Análise de ajuste de modelos de cobertura de sinal de rádio para experimentos indoor com multiplos robôs

Campos, P. Sofia * **Cid, L. M. Andre** * **Bessani, Michel** * **Freitas, M. Gustavo** *

* *Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal de Minas Gerais - Av. Antônio Carlos 6627, 31270-901, Belo Horizonte, MG, Brasil,*

(sofiapereiracampos05, andremacielcid)@gmail.com;
(mbessani, gustavomfreitas)@ufmg.br;

Abstract:
As robotic applications in complex environments, such as indoor and confined spaces, continue to increase, effective communication among mobile robots is a critical factor. To enhance communication between mobile robots, it is essential to model the signal transmitted between them and analyze the factors influencing its quality. This article focuses on the analysis and adjustment of radio signal coverage models in indoor environments using multiple robots. By employing an algorithm that divides the environment into regions and determines the most suitable radio propagation model for each region, this article aims to improve the estimation of signal loss under various environmental conditions. Experimental data were collected through tests using mobile robots in corridor-like environments. The results indicate that the TwoRay model proved to be more efficient in representing radio signal power loss along the path for samples closer to the transmitting antenna within a radius of 10m. Additionally, the LogNormal and LogNormal Shadowing models demonstrated greater efficiency at greater distances for the two tested databases.

Resumo:
À medida que aumentam as aplicações robóticas em ambientes complexos, como ambientes indoor e ambientes confinados, a comunicação eficaz entre robôs móveis é um fator crítico. Para melhorar a comunicação entre robôs móveis, é essencial modelar o sinal transmitido entre eles e analisar os fatores que influenciam sua qualidade. Este artigo tem como foco a análise e ajuste de modelos de cobertura de sinal de rádio em ambientes indoor utilizando múltiplos robôs. Ao empregar um algoritmo que divide o ambiente em regiões e determina o modelo de propagação de rádio mais adequado para cada região, este artigo visa melhorar a estimativa de perda de sinal sob diversas condições ambientais. Os dados experimentais foram coletados por meio de testes utilizando robôs móveis em ambientes semelhantes a corredores. Os resultados indicam que o modelo TwoRay provou ser mais eficiente na representação da perda de potência do sinal de rádio ao longo do caminho para amostras mais próximas da antena transmissora em um raio de 10m. Além disso, os modelos LogNormal e LogNormal Shadowing demonstraram ser mais eficientes em distâncias maiores para as duas bases de dados testadas.

Keywords: Multi-Robot Navigation; Radio Signal Propagation Models; Indoor Signal Coverage; Mobile Robots

Palavras-chaves: Navegação Multi-Robô; Modelos de Propagação de Sinal de Rádio; Cobertura de Sinal *Indoor*; Robôs Móveis

1. INTRODUÇÃO

O uso de robôs móveis em atividades de inspeção vem crescendo muito, sendo estes amplamente empregados na automação de processos (Ventrella et al., 2003), em tarefas onde a exposição seria prejudicial aos operadores humanos (Holtman, 2012) e para exploração de locais confinados de difícil acesso para operadores humanos (Ferasoli Filho, 1999; Azpurua et al., 2019).

Durante as inspeções geralmente são utilizadas antenas de rádio para comunicação entre um robô móvel e uma base de controle, principalmente em ambientes *indoor* com limitações de cobertura de sinal.

A cobertura do sinal de rádio é limitada por fenômenos como reflexão, refração, difração, espalhamento e absorção das ondas de rádio (Moura, 2017). Em função dessas limitações, diversos modelos de propagação de sinal de rádio foram propostos na literatura, os quais consideram

características do ambiente e a posição de obstáculos entre as antenas transmissora e receptora para estimar a perda de propagação de sinal de rádio causada por esses fenômenos.

Analisar a perda de propagação de sinal de rádio ao longo do caminho e propor melhorias na rede é fator crucial para a comunicação entre robôs móveis durante atividades de inspeção. Neste contexto, há trabalhos relevantes na literatura. Por exemplo, Saboia et al. (2022) desenvolveram uma solução de rede multicamada para exploração de ambientes confinados com múltiplos robôs. Os resultados mostraram que levar em consideração o ambiente de rádio e o estado da rede é vantajoso para as atividades de exploração.

Fink et al. (2009) propõe com experimentos que é possível caracterizar a propagação de sinal de rádio de um ambiente *indoor* com medições empíricas e que estas podem ser previstas com a utilização de modelos estatísticos e empíricos de propagação de sinal de rádio.

Por fim Clark et al. (2022) compararam diferentes modelos de propagação de sinal de rádio em testes com robôs móveis em ambientes confinados. Os dados medidos durantes os experimentos foram utilizados como entrada para o treinamento de uma rede neural utilizada para previsão de intensidade de sinal de rádio.

Para melhorar a estimativa de perda de potência de sinal de rádio ao longo do caminho em ambientes *indoor* este artigo propõe um algoritmo que divide o ambiente a ser inspecionado em regiões, sendo que para cada região é feita uma análise de qual modelo de propagação de sinal de rádio melhor se ajusta aos dados. O objetivo principal é analisar o quanto as características do ambiente influenciam na perda de potência de sinal de rádio ao longo do caminho e inferir quais modelos são mais aptos para cada característica do ambiente.

