

Interferência: Predição de Cobertura Eletromagnética Usando Inteligência Artificial

Luiz Felipe Pereira Costa *, Natanael Nunes de Moura Junior * e Frederico Fernandes Neves ***

Resumo—A expansão das redes 5G demanda um planejamento eficiente, o que requer previsões precisas da perda de propagação. Para superar a ineficiência de métodos determinísticos (ITU-R P.1812-6), este artigo aplica modelos de Inteligência Artificial para estimar a cobertura (SS-RSRP). Em validação cega, o XGBoost obteve a melhor Raiz do Erro Quadrático Médio (RMSE) calibrada (10,80 dB), reduzindo a inferência de 12 horas para 3 minutos. Uma rede híbrida quântica superou sua contraparte clássica (MLP), demonstrando maior resiliência contra o vazamento espacial e o sobreajuste às coordenadas de treino, evidenciando o grande potencial do Aprendizado de Máquina Quântico em telecomunicações reais.

Palavras-Chave—5G, Predição de Cobertura, Aprendizado de Máquina, XGBoost, Aprendizado de Máquina Quântico.

Abstract—The expansion of 5G networks demands efficient planning, which requires accurate predictions of propagation loss. To overcome the computational inefficiencies of deterministic methods (ITU-R P.1812-6), this paper applies Artificial Intelligence models to estimate coverage (SS-RSRP). Through blind validation, XGBoost achieved the best calibrated Root Mean Square Error (RMSE) of 10.80 dB, reducing inference time from 12 hours to 3 minutes. Furthermore, a hybrid quantum network outperformed its classical counterpart (MLP), demonstrating greater resilience against spatial leakage and overfitting to training coordinates, evidencing the great potential of Quantum Machine Learning in real-world telecommunications.

Keywords—5G, Coverage Prediction, Machine Learning, XGBoost, Quantum Machine Learning.

I. INTRODUÇÃO

O uso do espectro eletromagnético enfrenta crescente pressão com a expansão do 5G e da Internet das Coisas (IoT) [8]. Nesse cenário, o planejamento de redes e a predição precisa da perda de percurso (*path loss*) são indispensáveis para mitigar interferências e garantir a qualidade do serviço [1], [4]. Tradicionalmente, essa tarefa depende de modelos empíricos, que frequentemente falham em capturar toda a complexidade dos fenômenos de propagação do mundo real, como espalhamento e difração em ambientes urbanos dinâmicos [2], [6], ou de modelos determinísticos, como a Recomendação ITU-R P.1812 [18]. Embora possuam fundamentação física e considerem dados morfológicos, modelos determinísticos possuem altíssimo custo computacional e exigem extrema precisão dos dados geográficos [1], [7]. Em malhas urbanas densas, a dificuldade em modelar perfeitamente os múltiplos caminhos e difrações faz com que mesmo modelos rigorosos

apresentem taxas de erro substanciais e tempos de execução proibitivos [3], [14].

Para solucionar a dicotomia entre imprecisão estatística e ineficiência determinística, técnicas de Aprendizado de Máquina (*Machine Learning* - ML) baseadas em dados consolidaram-se como o estado da arte [1], [2]. Modelos como *eXtreme Gradient Boosting* (XGBoost) e Redes Neurais de Perceptron em Multi Camadas (*Multi-Layer Perceptrons* - MLP) demonstram valor ao aprender padrões não lineares do canal de rádio, extraindo correlações e características espaciais complexas diretamente de dados massivos de medições em campo ou *Drive Tests* (DT) [3], [6]. Motivado por esse potencial, este estudo aplica modelos de Inteligência Artificial para a predição do sinal SS-RSRP (*Secondary Synchronization Signal Reference Signal Received Power*), visando superar as limitações de tempo e precisão dos métodos tradicionais na adaptação ao canal físico real.

