

Sondagem Inteligente de Enlaces LoRa para Redução de Consumo Energético em Redes de Monitoramento Ambiental na Floresta Amazônica

Alexandre S. Tupinambá¹, Paulo V. F. Melo¹, Pedro Souza¹, Diogo S. Moreira¹,
Ronaldo Martins¹, Gilmara Santos¹, Edjair S. Mota¹

¹ Instituto de Computação – Universidade Federal do Amazonas (UFAM)
Av. Gen. Rodrigo Octávio 6200, Coroado – 69080-900 – Manaus – AM – Brasil

{alexandre.tupinamba, paulo.fernandes}@icomp.ufam.edu.br
{pedro.souza, diogo.soares, ronaldo}@icomp.ufam.edu.br
{gilmara, edjair}@icomp.ufam.edu.br

Abstract. *Environmental monitoring in dense rainforests requires reliable and energy-efficient wireless links. In this context, LoRa parameter selection is challenging due to vegetation, irregular terrain, and non-line-of-sight propagation. This paper presents an energy-aware LoRa parameter selection strategy based on short reference probing in the Amazon rainforest. Field measurements collected at the Federal University of Amazonas (UFAM), Brazil, are used to characterize point-to-point links and predict the SNR of candidate configurations without requiring geometric distance during operation. The Huber Regressor achieved the best performance, with MAE = 1.70 ± 0.40 dB and RMSE = 2.14 ± 0.53 dB. The recommended configuration reduced estimated energy consumption by 65.44% compared with an ADR-inspired baseline while preserving robust communication.*

Resumo. *O monitoramento ambiental em florestas densas exige enlaces sem fio confiáveis e energeticamente eficientes. Nesse cenário, a seleção de parâmetros LoRa é dificultada pela vegetação, pelo relevo irregular e pela ausência de linha de visada. Este artigo apresenta uma estratégia de seleção de parâmetros LoRa baseada em sondagens curtas de referência na floresta amazônica. O estudo utiliza medições de campo realizadas no campus da Universidade Federal do Amazonas (UFAM), em Manaus-AM, para caracterizar enlaces ponto a ponto e prever o SNR de configurações candidatas sem exigir a distância geométrica na operação. O Huber Regressor obteve o melhor desempenho, com MAE = $1,70 \pm 0,40$ dB e RMSE = $2,14 \pm 0,53$ dB. A configuração recomendada reduziu o consumo estimado de energia em 65,44% em relação a um baseline inspirado no ADR, preservando comunicação robusta.*

1. Introdução

A urgência climática global e o avanço do desmatamento exigem o monitoramento contínuo e granular de ecossistemas complexos, como a Floresta Amazônica. Nesse contexto, sistemas de suporte à gestão do meio ambiente baseados em dados, apoiados por redes de monitoramento ambiental automático, tornam-se fundamentais para orientar decisões de conservação e de uso sustentável. Em particular, redes de monitoramento ambiental automático vêm sendo empregadas para acompanhar parâmetros microclimáticos,

hidrológicos e de qualidade do ar em áreas extensas e por horizontes de operação de vários anos, muitas vezes com dezenas ou centenas de nós distribuídos em regiões de difícil acesso. Nesses cenários, a capacidade de sondar e configurar enlaces de forma eficiente torna-se crítica para evitar “pontos cegos” persistentes e garantir a continuidade das séries temporais utilizadas em campanhas científicas e em ações de gestão ambiental. Este trabalho tem como foco principal redes de monitoramento ambiental automático na Amazônia, nas quais a longevidade e a confiabilidade dos enlaces LoRa são requisitos centrais.

Para lidar com a variação do canal, o protocolo LoRaWAN utiliza o mecanismo *Adaptive Data Rate* (ADR), responsável por ajustar dinamicamente o fator de espalhamento (*Spreading Factor* - SF) e a potência de transmissão (Tx) [LoRa Alliance 2020]. Contudo, em cenários fortemente estocásticos, como o da Amazônia, o ADR pode apresentar falhas estruturais relevantes [Slabicki et al. 2018, Benkhelifa et al. 2019]. Por ser um mecanismo reativo, projetado com margens conservadoras, o algoritmo pode levar o nó sensor a operar com configurações excessivamente lentas e energeticamente mais custosas, potencialmente reduzindo a autonomia do dispositivo.

