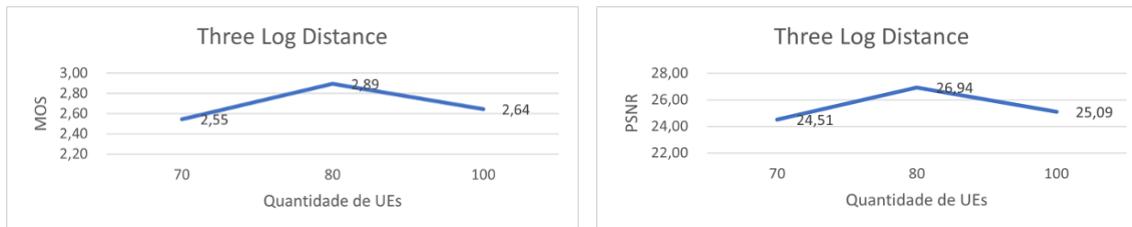


Figura 3. Relação MOS por UEs no modelo *Three Log Distance*

Figura 4. Relação PSNR por UEs no modelo *Three Log Distance*



Figura 5. Relação MOS por UEs no modelo *Cost 231*

Figura 6. Relação PSNR por UEs no modelo *Cost 231*

5.2. Comparação dos Modelos e Análise de QoE

A comparação entre os três modelos de propagação revela que, embora o *Log Distance* seja eficiente para cenários de baixa densidade, ele se torna inadequado à medida que a quantidade de usuários cresce. O *Three Log Distance*, apesar de oferecer uma abordagem mais refinada, apresentou desempenho inconsistente e inferior ao Cost 231, especialmente em cenários com quantidade de usuários consideráveis. As Figuras 7 e 8, apresentam um comparativo geral entre todos os modelos estudados.

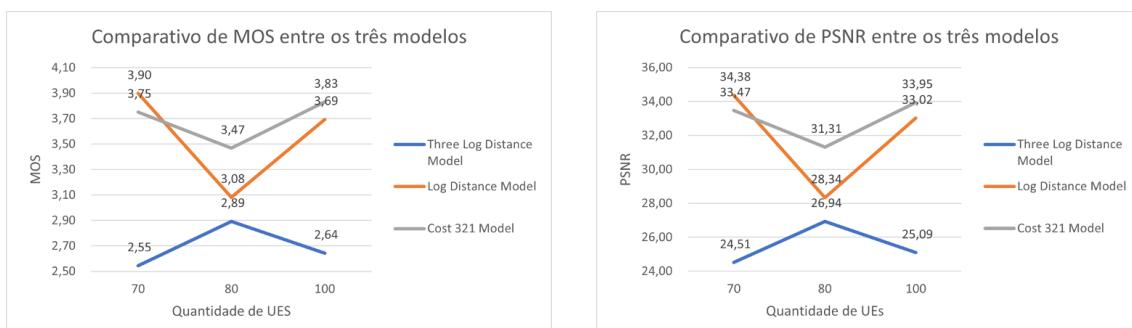


Figura 7. Relação MOS por UEs no modelo *Cost 231*

Figura 8. Relação PSNR por UEs no modelo *Cost 231*

5.3. Implicações Práticas para Redes 5G

Os resultados obtidos têm implicações significativas para o planejamento de redes 5G em ambientes urbanos densos. A utilização de modelos como o *Cost 231* pode melhorar a cobertura e a qualidade da experiência do usuário, principalmente em áreas com alta concentração de usuários.

6. Conclusão

Este trabalho investigou a eficiência de diferentes modelos de propagação (*Path Loss*) em um cenário de redes móveis 5G, com foco na análise de sua influência na qualidade da experiência do usuário. Três modelos de propagação foram analisados: *Log Distance*, *Three Log Distance* e *Cost 231*, utilizando a simulação no ambiente virtual do NS-3. As métricas de QoE, MOS e PSNR, foram utilizadas para avaliar o desempenho dos modelos em cenários com aumento gradativo de usuários.

A análise demonstrou que, enquanto o *Log Distance* apresenta um bom desempenho em cenários de baixa densidade, ele se torna ineficaz em situações com maior concentração de dispositivos. Isso ocorre devido à simplificação na modelagem da propagação de sinal, que não leva em consideração obstáculos e outros fatores que afetam o sinal em ambientes urbanos densos.

O *Three Log Distance*, apesar de oferecer uma abordagem mais detalhada, apresentou desempenho inconsistente. Em alguns cenários, o modelo teve desempenho semelhante ao do *Log Distance*, mas em outros, especialmente nos de alta densidade, sua performance foi inferior ao *Cost 231*. A complexidade adicional deste modelo, sem ajustes adequados, dificultou seu desempenho em cenários de rede com maior exigência de *bandwidth*.

