

Otimização da Taxa de Dados LoRa através de Caracterização Prévia para Transmissão em Cenários de Floresta com Eficiência Energética

Diogo Soares Moreira¹, Gilmara Santos¹, Pedro Barreto de Souza¹, Paulo Victor Fernandes de Melo¹, Edjair Mota¹

¹ Instituto de Computação – Universidade Federal do Amazonas (UFAM)
69077-000 – Manaus, AM – Brasil

{diogo.soares, gilmara, pedro.souza, paulo.fernandes,
edjair}@icom.ufam.edu.br

Abstract. *With the advancement of the Internet of Things (IoT) and low-power transmission technologies such as LoRa (Long Range), a range of solutions for remote environmental monitoring has emerged. In these scenarios, in addition to the proper selection of LoRa transmission parameters, the challenge of extending the battery life of network nodes also stands out. The standard LoRa strategy consists of dynamically adjusting transmission parameters using the Adaptive Data Rate (ADR) algorithm. However, ADR, based on SNR (Signal-to-Noise Ratio), has limitations in noisy and forest environments. This paper presents LoRaBB, an automatic parameter selection algorithm designed for noisy forest scenarios and energy consumption reduction, which incorporates three LoRa metrics (RSSI, SNR, and PDR) and is based on prior characterization of the deployment environment. Practical experiments in forest fragments demonstrated that LoRaBB converged to configurations with reduced Time on Air (ToA) and lower energy consumption. Finally, simulations conducted with 15 and 40 nodes, with ranges from 800 to 2200 meters to the gateway, confirmed an average improvement of 27.6% in LoRaBB's PDR compared to ADR and a reduction of up to 54.2% in energy consumption per packet, in addition to a 78.1% decrease in packet collisions.*

Resumo. *Com o avanço da Internet das Coisas (IoT) e de tecnologias de transmissão de baixa potência como LoRa (Long Range), emergiu uma gama de soluções para monitoramento ambiental remoto. Nestes cenários, além da seleção adequada dos parâmetros de transmissão LoRa, destaca-se também o desafio de estender a vida útil da bateria dos nós da rede. A estratégia padrão do LoRa consiste no ajuste dinâmico dos parâmetros de transmissão por meio do algoritmo de Taxa de Dados Adaptativa (ADR). Contudo, o ADR, baseado em SNR (Relação sinal-ruído), apresenta limitações em ambientes ruidosos e florestais. Neste trabalho, apresenta-se o LoRaBB, um algoritmo de seleção automática de parâmetros voltado a cenários florestais ruidosos e à redução do consumo energético, que incorpora três métricas do LoRa (RSSI, SNR e PDR) e se fundamenta na caracterização prévia do ambiente de implantação. Experimentos práticos em fragmentos de floresta demonstraram que o LoRaBB*

convergiu para configurações com redução do Time on Air (ToA) e menor consumo energético. Por fim, simulações conduzidas com 15 e 40 nós, com alcances de 800 a 2200 metros para o gateway, confirmaram melhoria média de 27,6% no PDR do LoRaBB em relação ao ADR e redução de até 54,2% no consumo energético por pacote, além de diminuição de 78,1% nas colisões de pacotes.

1. Introdução

O monitoramento ambiental tradicional, baseado em coletas manuais, é oneroso e não fornece dados em tempo real. Contudo, com o avanço da Internet das Coisas (IoT) e tecnologias de comunicação como o LoRa (*Long Range*) destacam-se para o monitoramento remoto, oferecendo menor consumo energético e custos reduzidos de implantação [Das and Jain 2017, Marini et al. 2022]. No entanto, a eficiência do LoRa depende do ajuste preciso de seus parâmetros físicos (Largura de Banda - BW, Fator de Espalhamento - SF, Taxa de Codificação - CR e Potência - TP). Com milhares de combinações possíveis, a configuração inadequada pode degradar o desempenho da rede e aumentar o consumo de energia em mais de 100 vezes [Rašić et al. 2021].

O desafio de configuração de parâmetros LoRa é amplificado em regiões de floresta, como encontradas em lugares como a Amazônia, onde a comunicação ocorre frequentemente sem linha de visada (NLOS) [Polidori et al. 2022] e com vegetação variada. Embora o LoRa utilize o algoritmo de taxa de dados adaptativo (*Adaptive Data Rate - ADR*) para ajustes dinâmicos nos parâmetros de transmissão, essa estratégia apresenta limitações em ambientes ruidosos, instáveis ou de floresta, pois baseia-se primordialmente na métrica de SNR, falhando na convergência em cenários florestais [Serati et al. 2022].