Paralelamente, o avanço da computação quântica à era NISQ (*Noisy Intermediate-Scale Quantum*) viabiliza o Aprendizado de Máquina Quântico (*Quantum Machine Learning* - QML) nas telecomunicações. Como hardwares tolerantes a falhas ainda são limitados, Redes Neurais Híbridas Quântico-Clássicas (HQNNs), onde circuitos parametrizados interagem com otimizadores clássicos, surgem como uma ponte viável para a otimização de redes móveis [9], [15], [16]. Neste contexto, o presente artigo avalia o desempenho de modelos de IA clássicos (Árvores de Decisão, XGBoost e MLP) na predição de níveis de sinal frente ao modelo ITU-R P.1812. Além de demonstrar o ganho preditivo e computacional da IA clássica, aplica-se um alinhamento físico utilizando a função *tanh* para restringir as saídas neurais entre -156 dBm e -31 dBm, conforme a norma 3GPP TS 38.133 [13].

II. TRABALHOS RELACIONADOS

Historicamente, a predição de perda de percurso e da cobertura em telecomunicações tem dependido de modelos empíricos ou determinísticos [6]. Modelos empíricos falham em capturar a complexidade da propagação em ambientes urbanos densos, onde fenômenos de espalhamento e difração são intensos [2], [4]. Por outro lado, modelos determinísticos rigorosos, como o ITU-R P.1812, oferecem robustez física, mas esbarram em um altíssimo custo computacional e em uma sensibilidade extrema à resolução das bases geográficas, tornando as previsões de larga escala muitas vezes impraticáveis ou excessivamente lentas [1], [6], [7]. Para resolver a dicotomia entre velocidade e precisão, abordagens orientadas a dados baseadas em ML consolidaram-se como o estado da arte [2], [5], [6].

*Laboratório de Processamento de Sinais (COPPE/Poli, UFRJ), Rio de Janeiro - RJ; **e-mail: luiz.costa@lps.ufrj.br; ***Gerência de Espectro, Órbita e Radiodifusão, Coordenador de Engenharia e Uso Eficiente do Espectro, e-mail: fneves@anatel.gov.br.

No contexto preditivo, métodos como Redes Neurais de Perceptron em Multi Camadas e algoritmos baseados em árvores de decisão e *ensemble*, como o XGBoost, têm demonstrado desempenho notável [1], [4], [14]. Diversos estudos comprovam que o XGBoost é altamente eficaz para modelar as relações não lineares típicas de dados de rádio propagação espacial extraídos a partir de medições de campo [3], [6], [14]. Devido à sua arquitetura de otimização sequencial, o algoritmo consegue processar rapidamente grandes volumes de características tabulares complexas (como distância, elevação do terreno e altura morfológica do *clutter* urbano), superando os modelos tradicionais tanto na precisão estatística e redução de viés, quanto na eficiência do tempo de execução [1], [6], [14].

Em paralelo à consolidação do ML clássico, a literatura recente tem começado a investigar o potencial do Aprendizado de Máquina Quântico para otimizar as operações das futuras redes 5G e 6G [8], [10]. Contudo, como os hardwares quânticos atuais ainda operam restritos à era NISQ, com limitações de coerência e quantidade de *qubits*, o processamento de modelos de forma puramente quântica permanece inviável. A solução adotada concentra-se nas Redes Neurais Híbridas Quântico-Clássicas (HQNNs), que utilizam Circuitos Quânticos Parametrizados (VQCs) para codificar a informação em espaços de Hilbert de alta dimensão, enquanto a otimização da função de custo continua a cargo de um computador clássico [9], [15], [16]. Embora as redes híbridas já venham sendo exploradas para tarefas como alocação de recursos e segurança cibernética, a sua aplicação direta como modelo de regressão para a predição espacial de sinais com base em dados massivos de DT permanece uma área incipiente [10], [11]. Nesse cenário, a introdução de uma rede híbrida (HQNN) neste artigo serve como uma prova de conceito, avaliando sua capacidade de generalização e extração de características físicas em comparação direta com arquiteturas clássicas.

III. METODOLOGIA

Este trabalho propõe o desenvolvimento de um *pipeline* computacional de ponta a ponta para a predição espacial do sinal de referência (SS-RSRP) em redes 5G NR. O sistema foi estruturado em quatro estágios: (1) Engenharia de Dados, (2) Separação Espacial de Amostras, (3) Modelagem Preditiva (ITU-R P.1812 e Inteligência Artificial) e (4) Inferência e Validação Georreferenciada.

A. Engenharia e Integração de Dados Geoespaciais

O primeiro passo consistiu em construir uma base de dados unificada, mesclando informações de licenciamento de antenas da Anatel, mapas topográficos de 10 metros de resolução e medições de campo ou *Drive Tests* (DT) 5G realizadas no ambiente urbano de Niterói/RJ.

