

Predição da Indicação de Intensidade do Sinal (RSSI) Recebido em Bosque Amazônico por meio de RNA, a Partir de Medidas com Drones em Alturas Superiores à Copa das Árvores

Maria C. D. P. Silva, Alex S. Macedo, Caio M. M. Cardoso,
Brenda S. S. Barbosa, Fabrício J. B. Barros, Jasmine P. L. Araújo.

Resumo—Este estudo utiliza uma Rede Neural Artificial (RNA) do tipo *Multilayer Perceptron* (MLP) para prever o RSSI em um ambiente florestal, com medições realizadas no Bosque Camilo Viana, UFPA. A comparação é feita com modelos de vegetação conhecidos, como Weissberger, FI e FITU-R. A RNA possui 3 parâmetros de entrada (alturas, ângulo, distância) e é treinada de forma supervisionada. A escolha da tecnologia LoRa se deve à sua capacidade de penetração em ambientes densos, destacando a importância da modelagem precisa do canal de propagação para esse tipo de ambiente. Nesse contexto, obteve-se um RMSE entre os dados medidos e previstos para o RSSI de 4,13 dB. Por fim, a aplicação do modelo MLP resultou em um RMSE de 4,95 dB para 110 m e de 3,70 dB para 50 m, demonstrando sua eficácia na previsão do sinal em comparação aos demais modelos.

Palavras-Chave—Amazônia, LoRa, MLP, Modelagem, Vegetação.

Abstract—This study uses an MLP-type Artificial Neural Network (ANN) to predict RSSI in a forest environment, with measurements carried out at Bosque Camilo Viana, UFPA. The comparison is made with known empirical models, such as Weissberger, FI and FITU-R. The ANN has 3 input parameters (heights, angle, distance) and is trained in a supervised manner. The choice of LoRa technology is due to its ability to penetrate dense environments, highlighting the importance of accurate modeling of the propagation channel for this type of environment. In this context, an RMSE was obtained between the measured and predicted data for the RSSI of 4.13 dB. Finally, the application of the MLP model resulted in a lower RMSE of 4.95 dB for 110 m and 3.70 dB for 50 m, demonstrating its effectiveness in predicting the signal at different distances.

Keywords—Amazon, LoRa, MLP, Modeling, Vegetation.

I. INTRODUÇÃO

Em novembro de 2025, o estado do Pará irá sediar a 30ª Conferência da ONU sobre Mudanças Climáticas (COP30). Enquanto a COP30 na Amazônia destaca a urgência de conservar e proteger uma das mais ricas biodiversidades do planeta, também lança luz sobre desafios tecnológicos cruciais. Em um ambiente onde a densa vegetação é um obstáculo, a cobertura e o canal de propagação tornam-se desafios substanciais, impactando diretamente a eficácia das soluções de Internet das coisas (*Internet of Things* - IoT).

Os autores pertencem ao Laboratório de Computação e Telecomunicações, Universidade Federal do Pará, Belém-Pará, email: maria.prado@itec.ufpa.br, alexsanchess@gmail.com, caio.cardoso@itec.ufpa.br, brendabarb@gmail.com, fbarros@ufpa.br, jasmine@ufpa.br

A principal característica da *IoT* é a capacidade de conectar diversos tipos de dispositivos à internet e dar autonomia para os mesmos, além de tornar sua utilização mais eficiente. Para realizar a conexão existem diversas tecnologias emergentes como: LoRa, Sigfox, NB-IoT as quais baseiam-se nos requisitos da aplicação, taxa de dados adequada, consumo de energia e longo alcance para determinar sua utilização [1].

A tecnologia LoRa (*Long Range*) foi escolhida, devido sua capacidade de penetrar em ambientes densos, e mais, ela está sendo amplamente utilizada, devido ao baixo custo de implantação e capacidade de fornecer comunicação confiável para longas distâncias, surgindo como uma tecnologia promissora [2].

Desde 2015, diversos trabalhos na literatura vem abordando o uso desta tecnologia para aplicações IoT, seja para monitoramento, gerenciamento ou analisando o canal de rádio nas frequências que o LoRa opera no Brasil, EUA ou Europa [3]–[7].

O uso de veículos aéreo não tripulados (VANT) ou drone nesse tipo de ambiente, tem se tornado tópico de diversas pesquisas nos últimos anos, como visto em [3]. Isto ocorre devido a sua ampla gama de aplicações, incluindo sua autonomia e flexibilidade. Sendo assim, é importante saber selecionar de forma adequada o veículo de acordo com a aplicação utilizada [4].

