

# Modelagem da Perda de Percurso em Comunicações de Missões Críticas

Silvane Priscila A. M. Andrade, Yuri R. Santos, Luís G. S. Costa, Álvaro A. M. Medeiros e Moisés V. Ribeiro

**Abstract**—Este estudo investiga a modelagem da perda de percurso em ambientes urbanos para sistemas de comunicação de missão crítica, como os utilizados por serviços de segurança pública e resposta a emergências. Para essa finalidade, foi realizada uma análise comparativa entre modelos empíricos clássicos, de regressão, probabilísticos e baseados em aprendizagem de máquina. A partir de dados coletados em uma campanha de medição, os resultados indicam que as abordagens de aprendizagem de máquina apresentam o desempenho mais acurado, seguidas pelos modelos empíricos. Em contrapartida, os modelos de regressão e probabilísticos demonstraram precisão inferior. Conclui-se que as técnicas de aprendizagem de máquina são mais adequadas para capturar as complexidades e não-linearidades da propagação de rádio em cenários urbanos.

**Palavras-Chave**—modelos de propagação, radiocomunicações, aprendizagem de máquina, perda de percurso.

## I. INTRODUÇÃO

O Rádio Móvel Digital (do inglês, *Digital Mobile Radio*) (DMR), padrão definido pelo Instituto Europeu de Padrões de Telecomunicações (ETSI) [1], desempenha um papel crucial em aplicações de missão crítica, especialmente em segurança pública e resposta a emergências [2]. O Corpo de Bombeiros Militar do Estado de Minas Gerais (CBMMG) adotou o DMR como base de seu sistema troncalizado, visando maior interoperabilidade, confiabilidade e eficiência operacional em diversos cenários [3]. No entanto, a implementação em Minas Gerais exige um planejamento de rede cuidadoso, dada a topografia variada do estado, o que ressalta a importância de modelos acurados de perda de percurso.

A modelagem da perda de percurso classifica-se em duas abordagens principais: a determinística (ou geométrica) e a empírica. A primeira pode ser extremamente complexa, uma vez que demanda conhecimento detalhado do ambiente, sendo, portanto, mais adequada a ambientes internos. A segunda é baseada em dados medidos e, apesar de não ser tão precisa, demanda poucos parâmetros para sua calibração. Como exemplos de modelos empíricos, destacam-se o Log-Distância [4], o Okumura-Hata [4] e o

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) proc. no 001; Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) proc. no. 445958/2024-3 e 314741/2020-8; Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) proc. no. APQ-04623-22 e Corpo de Bombeiros Militar do Estado de Minas Gerais.

Silvane Priscila A. M. Andrade, Yuri R. Santos, Luís G. S. Costa, Álvaro A. M. Medeiros e Moisés V. Ribeiro são afiliados ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora, Juiz de Fora-MG. E-mails para contato: {priscila.adonay, yuri.santos, luis.costa}@estudante.ufjf.br, {alvaro.medeiros, moises.ribeiro}@ufjf.br.

ITU-R P.1546-6 [5], amplamente utilizados para modelar a perda de percurso. De acordo com [6], a acurácia desses modelos é limitada pela falta de contextualização ao ambiente e pela baixa sensibilidade a obstruções e variações locais ao longo do trajeto.

A literatura aponta que o emprego de técnicas baseadas em Aprendizagem de Máquina (AM) oferece novas perspectivas para modelar ambientes urbanos heterogêneos, os quais apresentam elevada complexidade e não-linearidades, sem demandar maior detalhamento do ambiente [7]. Por exemplo, [8] propõe um modelo híbrido que integra abordagens empíricas e estatísticas com AM, obtendo redução de até 50% no erro relativo e maior robustez diante da diversidade topográfica e urbana. De fato, as técnicas de AM têm demonstrado resultados promissores, devido à sua capacidade de capturar relações não lineares e dinâmicas entre variáveis ambientais e de propagação.

