

Modelagem, Simulação e Avaliação de Redes LoRaWAN com Dados Empíricos de Floresta Tropical

Fábio O. Silva^{1,2}, Laura S. de Assis¹, Ana Lúcia F. de Barros¹,
Diego B. Haddad¹, Felipe da R. Henriques¹

¹Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
Rio de Janeiro – RJ – Brasil

²Instituto Federal da Bahia (campus Eunápolis)
Eunápolis – BA – Brasil

fabio.oliveira@aluno.cefet-rj.br

{laura.assis, ana.barros, diego.haddad, felipe.henriques}@cefet-rj.br

Abstract. *This work presents a comprehensive methodology for modeling, validating, and simulating LoRaWAN networks in dense tropical forest environments. Based on field measurements conducted in the Serra dos Órgãos National Park, Brazil, an empirical propagation model was derived for both static and mobile scenarios using a hybrid Orthogonal Distance Regression with Close-In reference constraint (ODR+CI). The extracted parameters were integrated into the FLoRaExt simulation framework. The proposed model was statistically validated through RMSE analysis, showing that simulation errors remain within the intrinsic environmental variability. Beyond validation, the study explores a large-scale deployment for geotechnical slope monitoring, highlighting the critical role of network densification and robust Adaptive Data Rate strategies under extreme propagation conditions.*

Resumo. *Este trabalho apresenta uma metodologia abrangente para modelagem, validação e simulação de redes LoRaWAN em ambientes de floresta tropical densa. Baseado em medições de campo no Parque Nacional da Serra dos Órgãos, um modelo empírico de propagação foi derivado para cenários estáticos e móveis utilizando uma Regressão de Distância Ortogonal híbrida com restrição de referência (ODR+CI). Os parâmetros extraídos foram integrados ao framework de simulação FLoRaExt. O modelo proposto foi validado estatisticamente via análise de RMSE, mostrando que os erros de simulação permanecem dentro da variabilidade intrínseca do ambiente. Além da validação, o estudo explora uma implementação em larga escala para monitoramento geotécnico de encostas, destacando o papel crítico da densificação da rede e estratégias robustas de Taxa de Dados Adaptativa (ADR) sob condições extremas de propagação.*

1. Introdução

O paradigma da Internet das Coisas (IoT) tem revolucionado a maneira como monitoramos e interagimos com o ambiente físico. Nos últimos anos, avanços significativos

nas tecnologias de comunicação sem fio têm sustentado esse desenvolvimento crescente. Tecnologias como 5G, NB-IoT (*Narrowband IoT*) e a expansão da internet via satélite têm transformado o cenário de conectividade global, oferecendo altas taxas de transferência e baixa latência. No entanto, para aplicações que exigem baixo consumo de energia, longo alcance e baixo custo de implementação, as redes LPWAN (*Low-Power Wide-Area Networks*) continuam sendo a escolha predominante.

Mesmo com o advento de novas tecnologias celulares, a relevância das redes LoRa (*Long Range*) é reforçada por pesquisas científicas recentes e pela crescente necessidade de soluções de conectividade em áreas de difícil acesso [Maurya et al. 2024]. A tecnologia LoRa utiliza a modulação *Chirp Spread Spectrum* (CSS), que oferece robustez contra interferências e ruídos, características essenciais para ambientes hostis.

Em [Haxhibeqiri et al. 2018], os autores destacam a capacidade do LoRa em atender requisitos específicos de aplicações IoT. A flexibilidade do protocolo LoRaWAN permite a criação de redes privadas sem a dependência de operadoras de telecomunicações, o que é crucial em regiões remotas. Essas características tornam a tecnologia uma opção atraente para projetos em larga escala em áreas com infraestrutura limitada, como agricultura de precisão, cidades inteligentes e, foco deste trabalho, o monitoramento ambiental.

Estudos comparativos, como o apresentado em [Mekki et al. 2019], analisam a tecnologia LoRa frente a outras redes LPWAN, como Sigfox e NB-IoT. A conclusão aponta que as redes LoRa oferecem um equilíbrio ideal entre alcance, consumo energético e custo. Para aplicações de monitoramento de ativos e sensoriamento ambiental — onde a substituição de baterias é custosa ou logisticamente inviável devido ao terreno acidentado — a eficiência energética do LoRa é um diferencial determinante.

No entanto, a aplicação dessas tecnologias em ambientes desafiadores, como florestas tropicais densas, apresenta obstáculos únicos que diferem substancialmente dos cenários urbanos ou de visada direta. A vegetação densa, típica da Mata Atlântica brasileira, causa obstrução severa, difração e espalhamento do sinal, além da absorção de energia eletromagnética pela água presente nas folhas e troncos. Esses fenômenos não são adequadamente representados pelos modelos de propagação padrão [Ferreira et al. 2020].

Nesse cenário, ferramentas de simulação tornam-se fundamentais. Elas permitem a avaliação prévia do desempenho da rede sob diferentes condições e a otimização de parâmetros como o número de *gateways*, a localização dos dispositivos e a configuração dos canais de comunicação [Słabicki et al. 2018]. Isso se traduz em economia de recursos tanto na fase de projeto quanto na implantação física, garantindo maior eficiência energética e evitando “zonas de sombra” que poderiam comprometer sistemas de alerta crítico.