No estudo de [6], foram comparados os modelos CI e FI com o modelo Okumura-Hata para estimar a perda de percurso em ambientes com vegetação amazônica. Um novo modelo, PLveg, foi introduzido para calcular a perda de percurso em áreas onde medições diretas não são viáveis. Os valores de RMSE para os diferentes modelos e fatores de propagação foram determinados, destacando a eficácia do modelo PLveg em ambientes densamente arborizados.

No entanto, a eficácia da tecnologia LoRa em ambientes de vegetação densa depende da compreensão precisa da propagação do sinal, para isso uma modelagem de canal se faz necessária.

O estudo da modelagem do canal de propagação tem sido tradicionalmente realizado por meio de modelos empíricos ou determinísticos. No entanto, recentemente, a inteligência artificial (IA) tem emergido como uma ferramenta promissora para aprimorar a precisão nos projetos de comunicações móveis, especialmente na criação de novos modelos de propagação

baseados em IA. Agregado a tudo isso, utilizamos a arquitetura *Multilayer Perceptron* (MLP), uma das técnicas existente de aprendizado de máquina, para prever a intensidade do sinal em ambiente de bosque Amazônico.

Um estudo recente, realizado na Universidade Federal do Pará, conduzido pelos autores em [6], investigou a influência de áreas arborizadas, especialmente a Floresta Amazônica, na qualidade do sinal de dispositivos *IoT* que utilizam comunicação sem fio, como a tecnologia LoRa em SF12. O estudo envolveu transmissões com diferentes alturas e o receptor percorrendo 250 metros floresta adentro.

Para analisar o efeito das árvores amazônicas na propagação do sinal, foram desenvolvidos dois modelos de propagação baseados em aprendizado de máquina: o *Generalized Regression Neural Network* (GRNN) e a MLP. Estes modelos mostraram uma precisão superior em comparação com modelos empíricos existentes, como CI, FI, Early ITU-R, COST235, Weissberger e FITU-R.

Neste contexto, este artigo tem o como objetivo realizar a predição de RSSI utilizando técnica de redes neurais artificiais através de dados coletados em ambiente real, na tecnologia LoRa em 915 MHz, SF7, em *uplink* com transmissor dentro da vegetação e na recepção um end-node acoplado a um drone para captura de dados. Esse tipo de comunicação, permite-nos simular diversas situações. Entre elas, uma aplicação de busca e resgate de uma pessoa perdida na floresta em cenários montanhosos, aplicação estudada em [9].

Esta pesquisa tem o potencial de impulsionar as comunicações sem fio em ambientes arborizados, contribuindo para o aprimoramento de redes LoRa mais eficientes e robustas, com aplicações em agricultura, monitoramento ambiental e infraestrutura urbana inteligente. Além disso, propõe ser um modelo de propagação baseado em aprendizado de máquina, MLP, comparando-o com os modelos modelos de vegetação Weissberger, FI, FITU-R.

Este artigo organiza-se da seguinte forma: na seção II apresenta a metodologia de campanha de medições; seção III apresenta-se os modelos de propagação para ambientes de floresta utilizados para comparação; seção IV é apresentado o modelo utilizado no trabalho; na seção V ocorre a análise de resultados e por fim, as conclusões na seção VI.

II. CAMPANHA DE MEDIÇÕES

A. Cenário

O cenário escolhido para realizar a campanha de medições é o Bosque Camilo Viana, situado no Campus Belém da Universidade Federal do Pará (UFPA), uma das instituições de ensino superior mais importantes da região Norte do Brasil. Este bosque abrange uma área de aproximadamente $16.700 m^2$ e apresenta características de vegetação típica da região Amazônica, composto por sete espécies nativas, destacam-se entre elas o Pau-Mulato (*Calycophyllum spruceanum*), reconhecido por sua significativa importância, conforme apresentado por [6]. A Figura 1 proporciona uma visão do bosque.

O caminho percorrido pelo drone como *gateway IoT* para a captura dos dados está ilustrado na Figura 2, nela também é possível observar a barra de nível de RSSI, quanto mais clara a cor da barra, melhor é o RSSI próximo ao Tx central.



Fig. 1. Drone, equipamentos e Bosque Camilo Viana.