Visando atender à demanda do CBMMG por melhorias no planejamento de sistemas DMR em Minas Gerais, este trabalho investiga a modelagem da perda de percurso na frequência de 150 MHz, utilizada em comunicações de missões críticas. Para isso, são apresentados dados obtidos em uma campanha de medição do indicador de intensidade do sinal recebido (do inglês, *received signal strength indicator*) (RSSI), realizada na cidade de Juiz de Fora-MG, seguidos de uma análise comparativa entre modelos empíricos, tanto clássicos como de regressão e probabilísticos; e modelos baseados em AM. Os resultados obtidos demonstram a eficácia e a superioridade dos modelos de AM para essa faixa de frequência, validando seu potencial para otimizar o planejamento de redes de missão crítica.

## II. CAMPANHA DE MEDIÇÃO

A campanha de medições para caracterizar a propagação do sinal em Juiz de Fora utilizou rádios portáteis MOTOTRBO™ DGP™ 8000e Series [9], pertencentes ao CBMMG. Uma funcionalidade nativa do equipamento permitiu o acesso em tempo real ao RSSI relativo à Estação Rádio Base (ERB). A frequência da portadora é de 150 MHz, com potência de transmissão de 50 W, o ganho da antena transmissora é 8.15 dBi, a altura da antena transmissora Tx é  $h_{Tx} = 20$  m e a altura da antena receptora Rx é  $h_{Rx} = 2$  m. As medições de RSSI foram realizadas em 18 locais distintos, distribuídos ao longo de um percurso de aproximadamente 10 km em linha reta a partir da ERB. Em cada ponto, foram coletadas 70 amostras consecutivas de RSSI, com um intervalo de 3 segundos entre cada registro.

O trajeto foi planejado para contemplar a diversidade morfológica da área urbana, como variações de relevo e de densidade de construções. As coordenadas geográficas dos locais de medição, obtidas através da plataforma *Google Earth*, estão apresentadas na Fig. 1.

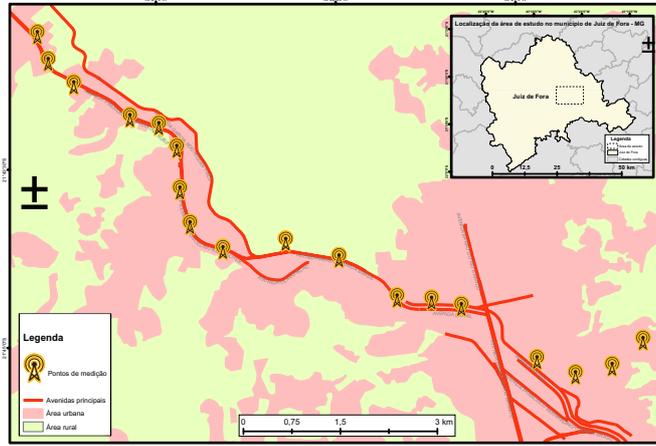


Fig. 1. Locais de medição da potência do sinal na cidade de Juiz de Fora.

### III. MODELAGEM EMPÍRICA

Os modelos empíricos clássicos, que dependem de parâmetros como distância e altura das antenas, apresentam dificuldades em representar com precisão ambientes reais e complexos. Para superar tais limitações, este estudo também analisa modelos de regressão e probabilísticos. Tais abordagens, que representam uma extensão da modelagem empírica, servem como um ponto de comparação intermediário entre a simplicidade dos modelos clássicos e a complexidade das técnicas de aprendizagem de máquina. Os modelos selecionados para esta análise são apresentados a seguir.

#### A. Log-Distância

Este modelo assume que a atenuação aumenta logaritmicamente com a distância e é descrito por

$$PL(d) = PL(d_0) + 10n \log_{10} \left( \frac{d}{d_0} \right) \text{ dB}, \quad (1)$$

em que  $d$  é a distância (em km) na qual se calcula a perda de percurso e  $PL(d_0)$  é a perda em dB na distância de referência  $d_0$ , tipicamente 1 km para macrocélulas. O expoente  $n \in [2, 4]$  indica a taxa de decaimento da potência com a distância [4], sendo  $n = 2$  para espaço livre e  $n = 4$  para ambientes com forte obstrução.