Neste contexto, este trabalho apresenta um estudo de validação do módulo de propagação dentro do FLoRaExt, um protótipo de *framework* de pesquisa atualmente em construção, baseado no *framework* FLoRa [Aalto University 2025], no *framework* INET [INET Community 2025] e no simulador OMNeT++ [OMNeT++ Community 2025]. Além da ferramenta de simulação em si, propomos uma metodologia sistemática para aquisição e processamento de dados de campo visando derivar parâmetros de simulação realistas. Embora esta abordagem seja validada aqui utilizando dados empíricos coletados em uma floresta tropical densa no Parque Nacional da Serra dos Órgãos, o fluxo de traba-

lho proposto é generalizável e pode ser aplicado para modelar e simular outros ambientes complexos, como áreas urbanas ou campos agrícolas. Esta abordagem percorre todas as fases críticas do projeto:

1. **Aquisição de Dados de Propagação:** Descreve o processo de medição em campo para a aquisição de dados reais de propagação seguindo [Ferreira et al. 2020].
2. **Tratamento e Modelação:** Aplicação do método de Regressão de Distância Ortogonal híbrida com restrição *Close-In* (ODR+CI) para garantir a consistência física do modelo de perda de percurso (*Path Loss*).
3. **Desenvolvimento do Framework:** Implementação do simulador FLoRaExt [Oliveira 2025], estendendo as capacidades do FLoRa [Aalto University 2025].
4. **Simulação e Análise Comportamental:** Avaliação da escalabilidade através da análise da Taxa de Entrega de Pacotes (PDR) e algoritmos de ADR robustos (como o *Min-SNR*) em cenários de alta densidade [Słabicki et al. 2018].

Esta trabalho demonstra que a precisão no projeto de redes em áreas críticas depende da adoção de um fluxo metodológico integrado, iniciando na coleta de dados empíricos e culminando na validação em ambiente de simulação.

2. Trabalhos Relacionados

A caracterização da propagação é vital para o planejamento de redes IoT, dado que a intensidade do sinal recebido (RSSI) e a confiabilidade do enlace são diretamente influenciadas pelo ambiente. Na literatura, campanhas experimentais buscam mapear esse comportamento em diversos cenários. Em ambientes urbanos, [Petajajarvi et al. 2015] e [Masadan et al. 2018] demonstram que a tecnologia alcança distâncias de vários quilômetros, embora seja sensível à altura dos *gateways* e a obstruções severas. Em contrapartida, estudos em áreas rurais e de vegetação, como os de [Seye et al. 2018] e [Lima et al. 2024], evidenciam que a topografia e a densidade da biomassa são os principais fatores de atenuação, exigindo modelos empíricos específicos. A natureza mutável do canal é ainda corroborada por [Dieng et al. 2020], que reforça a necessidade de parametrização adequada para cada cenário.

Complementarmente às medições, a simulação surge como ferramenta essencial para projetar redes em larga escala, onde testes puramente empíricos seriam proibitivos. O *framework* FLoRa [Słabicki et al. 2018], operando sobre o simulador OM-NeT++, consolidou-se como uma das principais referências ao modelar a camada física LoRa e o protocolo MAC, permitindo a avaliação de mecanismos como o *Adaptive Data Rate* (ADR). Expandindo essa capacidade para redes não terrestres, o FLORA-SAT [Fraire et al. 2022] adapta o FLoRa para cenários de IoT via satélite em órbita baixa (LEO). Outras abordagens, como o LoRaWANSim [Marini et al. 2021] em MATLAB, focam na ortogonalidade imperfeita dos fatores de espalhamento e no efeito de captura, enquanto [Chen et al. 2023] utiliza o NS3 para propor algoritmos de localização via filtro de Kalman.

Apesar da precisão de métodos determinísticos como o *ray-tracing* proposto em [Ruz-Nieto et al. 2023], observa-se uma lacuna na literatura: a integração direta de modelos empíricos extraídos de ambientes de vegetação severa (como florestas tropicais) em simuladores de eventos discretos. A Tabela 1 sintetiza essa comparação, destacando que

Tabela 1. Comparação entre trabalhos relacionados em redes LoRa.

Trabalho	Ambiente	Modelo	Simulação	Ferramenta
[Petajajarvi et al. 2015]	Urbano	Empírico	Não	–
[Seye et al. 2018]	Rural	Empírico	Não	–
[Ruz-Nieto et al. 2023]	Urbano	Ray tracing	Sim	Própria
[Słabicki et al. 2018]	Geral	Simplificado	Sim	FLoRa
[Marini et al. 2021]	Geral	Analítico	Sim	LoRaWANSim
Este trabalho	Floresta tropical	Empírico (ODR+CI)	Sim	FLoRaExt

a maioria dos estudos foca ou na caracterização isolada ou em simuladores com modelos de propagação simplificados.

Diferente das abordagens citadas, este trabalho foca na validação de modelos empíricos específicos para a severa atenuação de florestas tropicais dentro do ecossistema OMNeT++/FLoRa. A contribuição reside na metodologia de extração de parâmetros via Regressão de Distância Ortogonal (ODR) e sua integração no simulador FLoRaExt, permitindo uma análise de rede mais fiel à realidade amazônica.

3. Modelagem de Propagação

A perda de percurso (*Path Loss*) é a redução na densidade de potência de uma onda eletromagnética à medida que ela se propaga pelo espaço. Segundo [Veluru Sai et al. 2017], essa atenuação é causada por fatores como absorção, refração, reflexão, difração e espalhamento do sinal. A modelagem correta da perda de percurso é crucial para o dimensionamento de redes sem fio, permitindo determinar o número ideal de estações base e a área de cobertura.