A metodologia aplicada para aquisição e armazenamento de dados foi utilizando o arduino uno, dois shields Dragino LoRa em 915 MHz e um cartão microSD San Disk. Para realizar a comunicação entre transmissor (Tx) e receptor (Rx), foi acoplado em cada shield uma antena modelo TX915-JKS-20 omnidirecional, com 3 dBi de ganho, potência de transmissão setada em 5 dBm, fator de espalhamento SF7, largura de banda 125 KHz, os quais utilizam o chip sx1276 da SEMTECH e o protocolo LoRaWAN. Além disso, utilizou-se um drone modelo Inspire 1, conforme mostrado na Figura 1.



Fig. 2. Percurso do Drone pelo Bosque Camilo Viana.

O fator de espalhamento ou *Spreading Factor* (SF), da tecnologia LoRa, varia do SF7 ao SF12. Um fator de espalhamento pequeno permite uma maior taxa de dados a serem transmitidos e consequentemente menor quantidade de enlaces necessários para comunicar-se com o receptor, permitindo a economia de bateria e tempo de transmissão [9], por isso foi escolhido SF7 para o desenvolvimento deste trabalho.

B. Dados

A Figura 3 apresenta os dados coletados da perda no percurso pelo ângulo nas alturas de 50 m e 110 m. Através dela, observa-se que quanto menor o ângulo de incidência do raio

transmitido, maior é a perda de percurso. Além disso, nota-se que para ângulos similares, em alturas mais elevadas, a perda de percurso possui um comportamento mais diversificado, ou seja, um elevado desvio padrão.

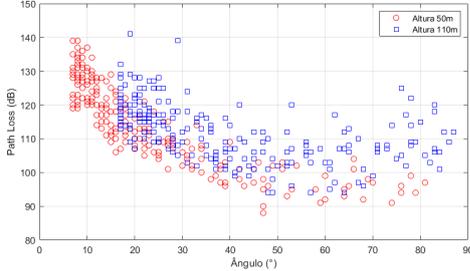


Fig. 3. Dados Capturados.

C. Modelagem de Canal

A Figura 4 ilustra a modelagem de canal realizada neste estudo. O transmissor está dentro da área de vegetação e a recepção dos dados foi feita em duas alturas: 50 e 110 metros.

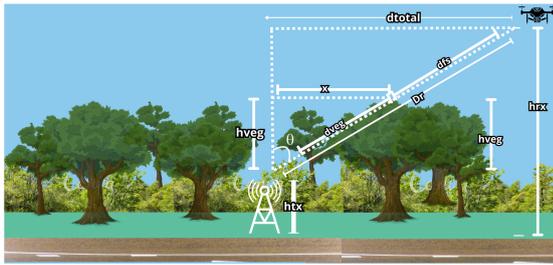


Fig. 4. Modelagem de Canal.

O drone percorreu uma distância (dt) de 350 m em uma velocidade média de 30 km/h. A análise representativa dos dados será em função do ângulo θ e dr que representa a distância radial entre TX e RX. A altura do drone, Rx, é representada por hrx ; dfs é a distância correspondente ao espaço livre; htx é a altura de TX; $hveg$ é a altura de folhagem, onde foi considerada uma altura média para toda a floresta de 15 m e $dveg$ a distância radial de vegetação.

$$dveg = \frac{hveg}{\cos(\theta)} \quad (1)$$

III. MODELOS DE PROPAGAÇÃO

Os modelos de propagação são essenciais na engenharia de comunicação, permitindo prever como os sinais se propagam em diferentes ambientes. Nesta seção, apresentaremos alguns dos modelos de vegetação mais utilizados na literatura, explorando suas características e aplicações específicas. Compreender esses modelos é crucial para o desenvolvimento de sistemas de comunicação sem fio para áreas vegetadas, tornando-os mais confiáveis e eficientes.

A. Floating Intercept (FI) Model

O modelo FI requer dois parâmetros, um para o deslocamento da perda de percurso medida, α , e o outro coeficiente β que depende da distância. Na Equação 2 apresenta-se o modelo FI [8]:

$$PL_{FI} = \alpha + 10\beta \log_{10}(d) + X_{\sigma}^{FI} \quad (2)$$

onde

- PL é a perda de propagação do sinal (dB);
- α é o deslocamento da perda de percurso medida (dB);
- β é a frequência de operação do sistema (MHz)
- d é a distância entre Tx e Rx (m);
- X_{σ}^{FI} é a variável de desvanecimento.