Modelos empíricos clássicos de propagação, que tentam prever a qualidade do enlace baseando-se puramente na distância física – como modelos *Log-Distance* – apresentam limitações significativas nestes cenários, uma vez que a obstrução causada por poucos metros de troncos densos pode atenuar o sinal com maior severidade do que centenas de metros em uma clareira [Azevedo and Mendonça 2024].

Para mitigar esse gargalo energético, este trabalho propõe uma abordagem autônoma de seleção de parâmetros orientada por aprendizado de máquina (*Machine Learning* - ML), com baixa complexidade computacional e, portanto, compatível com execução local em nós com recursos computacionais restritos. A solução baseia-se em uma estratégia determinística de sondagem ativa (*probing*): ao enviar um orçamento fixo de pacotes em configurações de referência de longo alcance (SF12 e SF11), o nó obtém uma estimativa do estado instantâneo do enlace por meio das medições de relação sinal-ruído (SNR).

Um modelo de regressão linear robusto processa essa leitura localmente e prevê o SNR para o restante do espaço de busca. Ao incorporar medições locais recentes do canal florestal, o filtro preditivo descarta configurações inviáveis e seleciona configurações menos conservadoras, mas ainda compatíveis com a margem de SNR adotada, explorando canais mais rápidos como largura de banda (BW) de 250 kHz que não são tipicamente exploradas por implementações padrão do ADR.

As principais contribuições deste artigo são:

- **Evidência empírica das limitações de modelos baseados em distância para predição de enlace no cenário avaliado:** Demonstra-se que fórmulas de decaimento orientadas pela distância (*Log-Distance*) resultam em erros médios absolutos (MAE) superiores a 10 dB na Amazônia, o que justifica o emprego de sondagem ativa.
- **Discussão das limitações do baseline inspirado no ADR no cenário avaliado:** Análise do comportamento de adaptação do ADR revelando o excessivo custo de exploração volátil e viés conservador do protocolo padrão.

- **Proposição de um filtro preditivo baseado em Huber Regressor, potencialmente compatível com execução embarcada:** Apresentação de um regressor (Huber) avaliado por validação cruzada espacial (*Leave-One-Distance-Out*), com MAE de 1,70 dB em áreas não mapeadas da floresta.
- **Fornecimento de um procedimento operacional de sondagem e seleção de parâmetros** que pode ser implementado em nós LoRa convencionais, sem necessidade de GPS ou de infraestrutura LoRaWAN centralizada, permitindo a configuração autônoma de enlaces em redes de monitoramento ambiental de larga escala na Amazônia.
- **Evidência de redução estimada de consumo energético** de até 65,44% em relação ao baseline ADR, preservando o critério de operação segura no cenário avaliado.

O restante deste artigo está organizado da seguinte forma: A Seção 2 discute os trabalhos correlatos. A Seção 3 detalha o cenário experimental amazônico e a arquitetura preditiva proposta. A Seção 4 discute as métricas de seleção energética e os resultados em comparação com os algoritmos tradicionais. Por fim, a Seção 5 conclui o trabalho e discute direções futuras.

2. Trabalhos Relacionados

2.1. Parâmetros LoRa, tempo no ar e custo energético

A escolha de SF , BW e potência impacta diretamente o tempo no ar e, portanto, o custo energético por pacote [Semtech Corporation 2015]. Resultados experimentais mostram que parâmetros mais robustos aumentam o consumo, enquanto configurações mais agressivas podem reduzir a confiabilidade [Casals et al. 2017, Bouguera et al. 2018]. Esses resultados motivam estratégias de seleção que considerem explicitamente a energia, em vez de tratarem a parametrização como um ajuste secundário.