Modelos de propagação dividem-se em empíricos, determinísticos e estocásticos. Neste trabalho, optou-se por modelos empíricos devido à sua praticidade e precisão em cenários reais. Estes modelos são derivados de medições de campo, tornando-os mais representativos das condições reais de propagação do que modelos puramente teóricos [Veluru Sai et al. 2017]. Além disso, suas formulações matemáticas são frequentemente mais simples, facilitando a integração em ferramentas de planejamento de rede.

3.1. Coleta de Dados e Cenários Experimentais

Os dados utilizados para construir o modelo de propagação proposto foram coletados no cenário descrito em [Ferreira et al. 2020], sendo o local o Parque Nacional da Serra dos Órgãos (PARNASO), no estado do Rio de Janeiro. Cobrindo uma área de aproximadamente 20 mil hectares, o PARNASO é uma unidade de conservação federal que abriga uma vasta área de floresta tropical densa e topografia acidentada.

Os dados foram coletados ao longo de trilhas suspensas e no solo, utilizando dois protótipos de nós sensores e um nó fixo. Este trabalho aborda dois cenários principais de coleta:

- **Cenário A - Estático:** Pontos de medição foram determinados a intervalos de 50 metros a partir do nó receptor. A partir de 50 metros, não havia mais linha de visada (LoS) clara para o receptor. Nos pontos subsequentes, a visibilidade era completamente obstruída pela vegetação, caracterizando uma situação de Não-Visada (NLoS) severa. Este cenário é útil para observar a degradação pontual do sinal sob bloqueios estáticos e identificar a variância causada por obstáculos fixos.
- **Cenário B - Móvel:** Um transmissor moveu-se de uma distância de 250 metros (o alcance máximo obtido) em direção ao receptor (0 metro) a uma velocidade constante de aproximadamente 3 km/h (10 m/min). O objetivo deste cenário foi obter uma nuvem de pontos densa de medições de RSSI (*Received Signal Strength Indicator*) e SNR (*Signal-to-noise ratio*), capturando a variabilidade espacial do canal e o desvanecimento de pequena escala.

As Figuras 1a e 1b ilustram, respectivamente, o conceito dos cenários estático e móvel utilizados na campanha de medição. No cenário estático, a discretização dos pontos permite uma análise focada na distância, enquanto no cenário móvel, a continuidade do trajeto revela as flutuações rápidas do sinal.

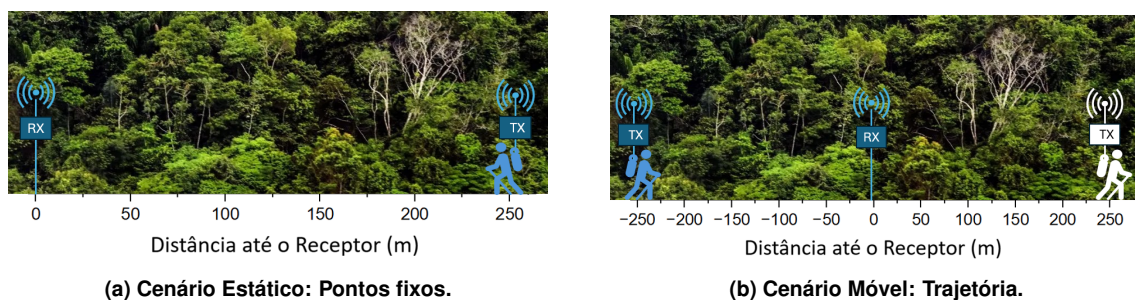


Figura 1. Representação dos cenários de coleta de dados.

3.2. Setup de Medição e Hardware

Para gerar e adquirir dados nos experimentos, [Ferreira et al. 2020] construiu dois protótipos baseados na plataforma Arduino Uno. A escolha deste *hardware* deve-se à sua flexibilidade e baixo custo, permitindo a replicação do experimento. Cada protótipo foi equipado com rádios LoRa, localizadores GPS com precisão de 2,5 metros [u blox 2011], e sensores ambientais. A Tabela 2 resume os componentes de *hardware* utilizados.

Para o canal de comunicação LoRa, utilizou-se a banda de frequência de 915 MHz, em conformidade com o plano de frequências AU915-928 adotado no Brasil pela ANATEL. A potência de saída foi fixada em 14 dBm. Embora o padrão suporte vários Fatores de Espalhamento (SF), para a modelagem de propagação neste estudo, empregou-se exclusivamente o SF 12. O SF 12 oferece a maior sensibilidade de recepção (ao custo de menor taxa de dados), sendo ideal para testar os limites de alcance em ambientes de alta atenuação. Os parâmetros detalhados estão na Tabela 3.

3.3. Análise dos Dados Coletados

A Figura 2 apresenta o comportamento do RSSI e da SNR, medidos nos dois cenários. Essa análise visual é fundamental para entender a dinâmica do canal antes da modelagem matemática.

Tabela 2. Componentes de Hardware dos Nós Protótipos [Ferreira et al. 2020].