Para preencher essa lacuna, este trabalho propõe o LoRaBB (*LoRa Binary Search-Based Adaptive Data Rate*). O algoritmo utiliza um vetor de referência (R-array), construído a partir da caracterização do cenário real, e emprega uma estratégia de busca binária para otimizar a seleção de SF, BW e TP com base em métricas combinadas de desempenho LoRa como RSSI, SNR e PDR (*Packet Delivery Ratio*). Diferente do ADR, o LoRaBB é projetado para lidar com a variabilidade de atenuação típica da vegetação densa.

Os resultados obtidos, tanto em validação prática quanto em simulação, demonstram a superioridade do LoRaBB sobre o ADR tradicional em cenários florestais. O algoritmo proposto alcançou uma redução de 16,20% no *Time on Air* (ToA) em testes práticos. Nas simulações, o LoRaBB apresentou um aumento de 27,6% na taxa de entrega de pacotes (PDR), redução de 54,2% no consumo de energia por pacote e redução nas colisões em 78,1%.

2. Trabalhos Relacionados

A seleção de parâmetros LoRa (SF, BW, CR, TP) é fundamental para garantir a qualidade da comunicação e otimização do consumo de energia [Wang et al. 2022, Li and Cao 2022]. Estudos demonstram que fatores ambientais influenciam significativamente essa seleção, exigindo um equilíbrio entre taxa de entrega e consumo energético [Gao et al. 2019, Cattani et al. 2017, Angrisani et al. 2017], enquanto a estratégia padrão ADR, baseada primordialmente na relação do SNR e RSSI, apresenta limitações em ambientes ruidosos e florestais [The Things Network 2023, Wang et al. 2022]. Por outro lado, a

distância entre transmissor e receptor é determinante na taxa de entrega [Gao et al. 2019], e embora o LoRa seja robusto a ruído intenso, a variação de SF, CR e BW influencia diretamente as perdas de pacotes [Angrisani et al. 2017, Cattani et al. 2017]. Além disso, a taxa de entrega de pacotes mantém-se em um limite próximo dos parâmetros selecionados, apresentando redução de apenas 10% comparada aos parâmetros mais lentos quando o nó está distante do gateway [Cattani et al. 2017].

Diversas abordagens foram propostas para aprimorar a seleção de parâmetros. O tradicional ADR ajusta os parâmetros do LoRa com base nos valores de SNR, contudo essa estratégia adiciona complexidade computacional aos processos do gateway [Wang et al. 2022]. O ADR-Lite [Serati et al. 2022] utiliza busca binária com PDR como critério, porém não incorpora RSSI, SNR nem o parâmetro BW. Por outro lado, o ADR-X [de Jesus et al. 2021] introduz limiares adaptativos de SNR, enquanto a troca dinâmica de canais é proposta em solução centralizada, mas com detalhes incompletos [Khalifeh et al. 2020].

Além disso, uma tendência recente envolve a aplicação de técnicas de aprendizado de máquina (ML) para selecionar parâmetros LoRa. Nas pesquisas de [Filho and Campista 2022] e [Yatagan and Oktug 2019], os autores investigaram essa metodologia, que prioriza a eficiência energética e melhora o PDR utilizando abordagens convencionais de ML. De forma similar, é encontrado na literatura algoritmo de aprendizado profundo (Deep Learning), formulado como um processo de decisão de Markov, para otimizar o PDR no processo ADR [Ilahi et al. 2020]. Contudo, em ambientes reais, a utilização de modelos de aprendizagem de máquina podem quadruplicar o consumo energético durante o período de predição [Sabovic et al. 2025].

Acosta-García et al. [Acosta-Garcia et al. 2026] propuseram o CADD, uma abordagem colaborativa que combina redução de dados nos dispositivos finais com regulação adaptativa do *duty cycle*, com o uso de heurísticas, alcançando PDR $4\times$ superior e redução de até 54% no consumo energético em cenários com até 500 dispositivos. Embora o CADD aborde o controle de congestionamento em nível de rede e não a seleção de parâmetros da camada física, destaca-se a interação entre escolhas de parâmetros e desempenho da rede para otimizar a qualidade do enlace individual.

3. O Algoritmo LoRaBB

O LoRaBB (*LoRa Binary Search-Based Adaptive Data Rate*) é um algoritmo de seleção automática de parâmetros que opera de forma distribuída, permitindo que cada nó da rede selecione autonomamente os parâmetros ótimos de transmissão sem necessidade de coordenação centralizada com o gateway, contudo, é assumido que os gateways possam operar em múltiplos canais para comunicar-se com os demais nós. O algoritmo é composto por dois elementos fundamentais: o R-array, que caracteriza a rede para cada combinação de parâmetros; e a lógica de busca binária, que converge para a configuração mais adequada.