2.2. Propagação em vegetação densa e limitações de abordagens baseadas em distância

Em ambientes florestais, a vegetação e a ausência de linha de visada introduzem atenuação adicional e variabilidade espacial, o que dificulta a generalização por meio de modelos geométricos [International Telecommunication Union 2021]. Medições com LoRa em floresta evidenciam grandes variações de RSSI/SNR e desempenho dependente de condições locais [Ferreira et al. 2020, Ansah et al. 2020]. No contexto amazônico, esforços em 915 MHz ainda dependem de hipóteses e de calibração para capturar a heterogeneidade local [Lima et al. 2024], e revisões críticas indicam que a adequação de modelos de propagação em LoRa é altamente sensível ao ambiente e às premissas adotadas [Azevedo and Mendonça 2024]. No LoRaWAN, o mecanismo ADR apresenta limitações de agilidade e viés conservador em cenários altamente variáveis, o que pode elevar o custo energético [Slabicki et al. 2018, Benkhelifa et al. 2019, LoRa Alliance 2020]. Há também uma linha de uso de aprendizado de máquina para estimar qualidade de enlace, sintetizada por Cerar et al. [Cerar et al. 2021].

2.3. Síntese e diferencial do presente trabalho

De forma geral, a literatura cobre: (a) os trade-offs entre parâmetros LoRa e consumo de energia [Semtech Corporation 2015, Casals et al. 2017, Bouguera et al. 2018],

(b) a propagação em vegetação e floresta, incluindo a Amazônia [Ferreira et al. 2020, Lima et al. 2024, International Telecommunication Union 2021], (c) limitações do ADR em cenários variáveis [Slabicki et al. 2018, Benkhelifa et al. 2019, LoRa Alliance 2020] e (d) o uso de aprendizado de máquina para qualidade de enlace [Cerar et al. 2021]. Ainda assim, permanece uma lacuna prática: selecionar parâmetros LoRa em floresta densa com baixo custo de sondagem, sem exigir a distância do enlace na etapa operacional e com decisão explicitamente orientada à eficiência energética. O presente trabalho aborda essa lacuna ao investigar uma estratégia baseada em sondagens curtas por referências, predição supervisionada de SNR e seleção de parâmetros guiada por margem de SNR e custo energético em ambiente amazônico real.

3. Metodologia

3.1. Experimento de campo e aquisição de dados

O conjunto de dados utilizado neste estudo foi obtido em campanhas de medição realizadas em uma área de floresta amazônica densa localizada no campus da Universidade Federal do Amazonas (UFAM), em Manaus–AM, Brasil.

As campanhas foram realizadas em topologia ponto a ponto, sem gateway e sem infraestrutura LoRaWAN. Foram avaliadas sete distâncias de enlace: 110, 150, 190, 280, 340, 400 e 410 m. As distâncias entre os nós foram obtidas a partir das coordenadas geográficas dos pontos de transmissão e de recepção coletadas em campo. Todas as campanhas ocorreram no período noturno, em sessões de longa duração por distância.

A plataforma experimental foi composta por placas Heltec ESP LoRa V3, equipadas com o transceptor Semtech SX1262 e configuradas para operar em 915 MHz. O transmissor e o receptor foram conectados a antenas omnidirecionais Steelbras AP, com ganho nominal de 5,15 dBi. Cada antena foi montada sobre uma placa metálica quadrada de 20 cm, acoplada a uma estrutura com altura regulável, e posicionada a 1,5 m do solo.

Antes da varredura completa dos parâmetros de transmissão, foi realizada uma etapa preliminar de verificação de conectividade, destinada a confirmar a viabilidade do enlace e ajustar a posição final do receptor. Nessa etapa, foi adotada uma configuração de teste robusta com $SF = 12$, $BW = 62,5$ kHz, $Tx = 17$ dBm e $CR = 4/8$.

Após essa etapa, foi iniciada a coleta automatizada. O espaço de parâmetros avaliado foi definido pelo produto cartesiano de $SF \in \{7, 8, 9, 10, 11, 12\}$, $BW \in \{62,5, 125, 250\}$ kHz, $CR \in \{4/5, 4/8\}$ e $Tx \in \{5, 10, 17\}$ dBm, totalizando 108 combinações por distância. Para cada combinação, o transmissor enviou 50 pacotes com carga útil de 10 bytes. O primeiro byte da carga útil foi usado para armazenar o índice do pacote, variando de 0 a 49.