#### B. Okumura-Hata

Este modelo generaliza os resultados experimentais de Okumura para contemplar a faixa de frequência entre 150 MHz e 1500 MHz [4]. Permite calcular a perda de percurso em ambientes urbanos, suburbanos e rurais. A expressão da perda de percurso é dada por

$$PL(d) = \alpha + 26.16 \log_{10} f - 13.82 \log_{10} h_{Tx} - a(h_{Rx}) + (\beta - 6.55 \log_{10} h_{Tx}) \log_{10}(d) \text{ dB}, \quad (2)$$

em que  $\alpha = 69,55$  e  $\beta = 44,9$  são os parâmetros ajustáveis,  $a(h_r)$  corresponde ao termo de correção para a altura da antena Rx em ambientes urbanos e é expresso por

$$a(h_r) = 8.29(\log_{10} 1.54h_{Rx})^2 - 1.1. \quad (3)$$

#### C. Recomendação ITU-R P.1546-6 (08/2019)

Esta recomendação define um modelo empírico para estimar a intensidade do campo elétrico recebido com base na distância, frequência, altura das antenas e características do ambiente. Para refletir condições reais, a recomendação propõe a seguinte expressão:

$$E_{\text{total}}(d, f) = E(d, f) + \Delta E_{h_{Tx}} + \Delta E_{h_{Rx}} + \Delta E_{\text{terreno}} \text{ dB}(\mu\text{V/m}), \quad (4)$$

em que  $E(d, f)$  define o ajuste conforme as características específicas do ambiente,  $\Delta E_{h_{Tx}}$  é o ajuste em função da altura da antena do dispositivo Tx,  $\Delta E_{h_{Rx}}$  representa o ajuste devido à altura da antena do dispositivo Rx, e  $\Delta E_{\text{terreno}}$  é o ajuste em função das características do terreno.

São analisados valores de  $E_{\text{total}}(d, f)$  para trajetos terrestres com  $h_{Tx} = 20$  m. Observa-se que  $E_{\text{total}}$  decresce entre aproximadamente 92 e 58 dB( $\mu\text{V/m}$ ) no intervalo de 1 km a 10 km. A conversão de  $E_{\text{total}}(d, f)$  em densidade de potência e, em seguida, em potência recebida permite calcular a perda de percurso com base nos dados empíricos de campo elétrico.

#### D. Regressão e Probabilidade

No presente trabalho, são analisados os seguintes modelos de regressão [10]: Regressão Linear, *Ridge*, *ElasticNet*, *Bayesian Ridge*, *Automatic Relevance Determination* (ARD) e *Regularized Polynomial Regression* (RPR). As abordagens de Regressão Linear, *Ridge* e *ElasticNet* modelam a relação entre as variáveis de entrada e a perda de sinal, empregando diferentes estratégias de regularização para mitigar o sobreajuste e a multicolinearidade. Por outro lado, os modelos *Bayesian Ridge* e ARD introduzem uma perspectiva probabilística, na qual a relevância dos atributos é inferida por meio de distribuições de probabilidade *a priori*, promovendo uma seleção de características baseada em sua utilidade para o modelo. Por fim, a RPR de grau 5, combinada com a regularização *ElasticNet*, é utilizada para capturar não-linearidades complexas nos dados por meio de transformações polinomiais das variáveis de entrada. Essa expansão permite a representação de padrões mais elaborados na perda de percurso, enquanto a regularização controla o sobreajuste. É fundamental destacar que, embora todos esses modelos sejam lineares em relação aos seus parâmetros, a RPR é a única abordagem, dentre as listadas, capaz de modelar relações não-lineares entre as variáveis de entrada e a saída.