3.1. R-array e Métrica Composta R-value

O R-array fundamenta-se em uma métrica composta denominada R-value, que integra três indicadores de desempenho de comunicação LoRa, RSSI, SNR e PDR (Taxa de entrega)

em um valor unificado, o R-value:

$$R_{value} = W_1 \cdot \overline{RSSI} + W_2 \cdot \overline{(SNR_i + 20)} + W_3 \cdot \overline{PDR} \quad (1)$$

onde W_1 , W_2 e W_3 representam pesos que permitem customização conforme os requisitos de negócio, e a barra superior denota valores médios das medições iniciais.

As métricas foram normalizadas para o intervalo $[0, 1]$ mediante a fórmula $\frac{V_{valor} - V_{max}}{V_{min} - V_{max}}$, onde $V \in \{RSSI, SNR, PDR\}$. A inclusão simultânea de RSSI e SNR no R-value decorre de suas sensibilidades distintas em ambientes florestais: o RSSI captura a atenuação total do sinal causada pela distância e pela vegetação, enquanto o SNR reflete a relação entre o sinal recebido e o ruído de fundo. Em experimentos em fragmentos de floresta, ambas as métricas apresentaram comportamento com padrões de variação distintos, de modo que sua combinação produz um indicador mais estável [Richardson Ansah et al. 2020].

A configuração dos pesos ($W_1 = W_2 = 0,2$, $W_3 = 0,6$) foi determinada, a priori, com base no objetivo de maximizar a taxa de entrega de pacotes, e posteriormente validada por análise de correlação com diferentes valores de pesos. A comparação, usando simulação, entre quatro configurações de pesos (pesos iguais, priorização de PDR, priorização de RSSI e priorização de SNR) demonstrou que a configuração com $W_3 = 0,6$ produziu a maior correlação de Pearson entre o R-value e o PDR bruto, tanto em dados simulados ($r = 0,934$) quanto em dados práticos ($r = 0,895$), além de apresentar o melhor resultado de PDR. Esta configuração também produziu a maior separação entre configurações de alta e baixa performance no R-array ordenado, favorecendo a convergência da busca binária.

Assim, a construção do R-array é responsável pela caracterização esperada do cenário. Para cada combinação de parâmetros (SF, BW, TP), são transmitidos pacotes e coletadas as métricas RSSI, SNR e PDR. Os R-values calculados são então inseridos no arranjo, que é ordenado de forma crescente. Este arranjo ordenado é embarcado nos nós.

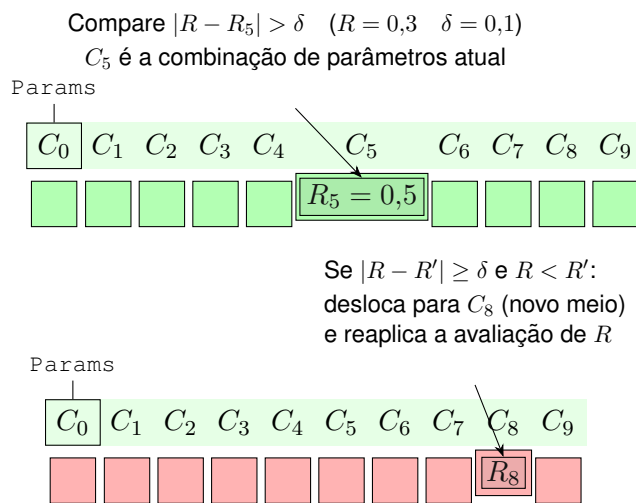


Figura 1. Exemplo do algoritmo de busca binária usando valores R no R-array ordenado ($R = 0,3$; $\delta = 0,1$). No R-array verde, C_5 é avaliado. No R-array vermelho, a busca desloca-se para C_8 .

3.2. Fase de Busca Binária

A fase de busca binária representa o algoritmo de taxa de dados adaptativo em si. Seu objetivo é, partindo de um R-array ordenado previamente caracterizado (Seção 3.1), convergir para a combinação de parâmetros (SF, BW, TP) mais adequada às condições de comunicação atuais do nó sensor.

O processo é iniciado com uma configuração padrão (*Default Parameters*: SF=12, BW=125 kHz, TP=20 dBm, CR=4/5) para garantir a comunicação inicial. A cada iteração, o nó coleta métricas de link (RSSI, SNR, PDR) ao transmitir um pacote, calcula o valor R_{value} medido conforme a Equação 1, e o compara com o valor R' esperado, e armazenado no R-array, para a combinação de parâmetros atual.

A direção da busca é determinada por essa comparação, conforme ilustrado na Figura 1:

- **Se $R > R'$:** O desempenho real é *superior* ao esperado. O algoritmo busca por configurações mais eficientes energeticamente (menor SF, maior BW) no lado esquerdo do R-array.
- **Se $R < R'$:** O desempenho real é *inferior* ao esperado. O algoritmo prioriza confiabilidade, deslocando-se para o lado direito do R-array em busca de configurações mais robustas (maior SF, menor BW).