Para cada transmissão, o receptor registrou em um arquivo CSV os parâmetros de rádio, o índice da combinação de parâmetros, o índice do pacote, o status de recepção e as métricas RSSI e SNR. O firmware adotou a seguinte convenção de status: 0 para pacote recebido corretamente, 1 para pacote corrompido e 3 para pacote não recebido. A confiabilidade foi quantificada pela taxa de entrega de pacotes (*Packet Delivery Ratio* – PDR), definida como a razão entre pacotes recebidos corretamente ($Status = 0$) e o total de tentativas de transmissão.

3.2. Preparação do conjunto de dados

Embora a campanha tenha incluído transmissões com $CR \in \{4/5, 4/8\}$, a modelagem final considerou apenas o subconjunto com $CR = 4/5$, mantendo somente as amostras com recepção correta ($Status = 0$), uma vez que o alvo da regressão corresponde ao SNR observado em pacotes efetivamente recebidos. As medições da distância de 400 m também foram excluídas dessa etapa por não apresentarem dados suficientes para a construção consistente das informações de referência utilizadas na entrada do modelo.

Após essa filtragem, os dados foram agregados por combinação de distância, fator de espalhamento, largura de banda e potência de transmissão, isto é, por (d, SF, BW, Tx) . Para cada combinação, foi calculada a mediana do SNR, adotada como variável-alvo, e a mediana do RSSI, utilizada como informação complementar sobre o enlace, de modo a reduzir a influência de flutuações pontuais e valores extremos. Ao final, o conjunto supervisionado incluiu apenas combinações válidas em $CR = 4/5$ e com recepção bem-sucedida nas distâncias de 110, 150, 190, 280, 340 e 410 m, servindo de base para a construção dos atributos e treinamento dos modelos.

3.3. Construção das variáveis de entrada

Para representar o estado do enlace em cada distância, foram definidas duas configurações de referência: *Ref1* ($SF = 12, BW = 125 \text{ kHz}, Tx = 17 \text{ dBm}$) e *Ref2* ($SF = 11, BW = 125 \text{ kHz}, Tx = 17 \text{ dBm}$). Essas configurações foram adotadas como referências por corresponderem a combinações mais conservadoras de transmissão no cenário avaliado. Para cada distância, foram calculadas as medianas de SNR e RSSI observadas nessas duas configurações, de modo a representar a condição local do canal a partir de um pequeno conjunto de transmissões de referência.

Com isso, cada amostra do conjunto supervisionado passou a ser descrita por sete variáveis: SF, BW e Tx da configuração candidata, além das medianas de SNR e RSSI associadas à *Ref1* e à *Ref2*. Em outras palavras, o modelo recebe como entrada tanto os parâmetros da configuração a ser avaliada quanto um resumo do comportamento do enlace nas duas configurações de referência, ambas medidas na mesma distância.

As próprias configurações de referência não foram mantidas no conjunto de saída. Essa decisão evita casos triviais em que o valor a ser previsto poderia ser obtido diretamente a partir das variáveis de entrada. Assim, o conjunto final foi formado apenas pelas combinações candidatas distintas das referências, preservando o papel dessas medições como informação auxiliar para caracterizar o enlace.

Esse procedimento permite condicionar a predição de SNR ao estado local do canal, sem utilizar a distância como variável de entrada na etapa operacional. Dessa forma, a informação geométrica do enlace não precisa ser conhecida pelo modelo no momento da predição, desde que as medições de referência estejam disponíveis.

3.4. Modelagem e protocolo de validação

Foram avaliados cinco modelos de regressão para a predição de SNR: Linear Regression, Bayesian Ridge, Huber Regressor, Support Vector Regression com kernel RBF e Gradient Boosting Regressor. Nos modelos sensíveis à escala das variáveis de entrada, foi aplicada padronização com *StandardScaler* antes do ajuste. Os hiperparâmetros foram ajustados

automaticamente via Optuna em validação cruzada agrupada por distância, minimizando o MAE. O modelo de regressão linear simples foi mantido como referência básica.