Os dados utilizados para a análise foram coletados utilizando robôs móveis em testes em ambientes de corredor que foram apresentados em (Campos et al., 2023). Neste artigo, os autores demostram a importância de utilizar uma estratégia de navegação utilizando múltiplos robôs para melhorar a cobertura de sinal de rádio durante inspeções em ambientes confinados. Determinar qual modelo de propagação de sinal de rádio é mais apto para ser utilizado de acordo com o ambiente inspecionado é crucial para otimizar a estratégia proposta.

Este artigo está dividido em oito seções. A Seção 2 apresenta os modelos teóricos de propagação de sinal de rádio utilizados ao longo deste artigo. A Seção 3 descreve a análise de variância (ANOVA) que é utilizada para comparar diferenças com significância estatística entre os modelos de propagação de sinal de rádio. A Seção 4 introduz os métodos de comparação de ajuste dos modelos que foram utilizados para determinar quais modelos foram mais eficientes para cada região. A Seção 5 apresenta a metodologia de divisão de dados em regiões e comparação dos modelos proposta neste trabalho. A Seção 6 descreve brevemente a coleta dos dados experimentais utilizados para comparação em os modelos. A Seção 7 apresenta os resultados encontrados para diferentes configurações. Finalmente, a Seção 8 conclui o artigo e propões sugestões para trabalhos futuros.

2. MODELOS DE DECAIMENTO DE SINAL DE RÁDIO

Nesta Seção são apresentados os modelos de decaimento de sinal de rádio, cujos ajustes são comparados com os dados medidos nos experimentos envolvendo múltiplos robôs.

2.1 Modelo Log-Normal

De acordo com Rappaport (2009) o modelo Log-Normal é um modelo estatístico para a perda de percurso de um sinal de rádio em função da distância de separação entre as antenas de propagação. O modelo é descrito em (1) e modela a perda de caminho para diferentes ambientes de acordo com o expoente de perda de caminho (n).

$$P(d) = P_0(d0) - 10n\log_{10}(\frac{d}{d_0}), \tag{1}$$

onde $P(d)$ é a potência do sinal a uma distância d do transmissor (dBm), P_0 é a potência do sinal na distância de referência (dBm), n é o expoente do decaimento do sinal (path loss exponent), e $d0$ é uma distância de referência próxima (m).

2.2 Modelo Log-Normal Shadowing

O modelo Log-Normal com sombreamento incorpora uma variabilidade adicional no decaimento do sinal em relação ao modelo Log-Normal , assumindo que a variável aleatória X segue uma distribuição Log-Normal com uma média m_X e um desvio padrão σ_X como descrito em (2).

$$X \sim \mathcal{LN}(m_X, \sigma_X). \tag{2}$$

Nesse caso, a potência do sinal em uma distância d é dada em (3).

$$P(d) = P_0(d_0) - 10n\log_{10}(\frac{d}{d_0}) + X. \tag{3}$$

2.3 Modelo de Dois Raios (Two Ray)

De acordo com Rappaport (2009) o modelo de dois raios é um modelo de propagação que considera o caminho direto percorrido pelo sinal de rádio (equação de Friss - Raio Direto) e uma componente refletida no solo (Raio refletido) como ilustrado pela Figura 1.

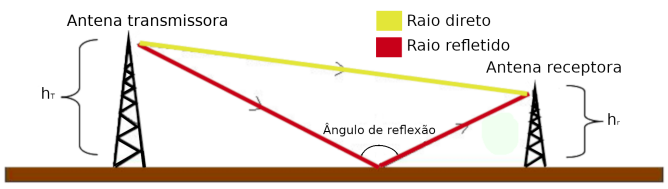

Figura 1. Ilustração do modelo de dois raios. Adaptado de (da Silva Mello, 2006).

O modelo de dois raios é descrito em (4). Quanto menor a distância entre as antenas transmissora e receptora maior é o efeito de reflexão dos raios refletidos no solo.

$$P_R = P_T \cdot G_T \cdot G_R \cdot \left(\frac{h_T \cdot h_R}{d^2}\right)^2, \quad (4)$$

onde P_R é a potência recebida, medida em watts (W), P_T é a potência transmitida, medida em watts (W), G_T é o ganho da antena transmissora, G_R é o ganho da antena receptora, h_T é a altura do transmissor, medida em metros (m), h_R é a altura do receptor, medida em metros (m) e d é a distância entre o transmissor e o receptor, medida em metros (m).

3. ANÁLISE DE VARIÂNCIA (ANOVA)

De acordo com Triola (2008), o método ANOVA ou Análise de variância é um teste estatístico cujo objetivo é comparar a igualdade de três ou mais médias populacionais por meio de análise das variâncias amostrais. Conforme (5) duas hipóteses são comparadas no teste ANOVA, a Hipótese Nula (H0) de que as médias não possuem diferenças significativas e a Hipótese Alternativa (H1) de que as médias entre os grupos possuem diferenças significativas.

$$\begin{cases} H_0 : \mu_1 = \mu_2 \\ H_1 : \mu_1 \neq \mu_2. \end{cases} \quad (5)$$

Neste artigo, o teste ANOVA é utilizado para determinar se existem diferenças significativas entre as médias dos modelos de propagação de rádio descritos na Seção 2 em comparação com os dados experimentais medidos. Para que o teste ANOVA seja válido este deve seguir a premissa de que os dados amostrais populacionais devem ser normais, independentes e homogêneos. Para determinar estas características estão disponíveis na literatura três testes estatísticos que serão descritos nas subseções a seguir.