A busca continua até que o critério de convergência principal seja satisfeito: a diferença absoluta entre R e R' seja menor que o limiar δ (neste trabalho foi adotado 0,1). O processo de comparação entre desempenho real e esperado repete-se até convergência ou esgotamento do R-array.

4. Metodologia

A metodologia de avaliação do LoRaBB compreendeu três fases sequenciais: avaliação por simulação, caracterização empírica do canal de comunicação florestal e validação prática do algoritmo LoRaBB em cenário de floresta.

4.1. Avaliação por Simulação

Para validar o desempenho do algoritmo LoRaBB em cenários escaláveis e compará-lo com estratégias ADR existentes, foram realizadas simulações usando o simulador LoRa-EnergySim [Callebaut et al. 2019]. A simulação foi conduzida em 12 cenários, combinando diferentes densidades de rede e condições de propagação, conforme sumariado na Tabela 1. Cada cenário foi executado em 5 replicações independentes (Monte Carlo), totalizando 60 execuções. Por fim, os valores usados como parâmetros de modelos de propagação foram baseados em estudos de propagação LoRa em florestas [Phai-boon and Phokharatkul 2023] e da recomendação ITU-R P.833-9 sobre atenuação em vegetação [ITU-R 2016].

A caracterização do R-Array foi realizada na fase de *warm-up* da simulação, considerando distâncias de 500 m, 1000 m e 1500 m, cobrindo as faixas de operação dos cenários de célula definidos para a execução da simulação (800 m a 2200 m). As métricas de desempenho coletadas incluíram: PDR, eficiência energética (consumo médio por pacote entregue em mJ/pkt e consumo total da rede) e colisões (taxa de pacotes perdidos por interferência).

Tabela 1. Parâmetros de configuração da simulação no LoRaEnergySim.

Parâmetro	Valor / Configuração
<i>Parâmetros de Cenário</i>	
Duração da Simulação	6 horas
Número de Nós	15 e 40 (Baixa e Média densidade)
Raios da Célula	800 m, 1600 m, 2200 m
Distribuição Espacial	Zonal (33% Perto, 33% Médio, 34% Longe)
Algoritmos Comparados	LoRaBB e ADR Tradicional
<i>Parâmetros de Canal e Tráfego</i>	
Modelo de Propagação	Log-Shadowing ($\gamma = 3,8$, $\sigma = 8,0$ dB)
Tamanho do Payload	20 bytes
Taxa de Transmissão	≈ 1 pacote a cada 30 segundos

4.2. Avaliação em Cenário Real

De modo a validar o LoRaBB em um cenário real, foram conduzidos experimentos em fragmento de floresta urbana do campus da Universidade Federal do Amazonas (UFAM) em Manaus (03°04'34" S, 59°57'30" O). A comunicação entre os nós ocorreu inteiramente sem linha de visada (NLOS), com obstáculos compostos por troncos de árvores de grande porte e copas sobrepostas, condições que introduzem atenuação significativa e propagação por múltiplos percursos.

A configuração de *hardware* utilizou dispositivos Esp32 Heltec V2 (nó transmissor, módulo SX1276) e V3 (como *gateway*, módulo SX1262), equipados com antenas Steelbras AP3900 de 5 dBi. O transmissor foi posicionado a aproximadamente 12 metros de altura e o receptor a 8 metros.

O conjunto completo de dados experimentais encontra-se em conjunto de dados publicamente disponível¹. A Tabela 2 sintetiza o espaço de parâmetros explorado no cenário real, que incluiu todas as combinações de SF, BW e TP listadas. Cabe ressaltar que, por restrições do simulador LoRaEnergySim, nas simulações foram utilizados apenas BW = 125 kHz e TP = 2, 8 e 14 dBm, mantendo os demais parâmetros conforme a tabela.

Tabela 2. Parâmetros para construção do R-array no cenário prático.

Parâmetro	Valores
Fator de Espalhamento (SF)	[7, 8, 9, 10, 11, 12]
Largura de Banda (BW)	[125,00; 250,00; 500,00] kHz
Potência de Transmissão (TP)	[10, 12, 14, 16, 18, 20] dBm

4.3. Cenários de validação prática e *baseline* ADR

Os cenários de validação prática empregaram distâncias de 72 m e 150 m para caracterização do R-array e de 187 m e 200 m para execução do LoRaBB e ADR, superiores às utilizadas na caracterização, a fim de avaliar a capacidade de generalização do algoritmo. A comparação *baseline* utilizou o algoritmo ADR tradicional conforme

¹<https://doi.org/10.48472/deposita/FRRQ8R>

a especificação Semtech, com margem de 15 dB. O ADR determinou os passos de otimização por meio da fórmula [Semtech 2015]:

$$N_{\text{passo}} = \frac{\text{SNR}_{\text{max}} - \text{SNR}_{\text{SF}} - \text{margem}_{\text{dB}}}{2,5} \quad (2)$$