### IV. MODELAGEM BASEADA EM APRENDIZAGEM DE MÁQUINA

A modelagem baseada em AM emprega um conjunto de técnicas diversificadas [11], selecionadas para abranger diferentes abordagens de aprendizado não-linear: *Support Vector Regression* (SVR), *Kernel Ridge*, *Decision Tree*,

*Random Forest*, a rede neural *Multilayer Perceptron* (MLP) e o *Gradient Boosting*. Os métodos de *kernel*, como a SVR e a *Kernel Ridge*, foram escolhidos por sua eficácia em capturar padrões complexos, com a primeira se destacando pela boa generalização em dados limitados e a segunda pelo controle explícito do sobreajuste. As abordagens de árvore, *Decision Tree* e *Random Forest*, oferecem um balanço entre interpretabilidade e robustez; enquanto a árvore única facilita a identificação de atributos relevantes, o conjunto de árvores (*Random Forest*) aprimora a precisão e reduz a variância do modelo. Por fim, a rede MLP é incluída por sua aptidão para aprender com grandes volumes de dados, e o *Gradient Boosting* por sua notória eficácia na correção iterativa de erros, tornando-o robusto a ruídos.

## V. RESULTADOS

Esta seção apresenta a análise comparativa dos modelos de predição de perda de percurso. As curvas foram geradas a partir dos dados de RSSI coletados e dos modelos descritos nas Seções III e IV. A análise considera um intervalo de distância entre 1 e 10 km, com os valores de potência recebida expressos em dBm.

### A. Modelos empíricos clássicos

A Fig. 2(a) exibe os valores de RSSI medidos em cada local, juntamente com as respectivas médias por ponto. Observa-se uma ampla dispersão dos dados, que, no entanto, seguem a tendência esperada de atenuação progressiva com o aumento da distância em relação à ERB. Esse comportamento é atribuído às características complexas do ambiente, como obstáculos (edificações e vegetação) e variações de relevo, que provocam flutuações significativas nos níveis de sinal recebido. Adicionalmente, a figura ilustra as curvas de predição dos modelos Log-Distância, Okumura-Hata e ITU-R P.1546-6 (ITU-R). Fica evidente que o modelo Log-Distância é o que melhor se aproxima da média das medições. Em contrapartida, os modelos Okumura-Hata e ITU-R P.1546-6 apresentam discrepâncias notáveis, sobretudo em distâncias mais curtas.

Para mitigar as discrepâncias observadas na Fig. 2(a), os parâmetros dos modelos empíricos foram otimizados. A Fig. 2(b) apresenta as curvas resultantes para os modelos Log-Distância, Okumura-Hata e ITU-R P.1546-6 calibrados. Essas modificações consistiram no ajuste dos parâmetros dos modelos, utilizando como critério a minimização do erro quadrático médio entre as previsões dos modelos e os valores médios das medidas de RSSI. Conforme ilustrado, os modelos ajustados demonstram uma aderência significativamente maior aos dados. Apesar dessa melhoria, as curvas permanecem suavizadas e não capturam variações abruptas presentes especialmente no intervalo de distâncias entre 3 km e 6 km. Esses resultados reforçam a necessidade de empregar modelos que unifiquem a perda de percurso com fenômenos de larga escala. As análises individualizadas dos modelos Log-Distância, Okumura-Hata e ITU-R P.1546-6 são apresentadas a seguir.

1) *Modelo Log-Distância*: A média do RSSI na distância de referência  $d_0 = 1$  km foi de  $-46,82$  dBm, valor adotado para  $PL(d_0)$ . O expoente de perda de percurso ( $n$ ) foi otimizado por meio de mínimos quadrados não lineares, resultando em  $n = 2,76$ , valor compatível com a propagação em ambientes urbanos. Adicionalmente, avaliou-se a inclusão de um deslocamento vertical (*offset*) para minimizar o erro residual. Embora essa abordagem tenha melhorado as métricas de ajuste (como o raiz do erro quadrático médio (do inglês, *root mean squared error*) (RMSE)), ela distorceu o significado físico do expoente  $n$ . Mesmo sem esse ajuste adicional, o modelo Log-Distância apresentou o melhor desempenho entre os modelos empíricos, refletindo uma boa aderência ao cenário real.