3.1 Teste de Normalidade de Shapiro-Wilk

Conforme introduzido em (Shapiro and Wilk, 1965), o teste de normalidade compara o grau de desvio em relação à normalidade de um conjunto de dados amostrais com uma distribuição esperada. Neste trabalho a distribuição esperada comparada é a distribuição t-student. O teste de normalidade de Shapiro Wilk calcula um valor (p-valor) que corresponde ao grau de desvios dos dados da normalidade. Valores de p-valor>0.05 indicam que os dados são aproximadamente normais.

3.2 Teste de Independência de Durbin-Watson

Este teste de independência introduzido por Durbin and Watson (1950) avalia autocorrelação entre os resíduos de um conjunto de dados e um modelo. A estatística de Durbin-Watson é representada pela letra d e sua fórmula é representada em (6).

$$d = \frac{\sum_{t=2}^{n}(e_t - e_{t-1})^2}{\sum_{t=1}^{n} e_t^2}, \quad (6)$$

onde e_t são os resíduos do modelo na observação t e n é o número total de observações.

Se d estiver próximo de 2, indica que não há autocorrelação serial nos resíduos. Se d estiver significativamente menor que 2, sugere autocorrelação positiva (resíduos adjacentes estão correlacionados positivamente), enquanto que se estiver significativamente maior que 2, sugere autocorrelação negativa (resíduos adjacentes estão correlacionados negativamente).

3.3 Teste de Homocedasticidade de Fligner-Killeen

Introduzido por Fligner and Killeen (1976), o teste de homocedasticidade analisa a homogeneidade das variâncias entre 2 ou mais grupos de dados diferentes. Neste é feito um teste de hipóteses onde são comparadas as variâncias entre os grupos conforme (7).

$$\begin{cases} H_0 : \sigma_1^2 = \sigma_2^2. \\ H_1 : \sigma_1^2 \neq \sigma_2^2. \end{cases} \quad (7)$$

4. COMPARAÇÃO DOS MODELOS

Para comparar os modelos de decaimento de sinal de rádio e seu ajuste em relação aos dados experimentais medidos são utilizados neste artigo três métricas de comparação descritas nas próximas seções. A primeira, o teste de Tukey visa determinar se existem diferenças estatisticamente significativas entre os modelos e os dados experimentais medidos. Uma vez que existe essa diferença, os resíduos são comparados em termos da segunda e da terceira métrica: o erro quadrático médio(EQM) e o erro absoluto médio(EAM) para determinar qual modelo teve melhor ajuste aos dados medidos de acordo com cada região analisada.

4.1 Teste das Comparações de Tukey

Introduzido por Tukey (1949) o teste das comparações é aplicado para conferir as diferenças entre pares de grupos e seu objetivo é determinar se existem diferenças significativas entre estes pares. Os pressupostos deste teste são os mesmos do ANOVA (normalidade, homocedasticidade e independência) e diferentemente do ANOVA este teste é uma comparação de todos contra todos, podendo determinar as diferenças entre todos os pares de grupos comparados. O teste das comparações de Tukey possui 2 indicativos para as comparações entre os pares: a diferença mínima significativa e o intervalo de confiança. A diferença mínima significativa é um valor mínimo de diferença entre as médias dos grupos comparados que pode ser considerado estatisticamente significativo de acordo com o nível de significância. O intervalo de confiança corresponde a um intervalo que possui uma estimativa da magnitude das diferenças entre as médias dos grupos. De posse desses valores é possível estimar um valor-p que indica o resultado do teste para cada grupo, ou seja, tem seu valor associado a hipótese de que as diferença entre as médias dos grupos é estatisticamente significativa. É usual considerar um nível de significância de 5% ou seja, valores-p menores que 0,05 indicam que as médias entre os grupos são estatisticamente diferentes.

4.2 Comparação de Modelos usando EAM e EQM

De acordo com Hodson (2022), o erro absoluto médio é uma medida de estatística que compara valores medidos

com valores previstos de um modelo em termos absolutos. O cálculo do EAM é feito de acordo com (8). Por tratar com erro em termos absolutos essa métrica é interessante para diminuir os impactos de *outliers* na análise do erro entre os valores previstos pelos modelos e os valores medidos.

$$EAM = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i|, \tag{8}$$

onde n é o número total de observações, y_i são os valores observados e $\hat{y}_i$ são os valores previstos pelo modelo.

Segundo James et al. (2013), o erro quadrático médio (EQM) é a medida mais comumente utilizada para medir o quanto uma previsão ou modelo se ajusta a um conjunto de dados reais. O cálculo do EQM é feito de acordo com (9). O EQM é uma métrica que penaliza valores previstos que estejam muito discrepantes das medidas reais o que é interessante para qualificar o ajuste entre os modelos.

$$EQM = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2, \tag{9}$$

onde n é o número total de observações, y_i são os valores observados e $\hat{y}_i$ são os valores previstos pelo modelo.

Neste artigo as duas métricas EAM e EQM são utilizadas para comparação de ajuste entre os modelos em relação aos dados experimentais medidos.