Como os DTs registram apenas coordenadas do veículo e intensidade do sinal, eles atuam como pontos cegos de infraestrutura. Para o pareamento geográfico, utilizou-se a estrutura *BallTree* filtrando os 15 transmissores mais próximos de cada ponto. A associação definitiva da Estação Rádio Base (ERB) não se baseou apenas na menor distância física, mas na

viabilidade eletromagnética, avaliando a atenuação direcional (desvio de azimuth) e a estimativa teórica de perda de percurso, vinculando estritamente o DT ao setor que fisicamente justificasse a recepção.

Para evitar redundância de dados (ex: veículo parado no trânsito registrando o mesmo ponto repetidas vezes) e filtrar o ruído de desvanecimento rápido (*fast fading*) causado por obstáculos móveis, os dados foram agrupados por combinação única de receptor e transmissor, restando-se a média do sinal recebido. O vetor final de atributos (*features*) entregue aos modelos conteve 10 parâmetros: classe de ocupação do solo (*Clutter_Class*), elevação do terreno (*Height_m*), distância Euclidiana (*Dist_Antena_m*), desvio de azimuth (*Delta_Azimuth*), características da antena transmissora (*Altura*, *Ganho*, *Ângulo de Meia Potência*, *Relação Frente-Costa* e *Ângulo de Elevação/tilt*), a frequência exata de operação (*Freq_Medida_DT_MHz*). A Figura 1 indica o *pipeline* de processamento com IA, abrangendo desde a engenharia de dados e treinamento dos algoritmos, até a renderização final da mancha de cobertura 5G.




Fig. 1

ARQUITETURA DO *pipeline* DE PRÉ-PROCESSAMENTO, TREINAMENTO E PREDIÇÃO DE COBERTURA 5G COM IA.

B. Separação de Dados e Prevenção de Memorização

Para garantir que os modelos preditivos baseados em IA realmente aprendessem a física da propagação e não apenas memorizassem as coordenadas específicas, foi aplicado o método *Leave-One-Antenna-Out*.

A separação dos dados foi feita agrupando os identificadores das ERBs. 15% das antenas únicas (totalizando 36 transmissores) foram completamente isoladas para atuar como o conjunto de teste cego (avaliação final). O subconjunto das 85% de antenas restantes foi então separado em treinamento (utilizando 80% desse subconjunto) e validação interna (20% desse subconjunto). Assim, os modelos foram forçados a inferir o sinal de antenas inéditas, validando sua generalização.

C. Arquiteturas Preditivas Avaliadas

O estudo confrontou um modelo físico normativo contra três arquiteturas de inteligência artificial:

- **Modelo Determinístico (ITU-R P.1812-6):** Utilizado como linha de base teórica, as simulações deste modelo

foram processadas através da biblioteca de código aberto Py1812 [17]. O motor de cálculo extraiu perfis topográficos 3D passo a passo (30m de resolução), avaliando os mecanismos de difração e espalhamento. Para refletir os sistemas reais, o modelo incorporou o padrão direcional de antena 3D da 3GPP (computando a divergência exata de azimute e *downtilt*).

- **XGBoost:** Utilizado como o padrão-ouro clássico para dados tabulares espaciais. A busca pelas melhores configurações do algoritmo foi automatizada usando a biblioteca *Optuna*. Para forçar o modelo a extrair as lógicas de atenuação global em vez de superajustar regras para coordenadas geográficas específicas, a profundidade máxima das árvores de decisão foi intencionalmente limitada.
- **MLP:** Uma arquitetura Multilayer Perceptron (MLP) estruturada em PyTorch, com ativações SiLU e *Dropout*. Esta rede foi construída com uma estrutura semelhante à da rede quântica para servir como uma base de comparação justa: caso o modelo híbrido apresentasse superioridade, seria possível confirmar que o ganho de desempenho foi resultado direto do processamento quântico e não de uma vantagem estrutural.
- **Rede Neural Híbrida Quântico-Clássica (HQNN):** Arquitetura implementada através da integração do PyTorch com o PennyLane [12]. Uma sub-rede clássica reduz a dimensionalidade dos dados e, no circuito quântico, a informação é embutida nos *qubits* via *Angle Embedding*. O processamento ocorre em camadas fortemente emaranhadas (*Strongly Entangling Layers*), sendo a saída extraída pela medição da expectativa no eixo Pauli-Z e convertida em RSRP por uma camada clássica final.