2) *Modelo Okumura-Hata*: A perda de percurso foi estimada pela Equação (2), com a correção de altura do receptor dada por (3). Os parâmetros do modelo — frequência ( $f = 150$  MHz) e alturas das antenas transmissora ( $h_{Tx} = 20$  m) e receptora ( $h_{Rx} = 2$  m) — foram mantidos constantes. Embora a curva resultante tenha seguido a tendência geral dos dados, sua aderência aos valores médios foi inferior à do modelo Log-Distância, o que se refletiu em um valor de RMSE superior.

3) *Modelo ITU-R P.1546-6 (08/2019)*: A aplicação do modelo considerou o trecho de 1 a 10 km, com base nas curvas de perda de percurso da ITU-R P.1546-6 [5]. Neste intervalo, o campo elétrico  $E_{total}(d, f)$  foi aproximado por uma função linear decrescente quando  $f = 150$  MHz. A intensidade de campo foi convertida em RSSI, incluindo ajustes para altura das antenas e características do terreno. Embora o modelo ofereça estimativas generalistas, seu desempenho foi limitado pela baixa sensibilidade às variações topográficas locais e pela incapacidade das curvas empíricas refletirem a dinâmica do ambiente urbano real.

Conclui-se que, mesmo após a calibração com dados locais de Juiz de Fora, os modelos empíricos clássicos demonstram limitações intrínsecas para modelar a complexidade e as não-linearidades de ambientes urbanos heterogêneos.

### B. Modelos de regressão, probabilístico e AM

Os modelos de regressão, probabilísticos e baseados em AM foram treinados utilizando as coordenadas de geolocalização como variáveis de entrada e o valor do RSSI medido como saída. Para garantir uma avaliação robusta, os dados de cada um dos 18 pontos de medição foram segmentados em 80% para treinamento e 20% para teste e, durante a fase de treinamento, aplicou-se a validação cruzada  $k$ -fold ( $k = 5$ ) para garantir a consistência estatística.

A Regressão Linear foi implementada utilizando o método de mínimos quadrados. Para mitigar o sobreajuste, o modelo *Ridge* aplicou regularização L2 ( $\alpha = 1,0$ ), enquanto o *ElasticNet* combinou penalizações L1 e L2, com  $\alpha = 1,0$  e balanceamento no padrão do *scikit-learn*. As abordagens bayesianas (*Bayesian Ridge* e ARD) introduziram distribuições *a priori* sobre os coeficientes, com o ARD se destacando por promover uma seleção automática de características ao zerar os pesos de preditores irrelevantes. Por fim, a RPR de grau

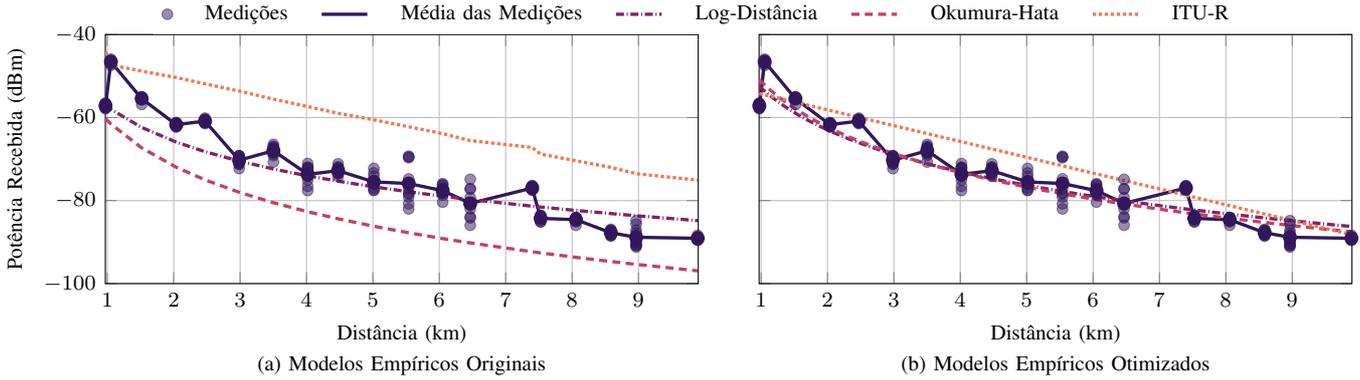


Fig. 2. Comparação entre modelos empíricos clássicos.