5. Resultados e Discussão

5.1. Resultados da Avaliação por Simulação

A simulação iniciou-se pela caracterização para construção do R-array, realizada com um nó gateway e outro nó sensor em distâncias fixas de 500m, 1km e 1,5km, e os parâmetros LoRa usados para caracterizar são os mesmos descritos na Tabela 2. A análise do R-array evidenciou a variação intrínseca entre robustez, eficiência espectral e consumo energético causada pela escolha dos parâmetros: as configurações com maior R esperado (SF=12, TP=14 dBm) alcançaram PDR de 100% com RSSI médio de $-107,77$ dBm, enquanto as de menor R (SF=7, TP=2 dBm) apresentaram PDR de 58,3% com RSSI de $-125,97$ dBm na distância de 1 km, uma redução de até 42% na taxa de entrega.

5.1.1. Taxa de Entrega de Pacotes (PDR)

O algoritmo LoRaBB demonstrou maior PDR em todos os cenários de densidade, distância e número de nós avaliados, com média de PDR superior à do ADR, conforme pode ser observado na Figura 2, enquanto o ADR tradicional, dependente de médias de SNR e *downlinks* do gateway, apresentou maior latência de adaptação, resultando em mais perdas de pacotes.

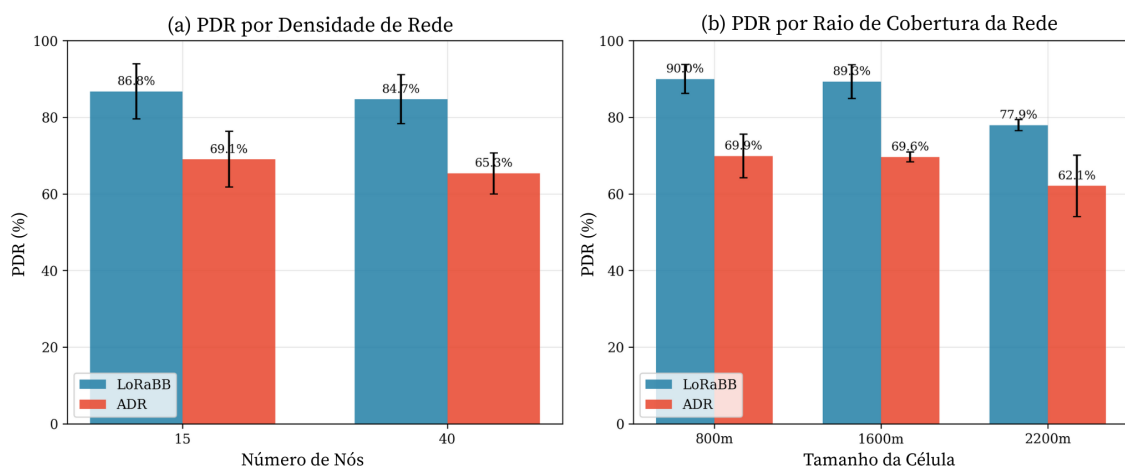


Figura 2. Comparação da Taxa de Entrega de Pacotes (PDR) entre LoRaBB e ADR.

Por sua vez, a análise por tamanhos de células mostrou que, mesmo para nós situados na zona "Longe" (borda da célula), o LoRaBB manteve taxas de entrega estáveis.

5.1.2. Eficiência Energética e Colisões

A eficiência energética foi avaliada considerando a energia consumida por pacote entregue com sucesso e o consumo total dos nós ao final da simulação, conforme pode ser visualizado na Figura 3. O LoRaBB obteve uma redução no consumo energético, sobretudo no cenário de 40 nós, no qual o consumo energético total da simulação foi 70% menor no cenário com 40 nós e 41% menor no cenário com 15 nós. Este ganho é atribuído à capacidade do algoritmo de convergir para parâmetros que equilibram o Fator de Espalhamento (SF) e a Potência de Transmissão (TP), evitando o uso desnecessário de SFs altos ou potências máximas quando não estritamente necessário, isto é, a longas distâncias.