D. Ambiente de Execução e Validação OOD

Para evitar a extrapolação catastrófica ao avaliar dados Fora da Distribuição ou *Out-of-Distribution* (OOD) no mapa contínuo, a camada final do MLP e da Rede Híbrida recebeu uma função tangente hiperbólica (*tanh*) escalonada. Essa técnica restringiu fisicamente as previsões ao intervalo de -156 dBm a -31 dBm (baseando-se na norma 3GPP TS 38.133 [13]).

O treinamento utilizou o otimizador AdamW com regularização por decaimento de pesos. Visando eficiência, os modelos clássicos foram treinados em GPU e a HQNN em CPU. Em contrapartida, devido à extrema exigência de memória, a simulação do modelo determinístico ITU-R P.1812 e as inferências espaciais operaram em um servidor dedicado multicore (48 *threads*) de 128 GB de RAM.

Na etapa final, os algoritmos geraram uma malha contínua (*grid*) de 30x30 metros de resolução. O cruzamento (tolerância de 40m) dessa malha sintética contra as 36 antenas inéditas do conjunto de teste cego resultou no erro residual calibrado, garantindo uma avaliação real da generalização espacial dos modelos.

IV. RESULTADOS E DISCUSSÃO

A avaliação de desempenho dos modelos foi conduzida sob o rigoroso paradigma de generalização espacial cega (OOD). A validação cruzou as previsões dos algoritmos exclusivamente

contra as medições de DT das 36 ERBs inéditas, filtradas a uma tolerância máxima de distanciamento de 40 metros. Este cenário isolou a capacidade algorítmica de reproduzir a física da propagação de rádio em 8.155 pontos de validação estrita.

A. Desempenho Preditivo e Análise de Generalização Espacial

O ranqueamento de desempenho algorítmico foi estabelecido prioritariamente através da figura de mérito de Raiz do Erro Quadrático Médio (RMSE). A Tabela I sumariza os resultados globais obtidos pelas Inteligências Artificiais avaliadas em cada etapa metodológica.

TABELA I
RESULTADOS DOS MODELOS DE IA NAS ETAPAS DE VALIDAÇÃO (MÉDIA $\pm$ DESVIO PADRÃO).

Modelo	RMSE K-Fold (dB)	RMSE Group K-Fold (dB)	RMSE Calibrado (dB)	Viés (Bias) (dB)
Árv. Decisão	5,85 $\pm$ 0,12	10,28 $\pm$ 0,63	11,48 $\pm$ 0,10	5,77 $\pm$ 0,13
MLP	3,56 $\pm$ 0,09	9,43 $\pm$ 0,41	12,16 $\pm$ 0,11	4,83 $\pm$ 0,13
HQNN	6,03 $\pm$ 0,07	9,32 $\pm$ 0,35	11,47 $\pm$ 0,10	5,49 $\pm$ 0,13
XGBoost	5,79 $\pm$ 0,10	8,68 $\pm$ 0,50	10,83 $\pm$ 0,09	6,28 $\pm$ 0,12

A Tabela I revela uma armadilha metodológica crítica na radiopropagação. Na calibração aleatória (*K-Fold*), o MLP obteve o menor erro aparente (RMSE de 3,56 dB). Contudo, na validação cruzada espacial (*GroupK-Fold*), seu erro saltou para 9,43 dB e, no teste cego com ERBs inéditas, atingiu 12,16 dB (pior desempenho geral). Esse fenômeno sugere a ocorrência de um severo vazamento espacial (*spatial leakage*): a causa mais plausível é que a arquitetura densa do MLP memorizou coordenadas de treinamento, embora limitações de capacidade ou otimização do modelo também possam ter contribuído para a falha em abstrair os padrões físicos de atenuação.

Em contrapartida, o modelo XGBoost demonstrou sua robustez característica para dados tabulares, alcançando o melhor resultado com o menor RMSE Calibrado (10,83 dB). A Figura 2 ilustra a importância de variáveis (*Feature Importance*) extraída do modelo XGBoost, comprovando que grandezas físicas essenciais (frequência de operação, distância e elevação do terreno) foram decisivas para as previsões do algoritmo, afastando a hipótese de uma tomada de decisão enviesada por parâmetros de localização arbitrários.