5 foi utilizada para capturar relações não-lineares, aplicando a regularização *ElasticNet* para controlar a complexidade do modelo.

A Fig. 3 ilustra o desempenho dos modelos de regressão e probabilísticos. Visualmente, a RPR de grau 5 demonstra a melhor aderência aos dados medidos. Embora as Regressões Linear e *Ridge* capturem a tendência geral de atenuação, elas exibem, por definição, limitações em modelar as não-linearidades locais, especialmente no intervalo entre 2 km e 5 km.

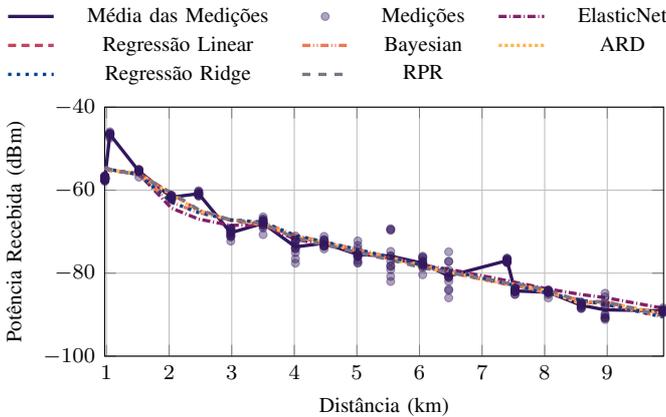


Fig. 3. Comparação entre os modelos de regressão e probabilístico.

Considerando a capacidade e a aplicabilidade dos modelos de AM, têm-se o SVR e o *Kernel Ridge*, ambos utilizam o *kernel radial basis function* (RBF) — o primeiro com normalização dos dados e otimização convexa, e o segundo com regularização fixada em  $\alpha = 1,0$ . O modelo *Decision Tree* foi configurado para ajustes hierárquicos sem restrição de profundidade, enquanto o *Random Forest* utiliza 100 árvores de decisão para reduzir a variância. A rede neural MLP emprega quatro variáveis de entrada, duas camadas ocultas com 50 neurônios cada, função de ativação ReLU nas ocultas e função linear na saída. Já o *Gradient Boosting* adota estimadores sequenciais do tipo árvore de decisão, com profundidade limitada e taxa de aprendizado de 0,1, ajustando iterativamente os resíduos a fim de convergir aos valores alvo.

Os resultados, apresentados na Figura 4, revelam que, com exceção da SVR, as técnicas de AM foram capazes de modelar

com eficácia as complexidades não-lineares do ambiente urbano. Essa capacidade de adaptação a cenários dinâmicos confirma os modelos de AM como ferramentas poderosas, aptas a complementar ou mesmo superar as abordagens empíricas clássicas na tarefa de prever a perda de percurso com maior acurácia.

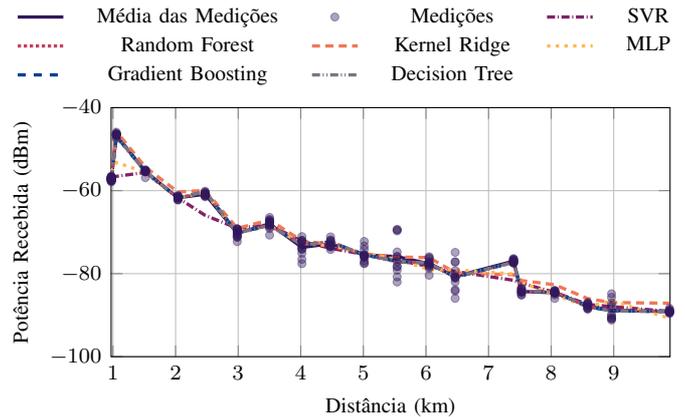


Fig. 4. Comparação entre os modelos baseados em AM.