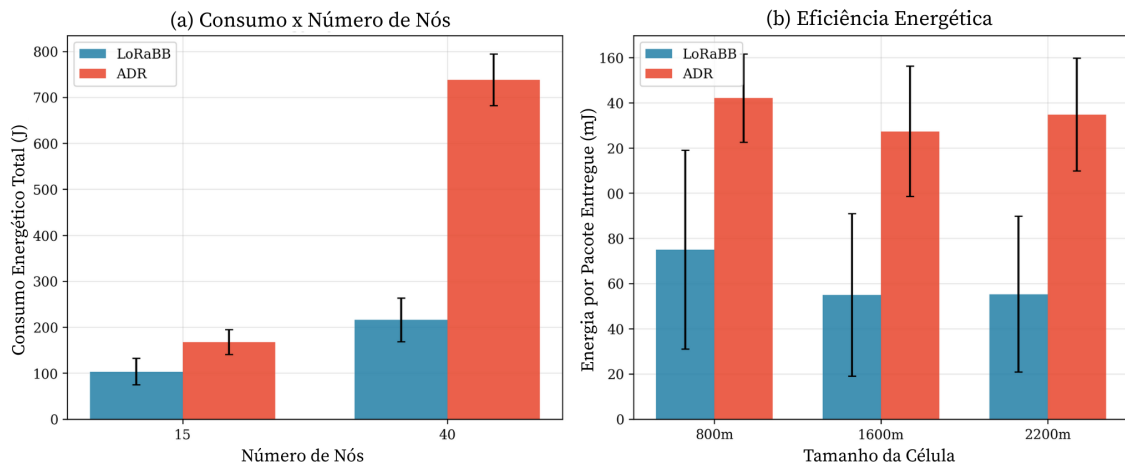


Figura 3. Comparativo de consumo energético em (a) relação ao número de nós e (b) consumo energético por pacote entregue nos cenários com diferentes tamanhos de célula.

A validação estatística, usando teste T, confirmou que as diferenças observadas entre as médias de PDR e consumo energético foram estatisticamente significativas ($p < 0,001$).

5.2. Resultados da Avaliação em Cenário Real

5.2.1. Caracterização e Construção do R-Array

A etapa de caracterização nas distâncias de 72 m e 150 m gerou o R-array usado para os experimentos reais. Conforme pode ser observado na Figura 4.a, os valores de PDR geraram maior perda, principalmente por conta do ruído do canal neste cenário (acima de -80 dB) mesmo em distâncias menores. Este ponto divergiu da simulação por conta do PDR menor em uma distância menor; contudo, tal resultado corrobora para o aspecto de impacto da comunicação dentro da floresta usando LoRa. A análise dos dados empíricos evidenciou também que a média de valores no R-array reduziu, com uma parte dos dados indo para a média de 0,2 e outra parte dos dados convergindo para a média de 0,8, o que demonstra a diferença em relação aos resultados simulados. Os resultados do R-valor distribuídos para o experimento real podem ser visualizados na Figura 4.b.

Notou-se, especificamente, que o aumento da potência de transmissão (TP) acima de 14 dBm nem sempre resultou em ganho proporcional de PDR, sugerindo que em am-

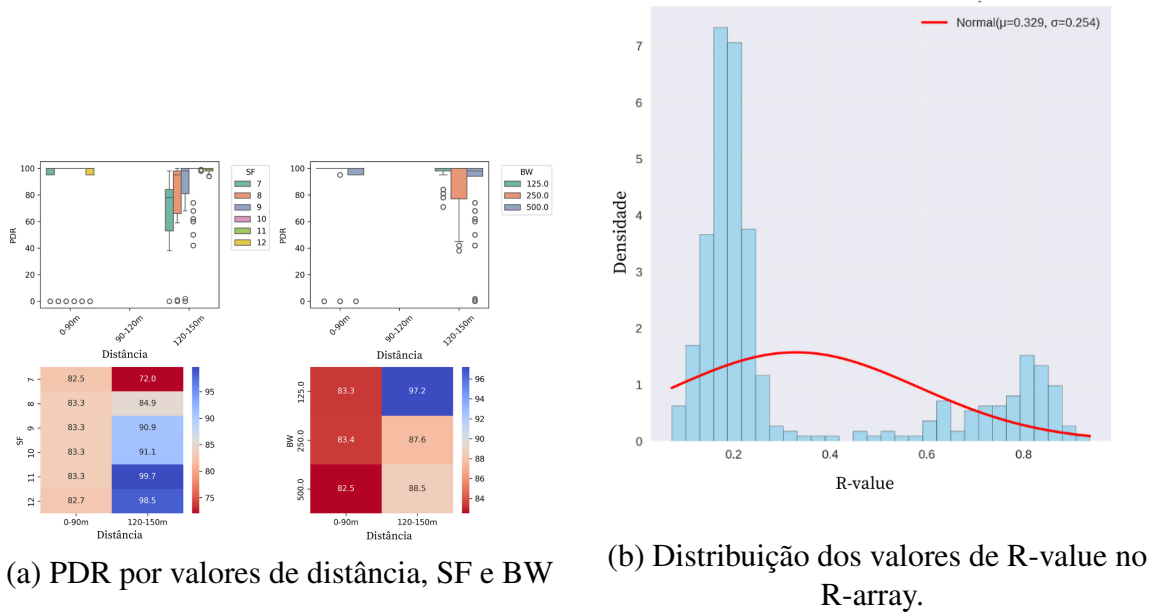


Figura 4. Resultados de PDR para os parâmetros usados no experimento real na floresta do Campus da UFAM e o impacto no R-array.

bientes de floresta densa, a escolha correta do SF e BW é mais crítica do que a potência do sinal em si, o que também gera impacto no custo energético.