5. ALGORITMO DESENVOLVIDO PARA COMPARAÇÃO ENTRE OS MODELOS

A estrutura do algoritmo desenvolvido neste artigo para comparação dos modelos de acordo com cada região explorada é ilustrada pela Figura 2. Primeiramente os dados de potência de sinal de rádio medidos são divididos em regiões de interesse, estas com um comprimento e largura definidos (em metros). Após a divisão das regiões de interesse os modelos de propagação de sinal rádio são aplicados. Para comparar o desempenho dos modelos primeiramente é realizado o teste ANOVA, para que seja investigado se houve diferenças significativas entre os modelos para aquela região. Caso não exista diferenças o algoritmo para e exibe uma mensagem. Para que o teste ANOVA realizado seja válido também são aplicados os testes estatísticos de normalidade, homocedasticidade e independência entre os resíduos. Para determinar quais modelos especificadamente são significadamente diferentes o algorítimo executa o teste das comparações de Tukey e retorna os resultados. Além deste teste também são calculadas as métricas de EQM e EAM para determinar qual modelo teve melhor ajuste aos dados medidos.

6. BASE DE DADOS PARA ANÁLISE DE AJUSTE DOS MODELOS

Neste artigo são utilizadas duas bases de dados para comparação entre os modelos. A primeira base de dados está disponível em Campos et al. (2023) onde foi conduzido um experimento com múltiplos robôs em uma ambiente de corredor no prédio da Escola de Engenharia da UFMG.

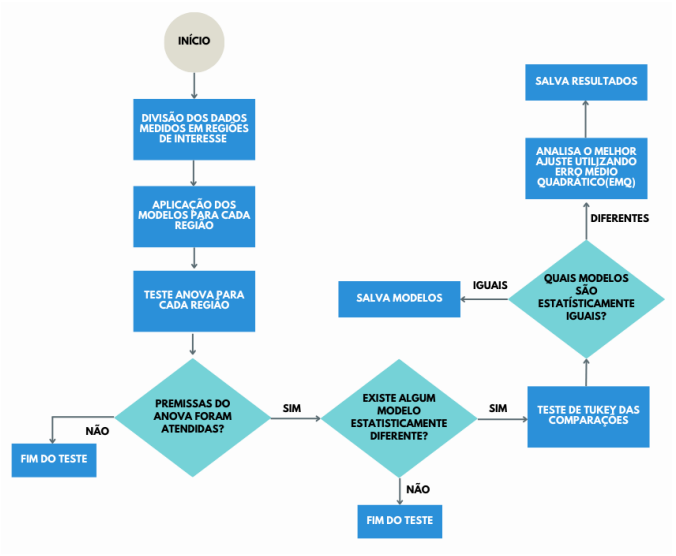

Figura 2. Diagrama esquemático do algoritmo proposto.

Neste experimento foram utilizados dois robôs (Espeleo Robô e Pioneer) e uma antena estação base. Neste experimento o EspeleoRobô foi teleoperado por um corredor até que um determinado limite de distância fosse alcançado, resultando em uma perda completa do sinal de rádio. Depois de atingir o limite de distância, o robô Pioneer foi guiado ao longo do mesmo caminho percorrido pelo EspeleoRobô para amplificar a transmissão do sinal e permitir a retomada da teleoperação até que outro limite de distância fosse atingido, resultando em perda de sinal mais uma vez. Os dados experimentais são ilustrados pela Figura 3.

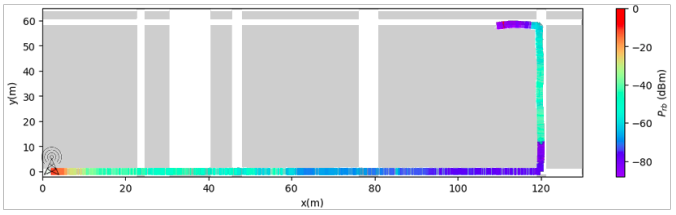

Figura 3. Potência de sinal de rádio (dBm) em função da distância (X-Y) em metros. Adaptado de Campos et al. (2023).

Para avaliar a primeira base de dados, foram realizadas 3 análises com diferentes tamanhos fixos de região de interesse (com diferença de 10m) com o objetivo de avaliar a influência do aumento das regiões no erro.

A segunda base de dados está disponível em Cid (2023), onde foi conduzido um experimento com um robô móvel (EspeleoRobô) e uma antena estação base. Neste experimento o EspeleoRobô foi teleoperado em um ambiente de corredores do prédio do Instituto Tecnológico Vale da Universidade Federal de Ouro Preto. Os resultados obtidos estão representados na Figura 4 e evidenciam o percurso percorrido pelo robô ao longo do mapa e as respectivas potência de sinal de rádio medidas para cada posição ocupada pelo robô. Para avaliar a segunda base de dados, o número de regiões foi definido de forma que cada região cobrisse o máximo possível de informações do ambiente, delimitando interseções entre corredores e salas.