### C. Análise Comparativa

Para realizar uma análise comparativa quantitativa entre os modelos considerados, os parâmetros RMSE dado por  $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$ , erro médio absoluto (do inglês, *mean absolute error*) (MAE) expresso por  $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$  e o índice de correlação dado por  $\rho = \frac{\sum_{i=1}^n (y_i - \bar{y})(\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2}}$ . Note que  $n$  é o número total de amostras;  $y_i$  é o valor real (medido) da  $i$ -ésima amostra;  $\hat{y}_i$  é o valor previsto pelo modelo para a  $i$ -ésima amostra;  $\bar{y}$  é a média dos valores reais, ou seja,  $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$ ; e  $\bar{\hat{y}}$  é a média dos valores previstos, ou seja,  $\bar{\hat{y}} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i$ .

A Tabela I apresenta os valores das métricas utilizadas na análise comparativa quantitativa entre os modelos projetados. Entre os modelos empíricos clássicos, o Log-Distância destacou-se por apresentar o menor erro médio, mesmo sem otimização adicional. Embora sua versão otimizada, com aplicação de *offset*, tenha melhorado as métricas avaliadas, a interpretação física do parâmetro  $n$  ficou comprometida,

indicando que a alteração descaracterizou o comportamento típico da atenuação.

Dentre os modelos de regressão e probabilísticos analisados, a combinação da RPR de grau 5 com a *ElasticNet* apresentou o melhor desempenho, alcançando o menor valor de RMSE, um MAE moderado e o maior índice de correlação. Isso evidencia a capacidade desse modelo em capturar tanto a tendência geral de atenuação do sinal com a distância quanto variações locais, por ser o único dessa classe capaz de modelar explicitamente relações não lineares.

Em relação aos modelos baseados em AM, conforme detalhado na Tabela I, o modelo com a técnica SVR apresentou o pior desempenho, inclusive inferior ao de alguns modelos empíricos clássicos. Em contraste, as demais técnicas baseadas em AM superaram os demais modelos avaliados, com destaque especial para os algoritmos *Decision Tree*, *Random Forest* e *Gradient Boosting*. Essas técnicas apresentam alta capacidade para lidar com as complexidades e não-linearidades típicas de ambientes urbanos heterogêneos, resultando em estimativas mais precisas do RSSI, mesmo na presença de obstáculos e variações topográficas.

TABELA I  
COMPARAÇÃO ENTRE OS DIFERENTES MODELOS

Parâmetro de Análise	RMSE	MAE	Índice de Correlação
<b>Empírica Clássica</b>			
ITU-R	13.4223	12.8546	0.9494
Okumura-Hata	10.2270	9.4936	0.9518
Log-Distância	4.4268	3.3882	0.9518
ITU-R Otimizado	4.1003	2.9638	0.9494
Okumura-Hata Otimizado	3.8031	3.1011	0.9518
Log-Distância Otimizado	3.6957	3.1697	0.9518
<b>Regressão e Probabilístico</b>			
RPR (grau 5, ElasticNet)	3.2109	2.3405	0.9305
ARD	3.2419	2.2739	0.9292
Regressão Linear	3.2422	2.2770	0.9292
Regressão Ridge	3.2902	2.3934	0.9271
Bayesian Ridge	3.2905	2.3937	0.9271
ElasticNet	3.4901	2.5405	0.9179
<b>Aprendizagem de Máquina</b>			
Decision Tree	1.6187	0.8867	0.9823
Gradient Boosting	1.6206	0.8917	0.9823
Random Forest	1.6245	0.8914	0.9822
Kernel Ridge	2.1866	1.5853	0.9678
MLP	2.6109	1.8198	0.9540
SVR	3.1917	1.8578	0.9314

#### D. Comentários gerais

Os modelos baseados em AM apresentam maior capacidade de aproximação e desempenho superior, especialmente em cenários com disponibilidade de dados históricos. Entre os modelos empíricos, o Log-Distância destacou-se por fornecer o resultado mais representativo, com valor estimado do expoente de propagação  $n$  compatível com ambientes urbanos descritos na literatura.