5.2.2. LoRaBB vs. ADR em Cenário Real

Os resultados dos experimentos de validação, dispostos na Tabela 3, resumem os parâmetros LoRa selecionados por cada algoritmo. Em contraste com o LoRaBB, o ADR convergiu para SF = 10, BW = 125 kHz e TP = 20 dBm, não reduzindo a potência de transmissão em nenhum caso. Esse comportamento é atribuído à baixa estabilidade do SNR em ambientes florestais, que leva o ADR a adotar valores conservadores de TP. Como resultado, o PDR alcançou 100% em todos os cenários, exceto para o ADR a 200 m (80%).

Tabela 3. Comparação dos parâmetros finais selecionados e desempenho na validação prática.

Algoritmo	Distância	SF Final	BW (kHz)	TP (dBm)	PDR (%)
ADR (Baseline)	187 m	10	125	20	100%
LoRaBB	187 m	11	250	14	100%
ADR (Baseline)	200 m	10	125	20	80%
LoRaBB	200 m	11	250	14	100%

A seleção de parâmetros impactou diretamente o consumo energético. O tempo no ar (*Time on Air* - ToA) calculado para o LoRaBB e ADR foi de 206,84 ms e 247,80 ms, respectivamente (resultados extraídos com a ferramenta *LoRa Calculator*²). Considere-

²<https://www.semtech.com/design-support/lora-calculator>, acessado em janeiro de 2026

rando que o consumo energético é proporcional ao ToA e cresce exponencialmente com o aumento da TP, a escolha do LoRaBB por uma potência 6 dB menor representa economia significativa, visto que estudos indicam aumento superior a 340% quando a TP varia de 13 para 20 dBm [Bouguera et al. 2018].

Quanto à convergência, o LoRaBB utilizou 38 e 40 pacotes, contra apenas 20 do ADR. Esta diferença decorre da busca binária realizada no R-array, que requer mais iterações mas resulta em parâmetros mais eficientes, enquanto o ADR baseia-se apenas no SNR médio, uma métrica com baixa variância em canais ruidosos.

6. Conclusão e Trabalhos Futuros

Este trabalho apresentou o algoritmo de taxa de dados adaptativo para comunicação LoRa, o LoRaBB, baseado em busca binária e caracterização prévia do cenário de implantação. O LoRaBB utiliza um vetor de referência do cenário (R-array) que relaciona métricas de qualidade de transmissão LoRa (RSSI, SNR e PDR) com as combinações de parâmetros (SF, BW e TP) para cada cenário específico. A abordagem foi especialmente projetada para cenários florestais como os encontrados na Amazônia, visando apoiar sistemas de monitoramento ambiental.

Os resultados demonstraram que o LoRaBB superou o ADR tradicional tanto em simulação quanto em experimentos práticos. Nas simulações, o algoritmo obteve aumento de 27,6% no PDR, redução de 54,2% no consumo energético por pacote e 78,1% nas colisões. Nos experimentos reais, convergiu para parâmetros mais eficientes em consumo energético (SF=11, BW=250 kHz, TP=14 dBm versus SF=10, BW=125 kHz, TP=20 dBm do ADR), resultando em redução de 16,20% no ToA.

Como trabalhos futuros, planeja-se investigar a capacidade do LoRaBB e ADR em diferentes condições climáticas. Adicionalmente, será analisado como os gateways podem gerenciar múltiplos dispositivos com diferentes parâmetros LoRa simultaneamente, explorando diferentes janelas de seleção de parâmetros ou estratégias baseadas em perdas recentes de pacotes.

7. Agradecimentos

Declaração sobre Uso de Inteligência Artificial Generativa: Ferramentas de IA generativa foram utilizadas para formatação de itens em LaTeX e geração de códigos e testes para o simulador LoraEnergySim e para o Esp32. Todas as ideias, resultados experimentais, análises e conclusões apresentadas são de inteira responsabilidade dos autores, que revisaram e validaram criticamente o conteúdo.

Referências

- Acosta-Garcia, L., Aznar-Poveda, J., Pedratscher, S., Etheredge, M., Asorey-Cacheda, R., Garcia-Haro, J., Fahringer, T., and Garcia-Sanchez, A.-J. (2026). Cadd: Collaborative adaptive duty cycle and data reduction for congestion control in lorawan. *Internet of Things*, page 101904.
- Angrisani, L., Arpaia, P., Bonavolontà, F., Conti, M., and Liccardo, A. (2017). Lora protocol performance assessment in critical noise conditions. *2017 IEEE 3rd International Forum on Research and Technologies for Society and Industry (RTSI)*, pages 1–5.