<i>Hardware</i>	Modelo/Descrição Detalhada
Controlador	Arduino Uno R3 (ATmega328P, 16MHz)
Interface Sem Fio	Dragino RF96 (Baseado no Chipset Semtech SX1276)
Antena	Monopolo 7 dBi (Otimizada para 915 MHz)
Receptor GPS	U-blox NEO-6M (Protocolo NMEA, Precisão $\approx 2.5\text{m}$)
Sensor Ambiental	DHT22 (Temperatura: $\pm 0.5^\circ\text{C}$, Umidade: $\pm 2\%$)
Fonte de Energia	<i>Power Bank</i> 5V (Estabilizado via USB)

Tabela 3. Parâmetros de Configuração LoRa Utilizados.

Parâmetro	Valor Configurado
Frequência Central	915 MHz (Plano AU915)
Potência de Transmissão	14 dBm (25 mW)
Fator de Espalhamento (SF)	12 (Maior Alcance)
Largura de Banda (BW)	500 kHz
Taxa de Codificação (CR)	4/5 (Redundância moderada)
Tamanho da Carga Útil	20 Bytes (Coordenadas GPS + Sensor)

No cenário estático (esquerda da Figura 2), observa-se que a transição de LoS para NLoS aos 50 metros resulta em uma queda abrupta nas métricas, destacando o efeito prejudicial dos obstáculos da floresta. A dispersão vertical dos pontos em uma mesma distância indica a variabilidade temporal do canal, mesmo com transmissor e receptor parados, provavelmente devido ao movimento da folhagem pelo vento. No cenário móvel (direita da Figura 2), nota-se uma alta flutuação dos valores de RSSI em todas as distâncias. Isso é atribuído ao ambiente de floresta densa, onde árvores e folhagens causam desvanecimento por múltiplos percursos (*multi-path fading*) e sombreamento.

A dispersão dos pontos de dados sugere que, apesar de as redes LoRa atingirem vários quilômetros em ambientes abertos, elas não garantem alcances longos em florestas densas, onde distâncias superiores a 200 metros foram dificilmente alcançadas com confiabilidade. Isso impõe restrições severas ao planejamento da rede, exigindo maior densidade de gateways.

3.4. Modelo Matemático e Metodologia de Regressão

Para calcular a perda de percurso experimental em cada ponto, PL_{measured} , aplicouse a equação (1) (*Link Budget*) aos dados coletados:

$$PL_{\text{measured}} = P_{\text{TX}} + G_{\text{TX}} + G_{\text{RX}} - \text{RSSI}, \quad (1)$$

onde P_{TX} representa a potência efetiva de transmissão, G_{TX} e G_{RX} são os ganhos das antenas do transmissor e receptor, respectivamente, e RSSI é o valor da potência do sinal

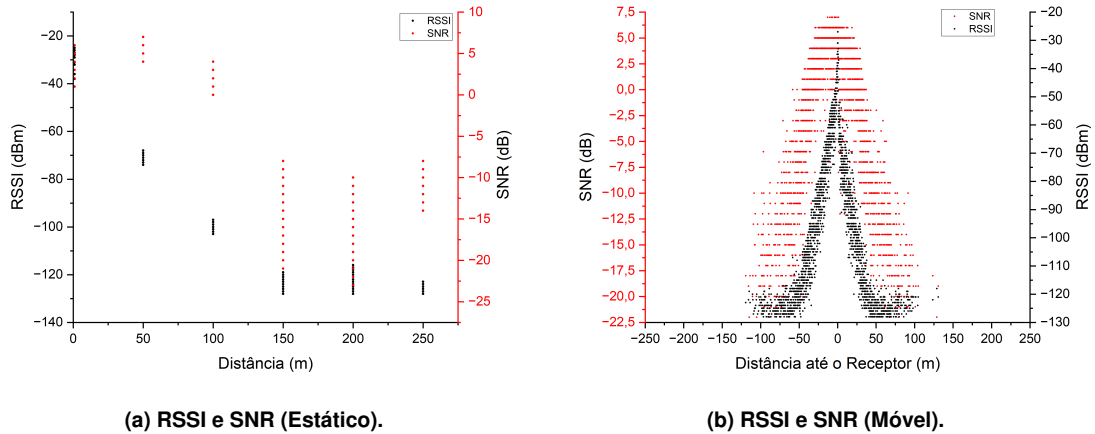


Figura 2. Comparação das métricas de sinal (RSSI e SNR) para os cenários.

recebido medido pelo rádio.

Baseando-se em trabalhos anteriores ([Linka et al. 2018, Lima et al. 2024]), decidiu-se realizar a modelagem baseada no método do Coeficiente de Regressão Log-Distância. Este modelo assume que a perda de percurso média aumenta logaritmicamente com a distância, conforme a equação (2).

$$EPL = B + 10 \cdot n \cdot \log_{10}(d/d_0), \quad (2)$$

onde EPL é a Perda de Percurso Esperada, B é a perda na distância de referência (d_0), n é o expoente de perda de percurso (que indica o quão rápido o sinal decai), e d é a distância entre transmissor e receptor.

Para extrair os parâmetros do modelo, empregou-se o algoritmo de Regressão de Distância Ortogonal (do inglês, *Orthogonal Distance Regression* - ODR). Ao contrário do método clássico de Mínimos Quadrados Ordinários, que minimiza apenas os resíduos verticais (erros na potência recebida, assumindo que a distância é perfeita), a ODR minimiza a soma das distâncias ortogonais quadradas dos pontos de dados até a curva ajustada. Essa abordagem é mais robusta para este tipo de experimento, pois leva em conta a variância intrínseca em ambos os eixos de medição: Y (Perda de Percurso, sujeita a ruído) e X (Distância GPS, que possui erro de precisão inerente de $\approx 2,5$ m).