Por outro lado, o *Cost 231* se destacou como o modelo mais robusto e adequado para ambientes urbanos mais exigentes. Sua capacidade de levar em consideração múltiplos fatores de atenuação do sinal, como a presença de obstáculos e a altura das antenas, permitiu que o modelo mantivesse um desempenho consistente em diferentes condições e foi o único a apresentar resultados "Excelentes" tanto para o MOS quanto para o PSNR em todos os cenários testados.

As implicações práticas deste estudo são claras: ao planejar redes 5G, a escolha do modelo de propagação deve ser feita com base na densidade de usuários e nas características específicas do ambiente. O *Cost 231* se mostrou particularmente eficaz em cenários urbanos, o que o torna a melhor opção para otimizar a qualidade da comunicação e a QoE.

Este estudo tem contribuições importantes para o planejamento de redes 5G, especialmente para ambientes urbanos densos, onde a qualidade da experiência do usuário é crucial para o sucesso das novas tecnologias. Contudo, como todo estudo, ele apresenta algumas limitações. A simulação foi realizada em um cenário específico e não considerou variáveis como interferências externas, mobilidade dos usuários de forma mais complexa, ou o impacto de novos modelos de antenas e tecnologias de rede, como o uso de MIMO (Multiple Input, Multiple Output) ou técnicas de *beamforming*.

6.1. Trabalhos Futuros

A continuidade deste estudo pode seguir diversas direções para ampliar a compreensão sobre a eficiência dos modelos de propagação e melhorar a performance das redes 5G em diferentes cenários. Algumas possíveis direções incluem:

- **Avaliação de Tecnologias Avançadas:** Estudar o impacto de tecnologias como MIMO e *beamforming* na propagação de sinal e como essas técnicas podem melhorar a QoE em redes 5G.
- **Cenários Mais Complexos:** Incluir a análise de interferências externas e a mobilidade dos usuários de forma mais complexa, simulando movimentos dinâmicos em áreas com grandes aglomerações.
- **Estudo de Outros Modelos de Propagação:** Testar e comparar outros modelos de propagação mais avançados, como os baseados em dados reais de medições de campo ou modelos adaptativos que podem ajustar os parâmetros de propagação em tempo real.
- **Análise de QoE para Diferentes Tipos de Serviços:** Estudar a QoE em diferentes tipos de serviços, como comunicação em tempo real (voz e vídeo), Internet of Things (IoT) e serviços de alta largura de banda.
- **Redes 6G e Propagação em Novas Frequências:** Considerando o futuro das redes 6G, estender o estudo para modelos de propagação em frequências ainda mais altas e explorar as implicações dessas novas bandas para a qualidade de serviço.

Referências

- Bezerra, T. (2017). Ajuste de curvas aplicado a escolha de modelos de predição de canais de comunicações por ondas milimétricas. *Dissertação de Mestrado*.
- CETIC (2022). Pesquisa tic domicílios 2022. <https://cetic.br>.
- Feng, Y., Zhou, Z., and Zhang, L. (2021). Beamforming and virtualized network slicing in c-ran for 5g. *IEEE Transactions on Communications*, 69(7):4567–4579.
- Giordani, M., Polese, M., Mezzavilla, M., Rangan, S., and Zorzi, M. (2020). Toward 6g networks: Use cases and technologies. *IEEE Communications Magazine*, 58(3):55–61.
- Haykin, S. (2008). *Communications Systems*. John Wiley & Sons, 5th edition.
- Huang, G., Ercetin, O., Gokcesu, H., and Kalem, G. (2022). Deep learning-based qoe prediction for streaming services in mobile networks. *2022 18th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)*, pages 327–332.
- (ITU), I. T. U. (2020). Itu towards imt for 2020 and beyond. <https://www.itu.int/en/ITU-R/study-groups/rsg5/rwp5d/imt-2020/Pages/default.aspx>. Accessed: 2024-11-25.
- Medeiros, G. d. O. (2020). Um framework inteligente baseado em previsões de qoe para o balanceamento de cargas em redes 5g. *Tese de Doutorado em Engenharia Elétrica*.
- Silva, G. N. S. d. (2020). Melhoria de modelos de predição de path loss para sinais da quinta geração (5g) na faixa de 3,5 ghz. *Trabalho de Conclusão de Curso*.
- Zhang, H., Liu, N., Liu, X., Wang, X., and Mao, S. (2019). C-ran: An enabling technology for 5g networks. *IEEE Wireless Communications*, 26(3):136–143.