A avaliação do desempenho foi conduzida com a estratégia *Leave-One-Distance-Out* (LODO). Em cada iteração, uma distância era separada integralmente para teste, enquanto as demais eram utilizadas para treinamento. Além da configuração com duas referências, também foi realizada uma ablação com apenas uma configuração de referência. No caso com duas referências, as variáveis de entrada foram compostas por SF , BW e Tx da configuração candidata, além das medianas de SNR e RSSI associadas à $Ref1$ e à $Ref2$. No caso com uma referência, foram mantidas apenas as informações associadas à $Ref1$. Essa comparação foi incluída para quantificar o efeito da segunda medição de referência sobre a qualidade da predição.

O desempenho dos modelos foi quantificado por meio do erro absoluto médio (MAE), da raiz do erro quadrático médio (RMSE) e do coeficiente de determinação (R^2). Além dessas métricas, o pipeline também registrou os valores preditos para cada amostra de teste, permitindo a construção das análises gráficas e comparativas apresentadas nas seções seguintes.

3.5. Baselines de predição

Para contextualizar o desempenho do modelo proposto, foram avaliados baselines de predição de SNR sob o mesmo protocolo *Leave-One-Distance-Out* (LODO). Os métodos considerados incluíram *Free-Space Path Loss* (FSPL), *Log-Distance*, *Two-Slope* e um modelo linear multivariado com dependência explícita da distância. Nos modelos baseados em perda de percurso, a predição de SNR foi obtida a partir da potência recebida estimada e de um piso de ruído calibrado por largura de banda em cada iteração do LODO. No modelo multivariado, foram utilizadas como variáveis de entrada a distância em escala logarítmica, o fator de espalhamento, a largura de banda e a potência de transmissão. Esses baselines contrastam com o método proposto, que estima o SNR a partir de medições de referência do próprio enlace, sem usar a distância como variável de entrada na etapa operacional.

4. Resultados

4.1. Predição de SNR

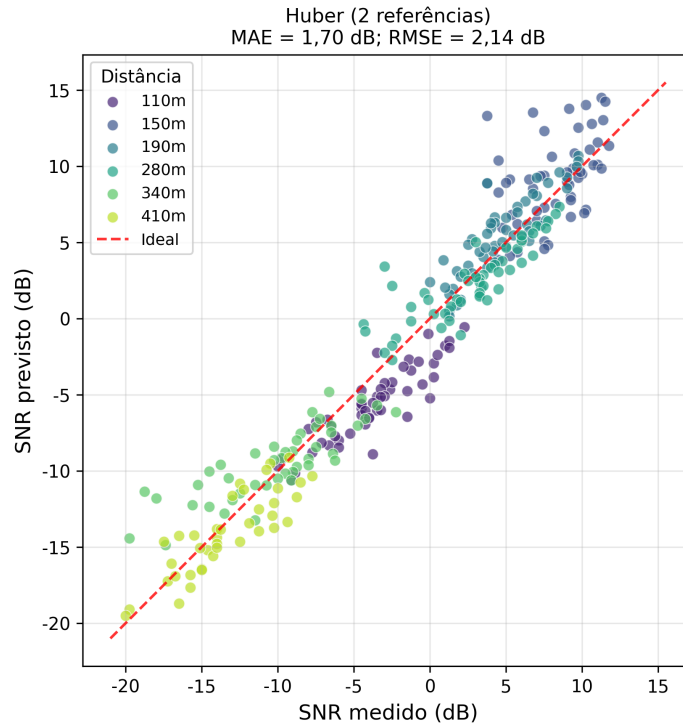
A Tabela 1 apresenta os resultados da validação *Leave-One-Distance-Out* para duas configurações de referência. O Huber Regressor obteve o melhor desempenho entre os modelos avaliados, com $MAE = 1,70 \pm 0,40$ dB e $RMSE = 2,14 \pm 0,53$ dB, e foi adotado como modelo principal nas etapas seguintes. Gradient Boosting e SVR (RBF) apresentaram erros substancialmente maiores, sendo descartados para o restante do pipeline.