No entanto, o ajuste da regressão do tipo ODR pode produzir inconsistências físicas (por exemplo, calcular um ganho de sinal a curtas distâncias, ou um valor de B negativo). Para resolver isso, neste trabalho, adotou-se uma estratégia híbrida combinando a ODR com a restrição de Referência Próxima (*Close-In* - CI). O valor de B foi fixado com base em medições empíricas na distância de referência ($d_0 = 1$ m), restringindo o algoritmo ODR a otimizar estritamente o expoente de perda de percurso (n).

3.5. Resultados da Modelagem

A Tabela 4 apresenta os parâmetros definitivos adotados. A seleção desses valores segue a abordagem híbrida (ODR + CI), priorizando a consistência física necessária para simulações subsequentes.

Tabela 4. Parâmetros de Regressão Selecionados (Método ODR + CI).

Parâmetro do Modelo	Cenário Estático	Cenário Móvel
Perda na referência (B) [dB]	54,57	72,86
Expoente de Perda (n)	3,95	4,23
Desvio Padrão de Sombreamento (σ) [dB]	11,89	6,61
Distância de Ref. (d_0) [m]	1,0	1,0
Coefficiente de Determinação (R^2)	0,984	0,964

Uma comparação detalhada entre os cenários destaca comportamentos distintos. Embora o cenário móvel apresente um expoente de perda de percurso ligeiramente maior ($n = 4,23$), indicando atenuação média mais forte ao longo do trajeto, ele exibe um desvio padrão significativamente menor ($\sigma = 6,61$ dB) em comparação ao caso estático ($\sigma = 11,89$ dB).

Esse resultado sugere que a amostragem espacial contínua inerente às medições móveis leva a um efeito de suavização das condições de sombreamento localizado. Em contraste, medições estáticas são mais influenciadas por características ambientais locais e pontuais (como uma árvore específica bloqueando o sinal), o que contribui para a maior dispersão dos dados.

Para garantir uma avaliação de rede conservadora e robusta, os parâmetros derivados do **cenário móvel** foram selecionados para a simulação de predição, pois capturam a média do comportamento da floresta de forma mais estável e representativa para nós distribuídos aleatoriamente.

4. Ferramentas e Configuração de Simulação

As simulações de rede LoRa foram executadas utilizando o *FLoRa-Ext* [Oliveira 2025]. O objetivo principal desta etapa é validar quantitativamente os resultados da simulação utilizando os parâmetros empíricos de propagação calculados.

4.1. Configuração de Sensibilidade do Rádio

A precisão da simulação da camada física depende diretamente dos limites de recepção do rádio. Para replicar o comportamento real do transceptor RFM95W [Hope Microelectronics 2014] (o chip central do módulo Dragino RF96), o módulo de rádio foi configurado com valores de sensibilidade correspondentes a várias combinações de Fatores de Espalhamento (SF) e Larguras de Banda (BW).

O módulo de propagação customizado, `LoRaEmpiricalPathLoss`, foi implementado no `FLoRaExt` utilizando a equação (2). Isso permite que os coeficientes empíricos (B , n e σ) sejam aplicados diretamente para replicar as características de atenuação e sombreamento do ambiente.

4.2. Parametrização do Consumo de Energia

O modelo de energia foi parametrizado com base nos perfis de consumo de corrente do dispositivo em seus diferentes estados operacionais (*sleep*, *idle*, recepção e transmissão). Como o *datasheet* do RFM95W especifica valores de consumo apenas para

níveis discretos de potência (+7, +13, +17, +20 dBm), foi realizada uma interpolação por ajuste de curva para estimar a corrente para todos os níveis intermediários utilizados pelo algoritmo de ADR (do inglês, *Adaptive Data Rate*). A Tabela 5 apresenta os valores interpolados utilizados na simulação.

Tabela 5. Parâmetros de Consumo de Corrente.

Estado	Corrente	Estado	Corrente
<i>Sleep</i>	0,2 μ A	Tx (+10 dBm)	22,34 mA
<i>Idle</i>	1,5 μ A	Tx (+12 dBm)	26,34 mA
Recepção (Rx)	10,3 mA	Tx (+14 dBm)	37,35 mA
Tx (+7 dBm)	20,00 mA	Tx (+17 dBm)	87,00 mA
Tx (+9 dBm)	21,06 mA	Tx (+20 dBm)	120,00 mA

5. Resultados e Análise

A análise dos resultados é estruturada em duas fases distintas: validação do ambiente de simulação e avaliação de desempenho de rede em larga escala.

5.1. Validação do Modelo de Propagação

Para validar se o ambiente de simulação reproduz com precisão as características de propagação observadas, os valores da Perda de Percurso Simulada ($PL_{simulated}$) gerados pelo FLoRaExt foram comparados com dados empíricos de campo.

A Figura 3 apresenta a comparação visual para ambos os cenários. No cenário estático (esquerda), a simulação reproduz corretamente a alta dispersão causada pelas diferenças ambientais específicas em cada ponto de coleta de dados. O erro quadrático médio (RMSE) calculado foi de **13,55 dB**. É importante notar que esse valor é comparável em magnitude ao desvio padrão empírico de sombreamento observado no campo ($\sigma = 11,89$ dB). Essa proximidade indica que o erro de simulação é amplamente impulsionado pela variabilidade estocástica intrínseca do ambiente, e não por um viés sistemático do modelo.