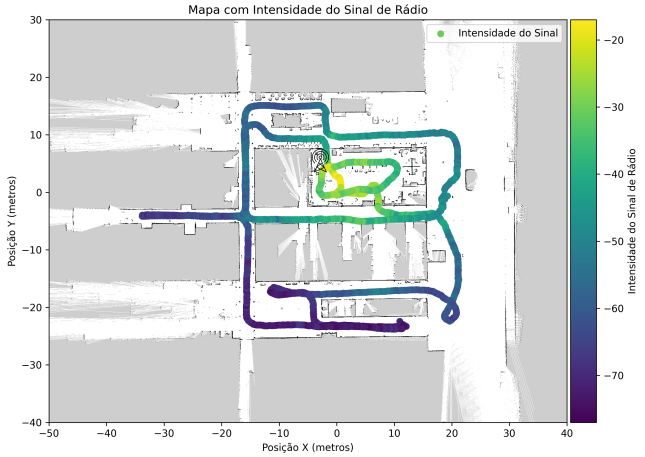

Figura 4. Potência de sinal de rádio (dBm) em função da distância (X-Y) em metros. Adaptado de Cid (2023).

Na primeira base de dados está representado a perda de caminho do sinal de rádio em visada direta e com o auxílio de repetidores de sinal para manutenção da visada direta após uma curva. Já na segunda base de dados está representado um mapa com várias paredes e bifurcações onde o EspeleoRobô percorre vários caminhos tanto em visada direta quanto obstruída.Em ambas as bases de dados, as regiões brancas representam corredores livres, e as regiões cinzas representam áreas inacessíveis ou desconhecidas (conjuntos de salas).

7. RESULTADOS

Conforme descrito na Seção 5 são gerados mapas para as duas bases de dados descritas na Seção 6 de forma a dividir os dados em regiões de interesse cujo tamanho é ajustável. Na primeira análise cada região possui um tamanho fixo (10m × 10m) como ilustrado pela Figura 5. Os resultados encontrados para esta análise estão dispostos na Tabela 1. Os menores índices de erro são destacados em negrito.

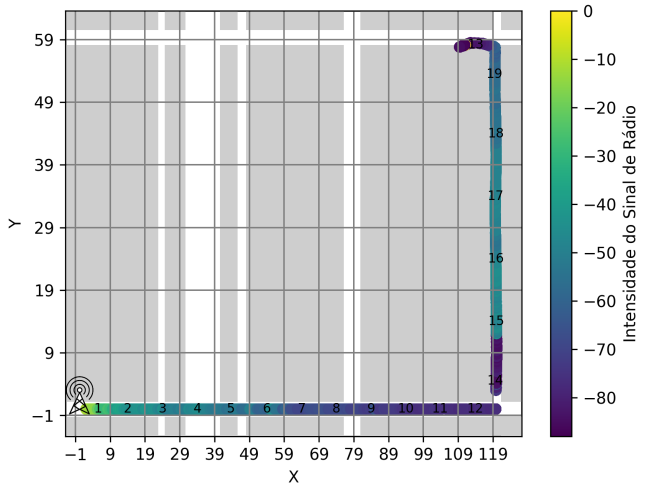

Figura 5. Dados de potência subdivididos em regiões para a primeira base de dados com tamanho fixo (10m × 10m).

Tabela 1. Resultados para a primeira base de dados com tamanho fixo 10m × 10m

Região	TwoRay		LogNormal		LogShadowing	
	MAE	**MSE**	**MAE**	**MSE**	**MAE**	**MSE**
1	0,080	**0,008**	2,93e6	1,15e13	4,84e06	7,36e13
2	0,074	**0,007**	49,270	6,810e3	67,476	1,59+04
3	0,065	**0,004**	0,729	0,832	1,317	7,641
4	0,061	**0,004**	0,063	0,005	0,121	0,053
5	0,063	0,004	0,012	**0,000**	0,019	0,001
6	0,063	0,004	0,003	**0,000**	0,006	**0,000**
7	0,064	0,004	0,001	**0,000**	0,002	**0,000**
8	0,062	0,004	**0,000**	**0,000**	0,001	**0,000**
9	0,062	0,004	**0,000**	**0,000**	**0,000**	**0,000**
10	0,061	0,004	**0,000**	**0,000**	**0,000**	**0,000**
11	0,064	0,004	**0,000**	**0,000**	**0,000**	**0,000**
12	0,064	0,004	**0,000**	**0,000**	**0,000**	**0,000**
13	0,152	**0,082**	0,090	0,090	0,090	0,090
14	0,076	0,012	**0,009**	**0,009**	**0,009**	**0,009**
15	0,072	0,007	**0,003**	**0,003**	**0,003**	**0,003**
16	0,068	0,005	**0,000**	**0,000**	**0,000**	**0,000**
17	0,068	0,005	**0,000**	**0,000**	**0,000**	**0,000**
18	0,068	0,005	**0,000**	**0,000**	**0,000**	**0,000**
19	0,066	0,004	**0,000**	**0,000**	**0,000**	**0,000**
Média	0,071	0,009	1,54e05	6,05e11	2,54e05	3,87e12

Na segunda análise cada região possui um tamanho de 20m × 20m como ilustrado pela Figura 6. Os resultados encontrados para esta análise estão dispostos na Tabela 2. Para a terceira análise cada região possui tamanho fixo de 30mX30m como ilustrado pela Figura 7 e pela Tabela 3. Estes resultados indicam que para regiões mais próximas da antena transmissora o modelo TwoRay se mostrou mais adequado por tratar as perdas por reflexão no solo. Além disso analisando as médias dos erros é possível perceber que o erro quadrático médio diminui com o aumento da divisão em regiões de interesse. Este resultados confirma a característica do MSE de capturar com mais sensibilidade as variações locais e indicam uma maior robustez da métrica para estimativa do erro. Ao comparar as 3 análises que possuem tamanhos com diferença de 10m para cada análise o erro quadrático médio diminui na maioria dos casos em cerca de 20% com o aumento de regiões de interesse.