B. A Vantagem da Arquitetura Híbrida Quântica

Avaliando o teste cego, o modelo HQNN obteve um RMSE Calibrado de 11,47 $\pm$ 0,10 dB, superando de forma consistente a rede neural clássica (MLP) equivalente, que registrou 12,16 $\pm$ 0,11 dB. A análise de incerteza amostral por *bootstrapping* com 1000 iterações (Tabela I) atesta a significância estatística desta melhoria, visto que os intervalos de confiança a 95% de ambos os modelos não apresentam sobreposição. O resultado corrobora a hipótese de que o mapeamento de variáveis clássicas para o espaço de Hilbert, processado através da codificação angular e do emaranhamento de *qubits*, entrega uma expressividade matemática mais robusta para capturar a não linearidade da propagação fora de distribuição, mitigando o sobreajuste severo sofrido pelas camadas densas clássicas.




Fig. 2

IMPORTÂNCIA DE VARIÁVEIS (*Feature Importance*) DO MODELO XGBOOST NO PROCESSO DE PREDIÇÃO DE SS-RSRP, DEMONSTRANDO O PESO DE CADA ATRIBUTO AVALIADO SOBRE O CONJUNTO DE VALIDAÇÃO INTERNA (*hold-out* DE 20%).

C. Análise de Viés Sistemático (*Bias*) e Calibração

A análise do conjunto de teste cego revelou um comportamento sistemático consistente nas previsões de todos os algoritmos avaliados. Independentemente da natureza matemática da arquitetura, todos os modelos apresentaram um viés estrito entre +4,8 dB e +6,3 dB, prevendo sinais sistematicamente mais fortes do que os mensurados no DT nas áreas ocultadas.

Como esse distanciamento foi uniforme, é provável que o fenômeno reflita variações físicas ausentes nas bases teóricas, como inclinações mecânicas não cadastradas ou sombreamento severo por folhagem. No entanto, características inerentes ao conjunto de dados e premissas dos modelos também podem ter contribuído para esse viés sistemático. Matematicamente, a métrica de RMSE Calibrado é obtida subtraindo-se o viés médio (*Bias*) de todas as previsões individuais antes de computar o erro quadrático. Essa figura de mérito é preferível nesta análise comparativa pois isola a variabilidade aleatória residual, a capacidade intrínseca da IA em modelar as flutuações estocásticas de sombreamento (*shadow fading*), desconsiderando erros de calibração global, como desalinhamento de potência de transmissão ou perdas não contabilizadas em cabos. No entanto, reconhece-se que ao subtrair esse viés sistemático, oculta-se uma parcela do erro bruto que estaria presente e seria relevante em um cenário de implementação prática direta. O ajuste preditivo do XGBoost para o erro residual é demonstrado na Função de Distribuição Acumulada (CDF) da Figura 3.

D. Comparação de Eficiência com o Modelo ITU-R P.1812-6

Por fim, os modelos de IA foram contrastados contra a simulação determinística direcional da norma ITU-R P.1812. Em condições idênticas de validação, a simulação normativa obteve um RMSE Calibrado de 15,17 dB, apresentando um *bias* conservador de -12,82 dB. Os modelos baseados em




Fig. 3

FUNÇÃO DE DISTRIBUIÇÃO ACUMULADA (CDF) DO ERRO ABSOLUTO DE PREDIÇÃO DO XGBOOST, OBTIDO POR MEIO DO PROTOCOLO DE VALIDAÇÃO ESPACIAL CEGA (*Leave-One-Antenna-Out*).

dados (como XGBoost e HQNN) reduziram o erro residual preditivo.

Mais além da precisão estatística, o ganho crítico em cenários práticos de engenharia provém da eficiência operacional de inferência da IA. A Tabela II compara os tempos de processamento dos *pipelines* de Inteligência Artificial completos.

TABELA II

COMPARATIVO DE TEMPO DE EXECUÇÃO DOS *pipelines* DE IA AVALIADOS (MÉDIA $\pm$ DESVIO PADRÃO).