Para o cenário móvel (direita), o RMSE foi de **11,53 dB**. Embora esse valor seja superior ao desvio padrão do modelo (σ), é notavelmente inferior ao erro observado no cenário estático. Isso confirma que as medições móveis, ao atravessarem múltiplas zonas de coerência do canal, tendem a suavizar os efeitos de desvanecimento severo e localizado. Assim, o modelo móvel mostra-se adequado para simular nós distribuídos em uma área ampla, onde as condições médias prevalecem sobre obstruções pontuais.

5.2. Avaliação de Desempenho de Rede: Monitoramento de Encostas

Após a validação do modelo, explorou-se um cenário de aplicação crítica: o monitoramento de risco geotécnico em áreas de Mata Atlântica. Essas áreas caracterizam-se por topografia íngreme onde a expansão urbana não planejada leva a construções em encostas instáveis.

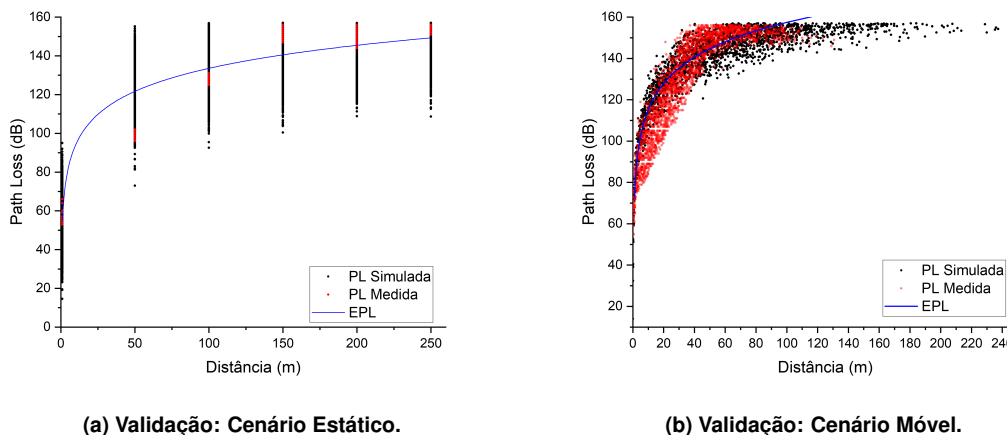


Figura 3. Comparação entre dados empíricos e de simulação.

5.2.1. Cenário e Parâmetros de Simulação

A topologia simulada corresponde a uma zona de risco de 300×300 metros, contendo uma malha densa de **1.000 nós sensores** distribuídos aleatoriamente. Essa alta densidade é necessária para capturar variações granulares na umidade do solo. O estudo avaliou a evolução da rede em três fases:

1. **Fase 1 - Baseline (4 Gateways - GWs):** Implantação padrão com 4 gateways nos vértices da área, usando parâmetros fixos (SF12).
2. **Fase 2 - Dimensionamento (9 Gateways - GWs):** Validação de uma grade densa de 3×3 gateways para garantir cobertura física.
3. **Fase 3 - Otimização Robusta (9 GWs + ADR):** Aplicação de um algoritmo de Taxa de Dados Adaptativa (do inglês, *Adaptive Data Rate - ADR*) baseado no “Min-SNR” [Słabicki et al. 2018].

Os parâmetros de simulação foram selecionados para corresponder às limitações de *hardware* observadas nos experimentos de campo. A Tabela 6 detalha as especificações físicas dos dispositivos, enquanto a Tabela 7 resume a configuração de transmissão da rede utilizada no cenário otimizado.

Tabela 6. Especificações de *Hardware*.

Parâmetro	Valor
Transceptor de Rádio	RFM95W (Semtech SX1276)
Ganho da Antena do Nó	2 dBi
Ganho da Antena do Gateway	6 dBi
Energia Inicial da Bateria	33,3 kJ (3,7 V, 2500 mAh)

5.2.2. Análise de Confiabilidade e Cobertura

O mapa de calor de Taxa de Entrega de Pacotes (do inglês, *Packet Delivery Ratio - PDR*) apresentados na Figura 4 evidencia a severidade do ambiente. No cenário **Baseline**

Tabela 7. Configuração de Transmissão e Rede.

Parâmetro	Valor
Tempo de Simulação	1 dia (86400 s)
Área de Cobertura	300 m × 300 m
Número de Nós	1000
Número de Gateways	4 (<i>Baseline</i>) e 9 (Otimizado)
Potência de Transmissão	7 dBm a 20 dBm
Frequência da Portadora	915 MHz
Largura de Banda	125 kHz
Fatores de Espalhamento	SF7 a SF12
Estratégia ADR	Min-SNR (Robusto)
Carga Útil da Aplicação	20 Bytes
Geração de Tráfego	Exponencial (Média: 60 s a 600 s)

(4 *Gateways* - GWs), observam-se vastas zonas vermelhas onde a taxa de entrega cai abaixo de 50% devido à atenuação da floresta. Já no cenário **Otimizado (9 GWs)**, o aumento da densidade cria uma “manta de cobertura” contínua (zonas azuis), eliminando pontos cegos críticos.