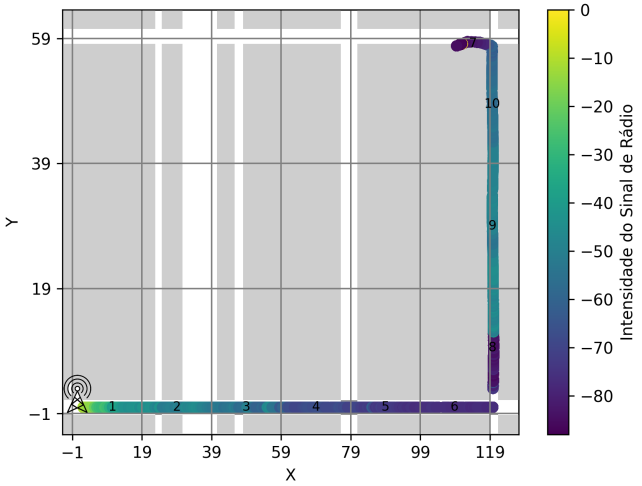

Figura 6. Dados de potência subdivididos em regiões para a primeira base de dados com tamanho fixo (20m × 20m).

O mesmo procedimento é realizado para a segunda base de dados como ilustrado pela Figura 8. Neste caso foram

Tabela 2. Resultados para a primeira base de dados com tamanho fixo 20m × 20m

Região	TwoRay		LogNormal		LogShadowing	
	MAE	**MSE**	**MAE**	**MSE**	**MAE**	**MSE**
1	0,056	**0,006**	2e06	7,85e12	3,61e06	9,88e13
2	0,047	**0,003**	0,413	0,440	0,760	2,797
3	0,053	0,003	0,008	**0,000**	0,014	0,001
4	0,055	0,003	0,001	**0,000**	0,001	**0,000**
5	0,049	0,002	**0,000**	**0,000**	**0,000**	**0,000**
6	0,056	0,003	**0,000**	**0,000**	**0,000**	**0,000**
7	0,152	**0,082**	0,090	0,090	0,090	0,090
8	0,072	0,009	**0,005**	**0,005**	**0,005**	**0,005**
9	0,067	0,005	**0,000**	**0,000**	**0,000**	**0,000**
10	0,065	0,004	**0,000**	**0,000**	**0,000**	**0,000**
Média	0,067	0,012	2e05	7,85e11	3,61e05	9,88e12

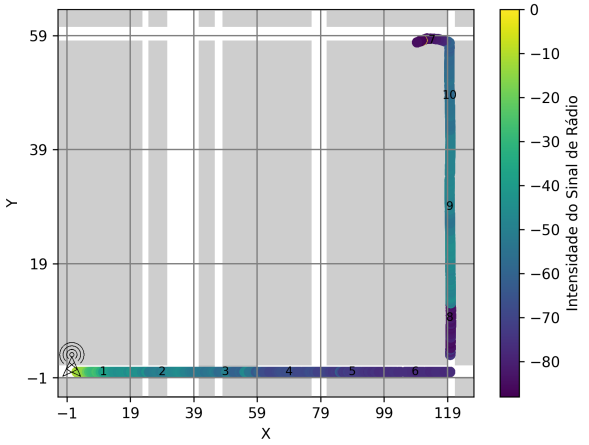

Figura 7. Dados de potência subdivididos em regiões para a primeira base de dados com tamanho fixo (30 × 30)m.

Tabela 3. Resultados para a primeira base de dados com tamanho fixo 30m × 30m

Região	TwoRay		LogNormal		LogShadowing	
	MAE	**MSE**	**MAE**	**MSE**	**MAE**	**MSE**
1	0,042	**0,004**	1,48e06	5,79e12	2,31e06	3,17e13
2	0,040	**0,002**	0,025	**0,002**	0,043	0,013
3	0,046	0,002	0,001	**0,000**	0,001	**0,000**
4	0,060	0,004	**0,000**	**0,000**	**0,000**	**0,000**
5	0,152	**0,082**	0,090	0,090	0,090	0,090
6	0,072	0,009	**0,005**	**0,005**	**0,005**	**0,005**
7	0,064	0,004	**0,000**	**0,000**	**0,000**	**0,000**
Média	0,068	0,015	2,11e05	8,27e11	3,30e05	4,52e12

consideradas regiões de tamanho fixo de 9m × 4m que demonstram ser mais representativas em relação às características do mapa como delimitação de corredores.

Os resultados encontrados estão dispostos respectivamente na Tabela 4. Novamente o modelo TwoRay demonstrou ser mais adequado para regiões próximas da antena em um raio de aproximadamente 10m. Após este raio os modelos Log-Normal e Log-Normal Shadowing demonstraram serem mais eficientes com pouca significância estatística de diferenças entre eles.