A Figura 1 mostra a relação entre os valores medidos e os preditos pelo Huber Regressor com duas referências, com concentração das amostras em torno da diagonal ideal, indicando boa aderência entre predição e observação ao longo das distâncias avaliadas. A inclusão da segunda configuração de referência reduziu o erro médio em todos os modelos: no Huber, o MAE caiu de 3,77 dB para 1,70 dB (redução de 54,8%), com reduções também superiores a 40% em modelos lineares.

Tabela 1. Resultados da validação *Leave-One-Distance-Out* com duas configurações de referência.

Modelo	MAE (dB)	RMSE (dB)
Huber Regressor	1,70 ± 0,40	2,14 ± 0,53
Linear Regression	2,04 ± 0,40	2,49 ± 0,49
Bayesian Ridge	2,07 ± 1,12	2,47 ± 1,10
Gradient Boosting Regressor	3,89 ± 1,34	4,37 ± 1,27
SVR (RBF)	4,11 ± 2,54	4,49 ± 2,38

A comparação com os baselines de predição é apresentada na Tabela 2. O Huber Regressor com sondagem por referências curtas obteve erro substancialmente menor do que todos os métodos dependentes da distância. Entre os baselines, o melhor desempenho foi do modelo linear multivariado, com $MAE = 9,91 \pm 5,08$ dB e $RMSE = 10,15 \pm 4,99$ dB, enquanto Log-Distance, Two-Slope e FSPL apresentaram erros ainda mais elevados. Esses resultados indicam que, no cenário avaliado, medições curtas de referência capturam melhor o estado do enlace do que a distância geométrica isoladamente.

**Figura 1. Relação entre SNR medido e SNR previsto pelo Huber Regressor com duas configurações de referência.**

4.2. Seleção de parâmetros com foco em eficiência energética

A etapa de seleção energética avaliou duas variantes do método proposto: ML_{BW125} , restrita a configurações com $BW = 125$ kHz, e ML_{Free} , com busca em todo o espaço de larguras de banda considerado. A energia de transmissão por pacote foi estimada como $E_{tx} = V \cdot I_{tx}(P) \cdot ToA$, em que ToA é o tempo no ar do pacote e $I_{tx}(P)$ a corrente de

Tabela 2. Comparação entre o método proposto e os baselines de predição sob validação Leave-One-Distance-Out.

Modelo	Tipo	MAE (dB)	RMSE (dB)
Huber Regressor	Sondagem por referências	1,70 ± 0,40	2,14 ± 0,53
Linear Regression	Sondagem por referências	2,04 ± 0,40	2,49 ± 0,49
Bayesian Ridge	Sondagem por referências	2,07 ± 1,12	2,47 ± 1,10
Gradient Boosting Regr.	Sondagem por referências	3,89 ± 1,34	4,37 ± 1,27
SVR (RBF)	Sondagem por referências	4,11 ± 2,54	4,49 ± 2,38
Multi-var Linear	Baseline	9,91 ± 5,08	10,15 ± 4,99
Log-Distance	Baseline	10,23 ± 12,64	10,75 ± 12,46
Two-Slope	Baseline	11,03 ± 13,57	11,62 ± 13,34
FSPL	Baseline	43,11 ± 7,65	43,28 ± 7,58

transmissão associada ao nível de potência configurado. Essa estimativa considera apenas a transmissão do rádio. Em ambos os casos, a decisão foi baseada na margem prevista de SNR e, entre as configurações viáveis, na menor energia estimada por pacote. Aqui, *safe rate* denota a fração de distâncias em que $PDR \geq 0,90$. A Tabela 3 resume os pontos operacionais mais relevantes: margens mais baixas reduzem a energia média de operação, mas aumentam o risco de selecionar configurações com $PDR < 0,90$. Segundo o critério de equilíbrio entre *safe rate* e energia, *ML-Free* com margem de 2 dB foi o ponto recomendado, com *safe rate* igual a 1, *PDR* médio de 0,9667 e energia operacional média de 24,09 mJ por pacote, enquanto *ML-BW125* só atingiu *safe rate* igual a 1 com margens de 3 e 4 dB, ambas com 52,01 mJ.