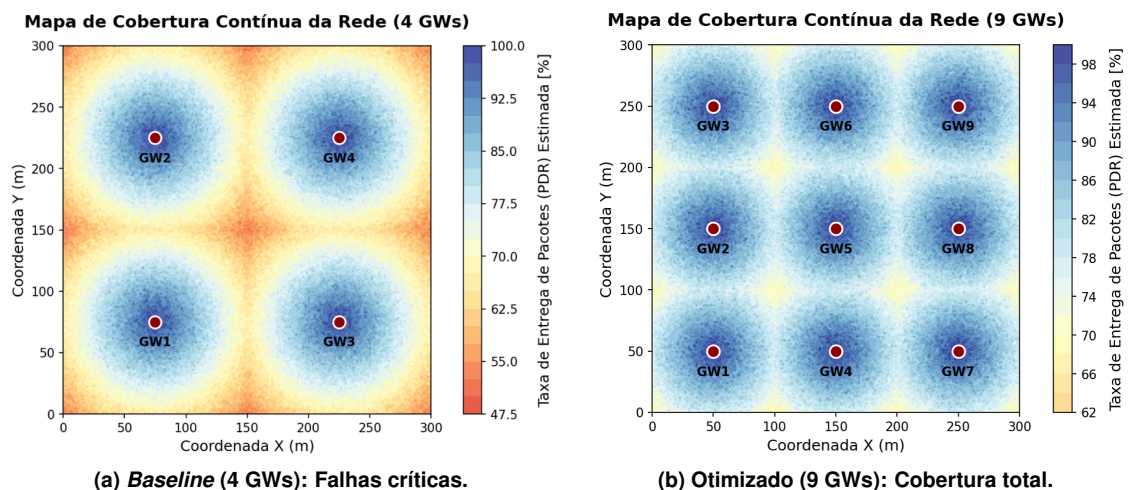


Figura 4. Mapas de calor de cobertura na área de 300 × 300 m.

A Figura 5 quantifica o impacto dessas configurações na confiabilidade. Os pontos pretos (*Baseline*) confirmam o colapso da rede para nós distantes mais de 60 metros. Em contrapartida, os pontos azuis (Otimizada com ADR) mostra que a combinação do aumento da densidade com a ADR mantém a PDR acima de 84% mesmo na borda da célula de cobertura.

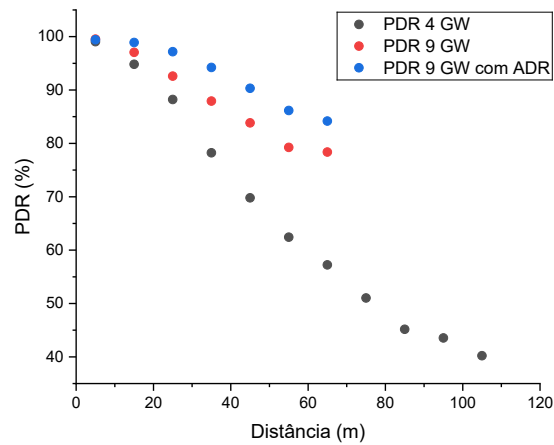


Figura 5. Impacto da Topologia e do ADR na Confiabilidade.

5.2.3. Eficiência Operacional e Consumo de Energia

Uma questão importante a ser avaliada é a relação entre o “tempo no ar” e capacidade da rede. No cenário *Baseline*, o uso forçado de SF12 gerou mais de 1,44 milhão de colisões. O cenário Otimizado, ao migrar para SFs mais rápidos, reduziu as colisões em **48,2%** (Tabela 8), aumentando a eficiência da rede. Contudo, pode-se observar um pequeno aumento no consumo de energia, já que há um incremento na quantidade de pacotes enviados. Isso gera um compromisso entre a entrega dos dados e o gasto energético.

Tabela 8. Análise da eficiência operacional e do consumo de energia.

Métrica	Baseline (Sem ADR)	Otimizado (ADR)	Variação
Tráfego e Confiabilidade			
Pacotes Enviados	112.100	128.970	+ 15,0%
Colisões Totais	1.441.780	746.917	- 48,2%
Energia e Sustentabilidade			
Energia Diária Média	11,44 J	12,15 J	+ 6,2%
Vida Útil da Bateria	≈ 8,0 Anos	≈ 7,5 Anos	- 0,5 Anos

A Tabela 9 detalha a convergência do algoritmo ADR. O sistema adota uma estratégia de “Alta Potência, Velocidade Moderada”, onde 90,8% dos nós convergiram para SF8 mantendo a potência máxima (20 dBm). Isso garante a margem de desvanecimento necessária para a floresta ($\sigma = 6,61$ dB) enquanto descongestiona o canal.

6. Conclusão

Além dos resultados específicos de desempenho, este trabalho consolidou uma metodologia sistemática de ponta-a-ponta: desde a coleta de dados brutos em campo,

Tabela 9. Resultados de Convergência do ADR: Alocação de Recursos.

SF	Contagem	Parte (%)	Distância Média (m)	Potência Tx (dBm)
SF7	0	0,0%	-	-
SF8	908	90,8%	37,56 ± 13,8	20,0 (Máx)
SF9	53	5,3%	53,08 ± 8,6	20,0 (Máx)
SF12	39	3,9%	50,55 ± 9,9	20,0 (Máx)

passando pela modelagem estatística robusta (ODR+CI), até a transposição fiel desses parâmetros para o ambiente de simulação. Embora a floresta tropical densa tenha sido utilizada como cenário de teste e validação devido à sua complexidade extrema, o procedimento desenvolvido é genérico e aplicável a qualquer ambiente de propagação (urbano, industrial ou agrícola).