De maneira geral, os algoritmos de AM alcançam maior eficácia na representação das complexidades ambientais observadas na cidade de Juiz de Fora. Contudo, o modelo Log-Distância constitui uma alternativa eficiente e de baixo custo computacional para estimativas gerais, mesmo sem calibração com dados locais, uma vez que seu valor estimado de  $n$  está dentro do intervalo típico para áreas urbanas. Por

outro lado, é importante ressaltar que os modelos de AM apresentam vantagens substanciais em relação aos demais. Essa superioridade é exemplificada pela significativa redução do RMSE, que passou de 3,6957 dB, obtido com o modelo Log-Distância otimizado, para valores próximos de 1,6 dB com os modelos baseados em AM, *Decision Tree*, *Random Forest* e *Gradient Boosting*.

## VI. CONCLUSÕES

A cobertura dos sistemas de comunicações de missão crítica demanda modelos de propagação acurados. Este trabalho partiu de medições realizadas na cidade de Juiz de Fora para avaliar e propor modelos de perda de percurso para sistemas de comunicação utilizados pelo CBMMG, com base em modelos empíricos clássicos, modelos baseados em regressão e probabilísticos, bem como modelos baseados em aprendizagem de máquina. O estudo demonstrou que os modelos baseados em AM são superiores aos modelos empíricos, de regressão e probabilísticos na modelagem da perda de percurso em ambientes urbanos heterogêneos. Essa superioridade decorre da capacidade das técnicas de AM de capturar relações complexas e não-lineares, adaptando-se às variações espaciais e topográficas típicas de Juiz de Fora. A aplicação desses modelos no sistema de radiocomunicação do CBMMG favorece o planejamento operacional, melhorando a eficiência e a confiabilidade das comunicações críticas. Trabalhos futuros incluem novas campanhas de medições em diferentes relevos e faixas de frequência para validar os modelos propostos.

## REFERÊNCIAS

- [1] "Electromagnetic compatibility and radio spectrum matters (erm); digital mobile radio (dmr); general system design," European Telecommunications Standards Institute (ETSI), Tech. Rep. TR 102 398 V1.5.1, Nov. 2023.
- [2] A. Kumbhar, F. Koohifar, I. Güvenç, and B. Mueller, "A survey on legacy and emerging technologies for public safety communications," *IEEE Commun. Surv. Tutor.*, vol. 19, no. 1, pp. 97–124, 2017.
- [3] S. P. A. M. Andrade, G. C. de Oliveira, A. de Almeida Teixeira, A. M. da Silva, and R. W. Batista, "Projeto básico: Análise e proposta para otimização e ampliação do sistema de radiocomunicação digital do corpo de bombeiros militar de minas gerais," Corpo de Bombeiros Militar de Minas Gerais, Tech. Rep., 5 2021.
- [4] T. S. Rappaport, *Comunicações sem fio : Princípios e Práticas*, 2nd ed. Person Prentice Hall, 2009.
- [5] "Recommendation ITU-R P.1546-6: Method for point-to-area predictions for terrestrial services in the frequency range 30 MHz to 4 000 MHz," Radiocommunication Sector of ITU, Geneva, Switzerland, Recommendation P.1546-6, 8 2019, p Series: Radiowave Propagation.
- [6] C. Phillips, D. Sicker, and D. Grunwald, "A survey of wireless path loss prediction and coverage mapping methods," *IEEE Commun. Surv. Tutor.*, vol. 15, no. 1, pp. 255–270, 2013.
- [7] M. Vasudevan and M. Yuksel, "Machine learning for radio propagation modeling: A comprehensive survey," *IEEE Open Journal of the Communications Society*, vol. 5, pp. 5123–5153, 2024.
- [8] J. Wang, Y. Hao, and C. Yang, "A comprehensive prediction model for vhf radio wave propagation by integrating entropy weight theory and machine learning methods," *IEEE Transactions on Antennas and Propagation*, vol. 71, no. 7, pp. 6249–6256, 2023.
- [9] Motorola Solutions, "Rádios Digitais Bidirecionais MOTOTRBO™ Séries DGP™ 8000e e DGP™ 5000e – Folha de Dados," 2016.
- [10] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Springer, 2009.
- [11] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*, 3rd ed. Sebastopol, CA: O'Reilly Media, 2022.