- 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).
- Callebaut, G., Ottoy, G., and van der Perre, L. (2019). Cross-layer framework and optimization for efficient use of the energy budget of iot nodes. In *2019 IEEE Wireless Communications and Networking Conference (WCNC)*, pages 1–6.
- Cattani, M., Boano, C. A., and Römer, K. (2017). An experimental evaluation of the reliability of lora long-range low-power wireless communication. *Journal of Sensor and Actuator Networks*, 6(2):7.
- Das, B. and Jain, P. (2017). Real-time water quality monitoring system using internet of things. In *2017 International conference on computer, communications and electronics (Comptelix)*, pages 78–82. IEEE.
- de Jesus, G. G. M., Souza, R. D., Montez, C., and Hoeller, A. (2021). Lorawan adaptive data rate with flexible link margin. *IEEE Internet of Things Journal*, 8(7):6053–6061.
- Filho, M. C. and Campista, M. (2022). Economia de energia através da configuração inteligente de parâmetros de camada física em redes lora. In *Anais do XL Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 559–572, Porto Alegre, RS, Brasil. SBC.
- Gao, W., Du, W., Zhao, Z., Min, G., and Singhal, M. (2019). Towards energy-fairness in lora networks. In *2019 IEEE 39th International Conference on Distributed Computing Systems (ICDCS)*, pages 788–798. IEEE.
- Ilahi, I., Usama, M., Farooq, M. O., Umar Janjua, M., and Qadir, J. (2020). Loradrl: Deep reinforcement learning based adaptive phy layer transmission parameters selection for lorawan. In *2020 IEEE 45th Conference on Local Computer Networks (LCN)*, pages 457–460.
- ITU-R (2016). Recommendation p.833-9: Attenuation in vegetation. Recommendation, International Telecommunication Union, Geneva. P Series: Radiowave propagation.
- Khalifeh, A., Shraideh, S., and Darabkh, K. A. (2020). Joint channel and spreading factor selection algorithm for lorawan based networks. In *2020 International Conference on UK-China Emerging Technologies (UCET)*, pages 1–4.
- Li, C. and Cao, Z. (2022). Lora networking techniques for large-scale and long-term iot: A down-to-top survey. *ACM Computing Surveys (CSUR)*, 55(3):1–36.
- Marini, R., Mikhaylov, K., Pasolini, G., and Buratti, C. (2022). Low-power wide-area networks: Comparison of lorawan and nb-iot performance. *IEEE Internet of Things Journal*, 9(21):21051–21063.
- Phaiboon, S. and Phokharatkul, P. (2023). An empirical model for 433 mhz lora-wan in ruby mango plantation. In *2023 9th International Conference on Engineering, Applied Sciences, and Technology (ICEAST)*, pages 25–28.
- Polidori, L., Caldeira, C. R. T., Smessaert, M., and Hage, M. E. (2022). Digital elevation modeling through forests: the challenge of the amazon. *Acta Amazonica*, 52:69–80.
- Rašić, T., Simon, J. L. E., Zorić, N., and Simić, M. (2021). The impact of lora transmission parameters on packet delivery and dissipation power. In *2021 International*

Balkan Conference on Communications and Networking (BalkanCom), pages 11–15. IEEE.

Richardson Ansah, M., Sowah, R. A., Melià-Seguí, J., Katsriku, F. A., Vilajosana, X., and Owusu Banahene, W. (2020). Characterising foliage influence on lorawan pathloss in a tropical vegetative environment. *IET Wireless Sensor Systems*, 10(5):198–207.

Sabovic, A., Fontaine, J., De Poorter, E., and Famaey, J. (2025). Energy-aware tinyml model selection on zero energy devices. *Internet of Things*, 30:101488.

Semtech (2015). Lora modulation basics. Accessed december 2023.

Serati, R., Teymuri, B., Anagnostopoulos, N. A., and Rasti, M. (2022). Adr-lite: A low-complexity adaptive data rate scheme for the lora network. In *2022 18th International Conference on Wireless and Mobile Computing, Networking and Communications (Wi-Mob)*, pages 296–301.

The Things Network (2023). LoRaWAN Adaptive Data Rate.

Wang, H., Pei, P., Pan, R., Wu, K., Zhang, Y., Xiao, J., and Yang, J. (2022). A collision reduction adaptive data rate algorithm based on the fsm for a low-cost lora gateway. *Mathematics*, 10(21):3920.

Yatagan, T. and Oktug, S. (2019). Smart spreading factor assignment for lorawans. In *2019 IEEE Symposium on Computers and Communications (ISCC)*, pages 1–7.