8. CONCLUSÃO

Este artigo investigou a aplicação de modelos de propagação de sinal de rádio para melhorar a comunicação entre robôs móveis em ambientes desafiadores, como corredores

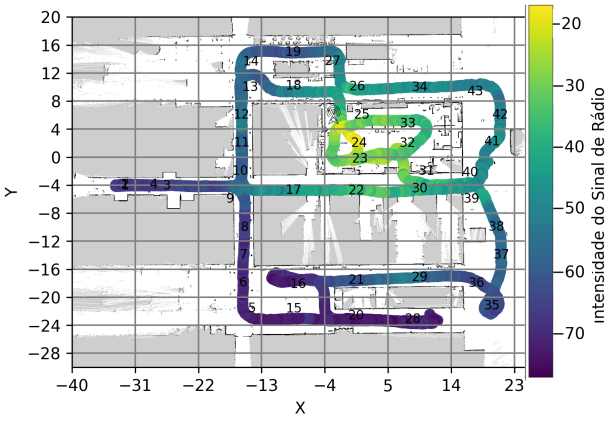

Figura 8. Dados de potência de sinal subdivididos em regiões para a segunda base de dados.

Tabela 4. Resultados para todas as regiões para a segunda base de dados

Região	TwoRay		LogNormal		LogShadowing	
	MAE	**MSE**	**MAE**	**MSE**	**MAE**	**MSE**
1	0,078	0,006	**0,000**	**0,000**	0,001	**0,000**
2	0,093	0,009	**0,000**	**0,000**	0,001	**0,000**
3	0,072	0,005	0,002	**0,000**	0,003	**0,000**
4	0,099	0,010	0,001	**0,000**	0,001	**0,000**
5	0,092	0,009	0,001	**0,000**	0,002	**0,000**
6	0,112	0,013	0,003	**0,000**	0,004	**0,000**
7	0,121	0,015	0,006	**0,000**	0,007	**0,000**
8	0,131	0,017	0,014	**0,000**	0,019	0,001
9	0,113	0,014	0,021	**0,001**	0,033	0,003
10	0,143	0,020	0,034	**0,001**	0,064	0,010
11	0,125	0,016	0,035	**0,001**	0,054	0,007
12	0,114	0,013	0,024	**0,001**	0,033	0,002
13	0,105	0,011	0,013	**0,000**	0,021	0,001
14	0,101	0,010	0,007	**0,000**	0,011	**0,000**
15	0,072	0,005	0,003	**0,000**	0,007	**0,000**
16	0,100	0,010	0,010	**0,000**	0,020	0,001
17	0,093	**0,011**	2,765	21,651	5,888	147,090
18	0,287	0,096	0,216	**0,081**	0,522	1,391
19	0,161	0,027	0,023	**0,001**	0,039	0,003
20	0,090	0,008	0,003	**0,000**	0,006	**0,000**
21	0,123	0,015	0,017	**0,000**	0,041	0,006
22	0,270	**0,073**	53,564	3,98e3	87,750	1,87e4
23	0,038	**0,003**	7,53e9	2,47e21	9,53e9	3,91e21
24	0,024	**0,003**	2,53e10	3,64e22	9,75e9	5,14e21
25	0,336	**0,115**	56,146	5,59e3	56,738	8,92e3
26	0,265	**0,073**	0,783	0,775	1,058	2,047
27	0,171	0,031	0,082	**0,009**	0,097	0,015
28	0,087	0,008	0,002	**0,000**	0,004	**0,000**
29	0,138	0,019	0,010	**0,000**	0,017	0,001
30	0,245	**0,077**	1,185	3,741	1,218	5,534
31	0,112	**0,016**	2,252	10,376	4,248	73,858
32	0,093	**0,010**	11,937	3,62e2	20,202	1,41e3
33	0,116	**0,015**	1,626	5,085	3,477	76,413
34	0,099	**0,011**	0,126	0,026	0,193	0,107
35	0,083	0,007	0,001	**0,000**	0,001	**0,000**
36	0,102	0,011	0,002	**0,000**	0,004	**0,000**
37	0,088	0,008	0,002	**0,000**	0,003	**0,000**
38	0,090	0,008	0,004	**0,000**	0,007	**0,000**
39	0,118	0,015	0,020	**0,001**	0,021	**0,001**
40	0,087	0,008	0,022	**0,001**	0,055	0,014
41	0,122	0,015	0,008	**0,000**	0,016	**0,000**
42	0,109	0,012	0,005	**0,000**	0,008	**0,000**
43	0,080	0,007	0,008	**0,000**	0,012	**0,000**

e espaços confinados. Os resultados demonstraram que a escolha adequada do modelo de propagação é crucial para otimizar a qualidade da comunicação, especialmente em diferentes regiões do ambiente. O modelo TwoRay obteve melhor ajuste em regiões próximas à antena transmissora delimitadas por um raio de cerca de 10m, enquanto que os modelos LogNormal e LogNormalShadowing mostraram ser mais eficientes em distâncias maiores da antena transmissora. Essas descobertas são essenciais para o desenvolvimento de estratégias de comunicação para comando de múltiplos robôs. Além disso, o algoritmo proposto para comparação entre os modelos oferece uma abordagem sistemática para avaliar e selecionar o modelo mais adequado para cada situação. A divisão do ambiente em regiões demonstrou ser uma boa estratégia para capturar as variações locais de potência de sinal de rádio e a métrica MSE mostrou ser mais robusta para ilustrar essas variações.