Modelo / Ferramenta	Otimização e Treino (min)	Inferência Espacial (min)	Tempo Total (min)
Árvore de Decisão	0,15 $\pm$ 0,03	2,56 $\pm$ 0,05	2,71 $\pm$ 0,04
XGBoost	0,63 $\pm$ 0,05	2,64 $\pm$ 0,04	3,27 $\pm$ 0,07
MLP	17,62 $\pm$ 0,89	2,66 $\pm$ 0,04	20,27 $\pm$ 0,97
HQNN	41,04 $\pm$ 8,02	2,76 $\pm$ 0,05	43,80 $\pm$ 8,89

Sob a complexidade $\mathcal{O}(N_{sites} \cdot (R/res)^2)$, o simulador ITU-R P.1812-6 demanda entre 10 e 12 horas para o processamento da malha urbana, enquanto a etapa de inferência dos modelos de IA é concluída em menos de 3 minutos. A Figura 4 consolida o resultado desta eficiência, exibindo a mancha de cobertura 5G gerada pelo modelo XGBoost em poucos minutos sobre a topologia da cidade. Esse contraste no tempo de execução demonstra que o emprego de modelos de IA viabiliza o planejamento de redes e a análise de interferência em larga escala em regime próximo ao real.

V. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho propôs e validou um *pipeline* computacional baseado em IA para a predição espacial de cobertura 5G (SS-RSRP), contrastando-o com o modelo determinístico ITU-R P.1812-6. Através de uma rigorosa validação espacial cega baseada no isolamento geográfico de 36 antenas inéditas, demonstrou-se que algoritmos orientados a dados são capazes




Fig. 4

RENDERIZAÇÃO ESPACIAL DA MANCHA DE COBERTURA 5G CONTÍNUA
GERADA A PARTIR DA INFERÊNCIA DO MODELO XGBOOST.

de abstrair as complexas leis da radiopropagação em ambientes urbanos densos, superando as ineficiências computacionais dos simuladores tradicionais.

Em termos de desempenho preditivo, o algoritmo XGBoost atingiu o estado da arte com o menor erro preditivo calibrado (10,83 dB), modelando a propagação física e permitindo a mitigação de vieses sistemáticos de infraestrutura. O ganho de eficiência operacional do *framework* mostrou-se altamente expressivo: o tempo de inferência para a renderização da malha vetorial contínua foi reduzido de cerca de 12 horas (exigidas pelo modelo determinístico) para menos de 3 minutos com a IA. Essa agilidade viabiliza o planejamento de redes de nova geração, a otimização de cobertura e a gestão do espectro em tempo quase real.

A pesquisa também explorou a aplicação do Aprendizado de Máquina Quântico como uma alternativa promissora para a modelagem de propagação. A arquitetura híbrida desenvolvida demonstrou maior resiliência contra o vazamento espacial, superando a precisão de sua contraparte neural clássica (MLP) ao reduzir o erro residual em antenas inéditas de 12,16 dB para 11,47 dB. Este resultado oferece indícios práticos favoráveis ao uso de abordagens quânticas em dados reais de telecomunicações. Os testes sugerem que a codificação de variáveis no espaço de Hilbert e o emaranhamento de *qubits* podem proporcionar uma expressividade matemática superior para abstrair as não linearidades do canal de rádio, mitigando o sobreajuste frequentemente observado em redes densas tradicionais.

Como trabalhos futuros, propõe-se expandir o *framework* integrando novos dados de medição para elevar o rigor da generalização espacial (ex: calibrar o algoritmo em uma malha urbana e validá-lo em uma cidade distinta). Isso atestará a robustez da IA frente a novas morfologias, reduzindo potenciais vieses de localidade. Vislumbra-se também a investigação de diferentes estratégias de codificação quântica e portas parametrizadas para aprofundar a otimização de circuitos QML nas

futuras redes móveis.

AGRADECIMENTOS

Este trabalho contou com apoio técnico e fomento à pesquisa pelo Centro de Altos Estudos em Comunicações Digitais e Inovações Tecnológicas (Ceadi), da Agência Nacional de Telecomunicações (Anatel), por meio de Termo de Execução Descentralizada celebrado entre a Agência Reguladora e a Universidade Federal do Rio de Janeiro, no contexto do Projeto nº 4/2024 (53500.060216/2024-35), “Soluções de Inteligência Artificial (IA) voltadas à gestão do espectro”.