Como referência, a estratégia de varredura exaustiva (*ExhaustiveSurvey*) obteve energia operacional média de 10,71 mJ por pacote, mas ao custo de 109 967,64 mJ de energia média de descoberta, cerca de 10,9 vezes superior ao custo médio de descoberta das variantes baseadas em ML (10 115,73 mJ). A Tabela 4 compara o ponto recomendado (*ML-Free*, margem de 2 dB) com um baseline inspirado no ADR do LoRaWAN, emulado por *replay offline* da política de rede sobre a última janela observada, com $BW = 125$ kHz, margem de instalação de 10 dB e ajustes em *SF* e potência de transmissão. O ADR atingiu $PDR = 1,0$, mas operou com energia média de 96,24 mJ por pacote, aproximadamente quatro vezes superior à do método proposto. Em um horizonte de 1000 pacotes, a energia total estimada de transmissão (incluindo sondagem) foi de 35,81 J para o método proposto e 103,63 J para o ADR, o que representa redução de 65,44% no cenário avaliado.

Tabela 3. Síntese dos resultados da etapa de seleção energética.

Método	Margem (dB)	PDR médio	Safe rate	Energia operacional média (mJ)
ML BW125	3,0	1,0000	1,000	52,01
ML Free	2,0	0,9667	1,000	24,09
ADR	–	1,0000	1,000	96,24
ExhaustiveSurvey	–	0,9667	1,000	10,71

4.3. Discussão

Os resultados mostram que medições curtas de referência são suficientes para caracterizar o estado local do enlace e sustentar a predição de SNR em ambiente de floresta amazônica

Tabela 4. Comparação operacional entre o ponto recomendado do método proposto e o baseline ADR.

Método	PDR médio	Energia operacional média (mJ)	Energia de descoberta (mJ)
ML Free (margem = 2 dB)	0,9667	24,09	10115,73
ADR	1,0000	96,24	7384,13

e que a segunda referência reduz de forma consistente o erro de predição. Nesse contexto, o Huber Regressor combina simplicidade estrutural e robustez a flutuações locais do canal, produzindo erros menores e comportamento mais estável do que modelos não lineares mais flexíveis sob o protocolo *Leave-One-Distance-Out*. Na etapa operacional, a seleção baseada na margem prevista de SNR permitiu reduzir substancialmente a energia de operação em relação ao ADR, mantendo a operação segura em todas as distâncias avaliadas, o que tende a gerar ganhos acumulados em campanhas de monitoramento de longa duração.

5. Conclusão

Este trabalho investigou a seleção energeticamente eficiente de parâmetros LoRa para monitoramento ambiental em floresta amazônica densa, combinando sondagem curta por referências, predição supervisionada de SNR e uma regra de seleção baseada na margem operacional e na energia de transmissão. A partir de medições de campo em enlaces ponto a ponto no campus da Universidade Federal do Amazonas (UFAM), em Manaus-AM, Brasil, mostrou-se que medições locais de referência caracterizam o estado do enlace de forma suficiente para apoiar decisões de configuração, sem exigir a distância geométrica como entrada na etapa operacional.

Na etapa de predição, o Huber Regressor apresentou o melhor desempenho sob validação *Leave-One-Distance-Out*, com $MAE = 1,70 \pm 0,40$ dB e $RMSE = 2,14 \pm 0,53$ dB para duas referências, indicando boa capacidade de generalização para distâncias não observadas no treinamento. A ablação com uma única referência mostrou que a segunda reduz de forma consistente o erro de predição, reforçando a utilidade de um conjunto mínimo, porém informativo, de medições locais. Além disso, o método proposto apresentou erros substancialmente menores do que os baselines clássicos de predição dependentes da distância, avaliados neste estudo, sugerindo que a sondagem local captura melhor a condição do canal em floresta densa do que a distância isoladamente.