Apesar de promissores, os resultados obtidos estão diretamente relacionados com o ambiente de testes utilizado, não podendo ser estendidos para outros ambientes com características distintas. Além disso, estes resultados também não levam em consideração a presença de obstáculos e sua influência na perda de propagação de sinal de rádio.

Como sugestões para trabalhos futuros seria interessante adicionar mais modelos de propagação de sinal de rádio ao algoritmo como o modelo KnifeEdge, que leva em consideração a presença de obstáculos no ambiente. Além disso, seria interessante também avaliar qual seria o número mínimo e máximo de regiões necessárias para ilustrar adequadamente as variações locais dos dados, e por fim realizar uma série abrangente de testes com múltiplos robôs utilizando a metodologia proposta.

AGRADECIMENTOS

Este trabalho foi parcialmente financiado pela Vale S.A., Instituto Tecnológico Vale (ITV), Universidade Federal de Minas Gerais (UFMG), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), e Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG).

REFERÊNCIAS

Azpurua, H., Rocha, F., Garcia, G., Santos, A.S., Cota, E., Barros, L.G., Thiago, A.S., Pessin, G., and Freitas, G.M. (2019). Espeleorobô - a robotic device to inspect confined environments. In *2019 19th International Conference on Advanced Robotics (ICAR)*. IEEE.

Campos, S.P., Cid, A.L.M., Vangasse, A.D.C., Júnior, G., Baião, J., Pimenta, L., Barros, L., Pessin, G., and Freitas, G. (2023). Navigation strategy with multi-robots in confined environments to improve radio signal coverage. In *2023 Latin American Robotics Symposium (LARS), 2023 Brazilian Symposium on Robotics (SBR), and 2023 Workshop on Robotics in Education (WRE)*. IEEE.

Cid, A.L.M. (2023). *Planejamento de Caminhos e Exploração para Robôs Móveis com Base na Intensidade do Sinal de Rádio*. Dissertação de mestrado, Programa de Pós-Graduacão em Instrumentacão, Controle e Automacão de Processos de Mineracão (PROFICAM) Escola de Minas, Universidade Federal de Ouro Preto (UFOP), Ouro Preto.

Clark, L., Edlund, J.A., Net, M.S., Vaquero, T.S., and Agha-mohammadi, A.a. (2022). Propem-l: Radio propagation environment modeling and learning for communication-aware multi-robot exploration. *arXiv preprint arXiv:2205.01267*.

da Silva Mello, L.A.R. (2006). *Redes de Acesso em Banda Larga Utilizando Sistemas VSAT e WiFi*. Ph.D. thesis, PUC-Rio.

Durbin, J. and Watson, G.S. (1950). Testing for serial correlation in least squares regression: I. *Biometrika*, 37(3–4), 409–428.

Ferasoli Filho, H. (1999). *Um robô móvel com alto grau de autonomia para inspeção de tubulações*. Ph.D. thesis, Universidade de São Paulo, São Paulo.

Fink, J., Michael, N., Kushleyev, A., and Kumar, V. (2009). Experimental characterization of radio signal propagation in indoor environments with application to estimation and control. In *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2834–2839. IEEE.

Fligner, M.A. and Killeen, T.J. (1976). Distribution-free two-sample tests for scale. *Journal of the American Statistical Association*, 71(353), 210–213.

Hodson, T.O. (2022). Root-mean-square error (rmse) or mean absolute error (mae): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487.

Holtman, M.S. (2012). *Robô móvel para inspeção de materiais perigosos*. Trabalho de conclusão de curso (graduação), Universidade Tecnológica Federal do Paraná.

James, G., Witten, D., Hastie, T., and Tibshirani, R. (2013). *An introduction to statistical learning*, volume 112. Springer.

Moura, M.B. (2017). *Melhoria na Predição de Cobertura de Sinal Rádio Móvel Outdoor-Indoor na Faixa de 700 MHz através de Redes Neurais*. Dissertação de mestrado, Universidade Federal Fluminense, Niterói. Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações.

Rappaport, T.S. (2009). *Comunicações sem Fio: Princípios e Práticas, 2/E*. Pearson Education do Brasil, São Paulo.

Saboia, M., Clark, L., Thangavelu, V., Edlund, J.A., Otsu, K., Correa, G.J., Varadharajan, V.S., Santamaria-Navarro, A., Touma, T., Bouman, A., Melikyan, H., Pailevanian, T., Kim, S.K., Archanian, A., Vaquero, T.S., Beltrame, G., Napp, N., Pessin, G., and Agha-mohammadi, A.a. (2022). Achord: Communication-aware multi-robot coordination with intermittent connectivity. *IEEE Robotics and Automation Letters*, 7(4), 10184–10191.

Shapiro, S.S. and Wilk, M.B. (1965). An analysis of variance test for normality (complete samples). *Biometrika*, 52(3–4), 591–611.

Triola, M.F. (2008). *Introdução à estatística*. LTC, Rio de Janeiro.

Tukey, J.W. (1949). Comparing individual means in the analysis of variance. *Biometrics*, 5(2), 99.

Ventrella, A., Moscato, L., de Souza, A., dos Santos, M., and Vital, W. (2003). Robô móvel aplicado à inspeção em linhas de transmissão. In *Anais do II Congresso de Inovaçao Tecnológica em Engenharia Elétrica*, volume 1.