REFERÊNCIAS

- [1] M. Vasudevan e M. Yuksel, “Machine Learning for Radio Propagation Modeling: A Comprehensive Survey,” *IEEE Open Journal of the Communications Society*, vol. 5, pp. 5123–5154, 2024.
- [2] A. Seretis e C. D. Sarris, “An Overview of Machine Learning Techniques for Radiowave Propagation Modeling,” *IEEE Transactions on Antennas and Propagation*, vol. 70, no. 6, pp. 3970–3985, 2022.
- [3] S. A. Robinson *et al.*, “Machine Learning Approach for Path Loss Prediction in Urban Drive 5G Network Environments,” *International Journal of Microwave and Optical Technology*, vol. 20, no. 4, pp. 380–386, Jul. 2025.
- [4] A. Abdulkarim *et al.*, “Application of Machine Learning Algorithms to Path Loss Modeling: A Review,” in *2022 5th Information Technology for Education and Development (ITED)*, 2022, pp. 1–6.
- [5] N. Moraitis, L. Tsipi, D. Vouyioukas, A. Gkioni, e S. Louvros, “Performance evaluation of machine learning methods for path loss prediction in rural environment at 3.7 GHz,” *Wireless Networks*, vol. 27, pp. 4169–4188, 2021.
- [6] İ. Yazıcı, E. Özkan, e E. Gures, “Enhancing Path Loss Prediction Through Explainable Machine Learning Approach,” in *2024 11th International Conference on Wireless Networks and Mobile Communications (WINCOM)*, 2024, pp. 1–6.
- [7] I. F. M. R. Rafie, S. Y. Lim, e M. J. H. Chung, “Path Loss Prediction in Urban Areas: A Machine Learning Approach,” *IEEE Antennas and Wireless Propagation Letters*, vol. 22, no. 4, pp. 809–813, 2023.
- [8] B. Narottama, Z. Mohamed, e S. Aissa, “Quantum Machine Learning for Next-G Wireless Communications: Fundamentals and the Path Ahead,” *IEEE Open Journal of the Communications Society*, 2023.
- [9] B. B. Prajapati e R. B. Prajapati, “Quantum Machine Learning: A Review of Hybrid Classical-Quantum Approaches,” *Quanta*, vol. 15, pp. 1–12, 2026.
- [10] E. Zeydan *et al.*, “Quantum Technologies for Beyond 5G and 6G Networks: Applications, Opportunities, and Challenges,” *IEEE Open Journal of the Communications Society*, 2025.
- [11] A. Farouk, N. A. AbuAli, e S. Mumtaz, “Quantum-Computing-Based Channel and Signal Modeling for 6G Wireless Systems,” *IEEE Communications Magazine*, 2024.
- [12] V. Bergholm *et al.*, “PennyLane: Automatic differentiation of hybrid quantum-classical computations,” *arXiv preprint arXiv:1811.04968*, 2018.
- [13] 3GPP, “TS 38.133: NR; Requirements for support of radio resource management,” *3rd Generation Partnership Project (3GPP)*, Release 18, 2024.
- [14] P. Kadakol, R. Chunamuri, B. Joshi, e K. Mallibhat, “Path Loss Prediction in Wireless Communication Using Machine Learning,” in *2025 6th International Conference for Emerging Technology (INCET)*, 2025, pp. 1–5.
- [15] D. Ranga *et al.*, “Hybrid Quantum-Classical Neural Networks for Efficient MNIST Binary Image Classification,” *Mathematics*, vol. 12, no. 23, p. 3684, Nov. 2024.
- [16] M. Benedetti, E. Lloyd, S. Sack, e M. Fiorentini, “Parameterized quantum circuits as machine learning models,” *Quantum Science and Technology*, vol. 4, no. 4, p. 043001, Nov. 2019.
- [17] I. Stevanovic, “Python implementation of Recommendation ITU-R P.1812,” 2026, implementação da Recomendação ITU-R P.1812-6 desenvolvida no OFCOM. [Online]. Available: <https://github.com/eeveetza/Py1812>
- [18] International Telecommunication Union, “Recommendation ITU-R P.1812-6: A path-specific propagation prediction method for point-to-area terrestrial services in the frequency range 30 MHz to 6 000 MHz,” ITU-R, Geneva, 2021.