Na etapa operacional, a variante recomendada (*ML-Free* com margem de 2 dB) atingiu *safe rate* igual a 1,0 (isto é, $PDR \geq 0,90$ em todas as distâncias avaliadas), com PDR médio de 0,9667 e energia operacional média de 24,09 mJ por pacote. Em comparação, o baseline inspirado no ADR apresentou energia operacional média de 96,24 mJ por pacote no recorte avaliado. Considerando um horizonte de 1000 pacotes, a energia total estimada (incluindo sondagem) foi reduzida em 65,44% em relação ao baseline, preservando operação segura nas distâncias analisadas. Como trabalhos futuros, pretende-se (i) avaliar a abordagem em campanhas adicionais com maior diversidade temporal e espacial, investigando a estabilidade das referências ao longo do tempo; (ii) estudar estratégias adaptativas para reduzir ainda mais o orçamento de sondagem, mantendo a robustez; e (iii) analisar a integração do método em cenários de rede multi-salto (mesh) e em implementação embarcada, quantificando o custo computacional da inferência frente

à economia obtida na comunicação sem fio.

Agradecimentos

Este trabalho foi apoiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (AUXPE-CAPES-PROEX), Código de Financiamento 001, e pela Fundação de Amparo à Pesquisa do Estado do Amazonas - FAPEAM, por meio dos projetos PDPG/CAPES e POSGRAD 2026/2027.

Referências

- Ansah, M. R., Sowah, R. A., Melià-Seguí, J., Katsriku, F. A., Vilajosana, X., and Banahene, W. O. (2020). Characterising foliage influence on LoRaWAN pathloss in a tropical vegetative environment. *IET Wireless Sensor Systems*, 10(5):198–207.
- Azevedo, J. A. and Mendonça, F. (2024). A critical review of the propagation models employed in LoRa systems. *Sensors*, 24(12):3877.
- Benkhelifa, F., Qureshi, H. K., and McCann, J. A. (2019). Experimental analysis of LoRa ADR. In *Proceedings of the IEEE Global Communications Conference (GLOBECOM)*, pages 1–6, Waikoloa. IEEE.
- Bouguera, T., Diouris, J.-F., Chaillout, J.-J., Jaouadi, R., and Andrieux, G. (2018). Energy consumption model for sensor nodes based on LoRa and LoRaWAN. *Sensors*, 18(7):2104.
- Casals, L., Mir, B., Vidal, R., and Gomez, C. (2017). Modeling the energy performance of LoRaWAN. *Sensors*, 17(10):2364.
- Cerar, G., Yetgin, H., Mohorčič, M., and Fortuna, C. (2021). Machine learning for wireless link quality estimation: A survey. *IEEE Communications Surveys & Tutorials*, 23(1):696–728.
- Ferreira, A. E., Ortiz, F. M., Costa, L. H. M. K., Foubert, B., Amadou, I., and Mitton, N. (2020). A study of the LoRa signal propagation in forest, urban, and suburban environments. *Annals of Telecommunications*, 75(7-8):333–351.
- International Telecommunication Union (2021). Recommendation ITU-R p.833-10: Attenuation in vegetation. Technical report, ITU, Geneva. Acesso em: 10 dez. 2025.
- Lima, W. G., Lopes, A. V. R., Cardoso, C. M. M., Araújo, J. P. L., Neto, M. C. A., Tostes, M. E. L., Nascimento, A. A., Rodriguez, M., and Barros, F. J. B. (2024). LoRa technology propagation models for IoT network planning in the amazon regions. *Sensors*, 24(5):1621.
- LoRa Alliance (2020). LoRaWAN 12 1.0.4 specification [ts001-1.0.4]. Technical report, LoRa Alliance, San Ramon. Acesso em: 10 dez. 2025.
- Semtech Corporation (2015). An1200.22: LoRa modulation basics. Application note, Semtech Corporation, Camarillo.
- Slabicki, M., PremSankar, G., and Di Francesco, M. (2018). How agile is the adaptive data rate mechanism of LoRaWAN? In *Proceedings of the IEEE Global Communications Conference (GLOBECOM)*, pages 1–7, Abu Dhabi. IEEE.