A validação bem-sucedida neste cenário desafiador confirma que seguir este fluxo metodológico é crucial para garantir que as simulações de redes LPWAN deixem de ser aproximações teóricas e se tornem ferramentas de planejamento confiáveis. Para o caso específico de monitoramento de encostas, os resultados indicam que o aumento na densidade da rede e o uso de ADR robusto são fatores importantes para superar a atenuação da vegetação e garantir a segurança operacional do sistema.

Para as futuras direções deste trabalho, pretende-se aprimorar o *framework* de simulação FLoRaExt para fornecer uma representação ainda mais abrangente do comportamento da rede LoRaWAN. Os desenvolvimentos planejados incluem a implementação de suporte à comunicação multicanal, melhorias nos mecanismos da sub-camada MAC e a integração de componentes de rede adicionais, como *relays*.

Referências

- Aalto University (2025). *FLoRa: Framework for LoRa simulations with OMNeT++*. Disponível em: <https://flora.aalto.fi/>. Acesso em: 13 jan. 2026.
- Chen, M., Zhao, H., Shi, C., Chen, X., and Niu, D. (2023). Multi-scene lora positioning algorithm based on kalman filter and its implementation on ns-3. *Ad Hoc Networks*, 141:103097.
- Dieng, O. et al. (2020). Comparing path loss models for lorawan in tropical environments. In *2020 IEEE International Conference on Communications*.
- Ferreira, A., Ortiz, F., Costa, L., Foubert, B., Amadou, I., and Mitton, N. (2020). A study of the lora signal propagation in forest, urban, and suburban environments. *Annals of Telecommunications*, 75:333–351.
- Fraire, J., Madoery, P., Mesbah, M., et al. (2022). Simulating lora-based direct-to-satellite iot networks with florasat. In *2022 IEEE 23rd International Symposium on a World of Wireless, Mobile and Multimedia Networks (WoWMoM)*, pages 464–470.
- Haxhibeqiri, J., De Poorter, E., Moerman, I., and Hoebeke, J. (2018). A survey of lorawan for iot: From technology to application. *Sensors*, 18:3995.

- Hope Microelectronics (2014). *RFM95/96/97/98(W) - Low Power Long Range Transceiver Module VI.0*. Available online: https://cdn.sparkfun.com/assets/learn_tutorials/8/0/4/RFM95_96_97_98W.pdf, Acesso em 13/01/2026.
- INET Community (2025). *The INET Framework*. Disponível em: <https://inet.omnetpp.org/>. Acesso em: 13 jan. 2026.
- Lima, W., Lopes, A., Cardoso, C., et al. (2024). Lora technology propagation models for iot network planning in the amazon regions. *Sensors*, 24:1621.
- Linka, H., Rademacher, M., Aliu, O., and Jonas, K. (2018). *Path loss models for low-power wide-area networks: Experimental results using LoRa*. VDE Verlag.
- Marini, R., Mikhaylov, K., Pasolini, G., and Buratti, C. (2021). Lorawansim: A flexible simulator for lorawan networks. *Sensors*, 21:695.
- Masadan, A. et al. (2018). Lora propagation analysis in tropical vegetation. *IEEE Access*.
- Maurya, P., Hazra, A., Kumari, P., Sørensen, T., and Das, S. (2024). A comprehensive survey of data-driven solutions for lorawan: Challenges & future directions. *Authorea Preprints*.
- Mekki, K., Bajic, E., Chaxel, F., and Meyer, F. (2019). A comparative study of lpwan technologies for large-scale iot deployment. *ICT Express*, 5:1–7.
- Oliveira, F. (2025). *FLoRaExt: LoRa Simulator*. Disponível em: <https://github.com/ProfFabioOliveira/floraext/>. Acesso em: 13 jan. 2026.
- OMNeT++ Community (2025). *OMNeT++ Discrete Event Simulator*. Disponível em: <https://omnetpp.org/>. Acesso em: 13 jan. 2026.
- Petajarvi, J., Mikhaylov, K., Roivainen, A., Haapola, J., and Pouttu, A. (2015). On the coverage of lorawan deployments: City-wide measurements and analysis. In *2015 International Conference on Wireless Communications and Signal Processing (WCSP)*, pages 1–5. IEEE.
- Ruz-Nieto, A., Egea-Lopez, E., Molina-Garcia-Pardo, J.-M., and Santa, J. (2023). A 3d simulation framework with ray-tracing propagation for lorawan communication. *Internet of Things*, 24:100964.
- Seye, A., Ngom, B., Gueye, B., and Mansouri, A. (2018). A lorawan propagation model for rural areas. In *2018 IEEE Wireless Communications and Networking Conference (WCNC)*, pages 1–6. IEEE.
- Słabicki, M., Premsankar, G., and Di Francesco, M. (2018). Adaptive configuration of LoRa networks for dense IoT deployments. In *Proceedings of the IEEE/IFIP Network Operations and Management Symposium (NOMS)*, pages 1–9.
- u-blox (2011). *NEO-6 GPS Modules*. u-blox AG.
- Veluru Sai, A., Nithya, G., and Rao, S. (2017). A comprehensive survey of electromagnetic propagation models. In *Proceedings of the 2017 International Conference on Communication and Signal Processing (ICCSP)*, pages 1457–1462.