B. Fitted ITU-R (FITU-R) Model

Este modelo, proposto em 1998, foi originado como um aprimoramento do modelo ITU-R, introduziu o conceito de diferenciar equações do modelo de previsão com base na sazonalidade experimentada por vegetação [6]. Neste estudo é considerada a equação com presença de folhas. As equações para calcular a perda excessiva adicionada à perda de espaço livre são as seguintes:

$$Att_{FITU-R} = \begin{cases} 0.37 * f^{0.18} * d^{0.59}, & \text{se sem folhas} \\ 0.39 * f^{0.39} * d^{0.25}, & \text{se com folhas} \end{cases} \quad (3)$$

onde

- Att é o excesso de atenuação segundo o modelo de FITU-R (dB);
- d é a distância entre Tx e Rx (m);
- f é a frequência de operação do sistema (MHz).

C. Weissberger (WEIS) Model

Este modelo é aplicável em situações onde a propagação do sinal sem fio ocorre em ambientes arborizados e a distância entre as antenas de transmissão e recepção deve ser de até 400 m, na faixa de frequência de 230 MHz a 96 GHz [6]. Sua equação para o cálculo da perda excessiva, somada à perda de espaço livre, é dada por:

$$Att_{weis} = \begin{cases} 1.33 * f^{0.284} * d^{0.588}, & \text{se } 14m < d < 400m \\ 0.45 * f^{0.284} * d, & \text{se } 0m < d < 14m \end{cases} \quad (4)$$

onde

- Att é o excesso de atenuação segundo o modelo de Weissberger (dB);
- d é a distância entre Tx e Rx (m);
- f é a frequência de operação do sistema (MHz).

IV. TREINAMENTO DA RNA

As MLPs são um tipo de Redes Neurais Artificiais (RNA) capazes de aprender com exemplos fornecidos durante o treinamento. A propagação dos dados ocorre diretamente da camada de entrada para a camada de saída, passando por

neurônios que possuem funções de ativação capazes de introduzir não-linearidade na rede e permitindo que ela aprenda relações complexas entre os dados.

Uma vez que a rede tenha sido treinada, ela pode ser usada para fazer previsões ou classificar novos exemplos de entrada. Através do processo de propagação direta, a rede realiza uma série de operações matemáticas e ativações de neurônios, processando os dados de entrada e gerando uma saída final [6].

A estrutura utilizada para o desenvolvimento do modelo de previsão do RSSI com redes LoRa utiliza 3 parâmetros de entrada (ângulo, altura e distância), uma camada oculta e uma camada de saída composta pelos valores do RSSI. O software utilizado para a implementação da RNA foi o MATLAB®, com 3 neurônios na camada de entrada; 15 neurônios na camada oculta, com função de ativação sigmoide; 1 neurônio na camada de saída, com função de ativação linear, exibida na Figura 5. Foi aplicado o treinamento supervisionado, utilizando-se o algoritmo *Levenberg-Marquardt*.

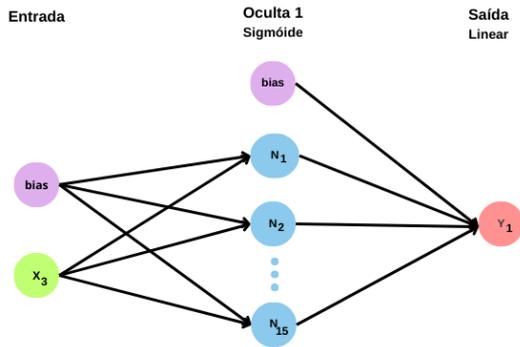


Fig. 5. MLP implementada.

A RNA foi treinada utilizando 450 amostras distribuídas aleatoriamente em três conjuntos, 314 pontos no conjunto de treinamento correspondendo à 70% dos dados totais, os conjuntos de validação e teste contém 68 pontos cada um, correspondendo aos 30% do total de amostras, como é exibido na Tabela I.

TABELA I
DIVISÃO DOS DADOS.

Conj. de Amostras	N. de Amostras	% de amostras
Treinamento	314	70%
Validação	68	15%
Teste	68	15%

Ao longo do desenvolvimento do modelo proposto, foram testadas algumas topologias de MLP, variando o número de neurônios disponíveis na camada oculta. De acordo com a Tabela II, observa-se que a topologia que obteve o melhor desempenho foi a que possui 15 neurônios, na camada escondida, com o RMSE de 4,12.

V. RESULTADOS

Nesta seção, serão apresentados os resultados obtidos na implementação da RNA proposta, para prever os parâmetros

TABELA II
TOPOLOGIAS TESTADAS DA MLP.

Camada Oculta	Num Neurônios	RMSE
1	20	4,13
1	17	4,20
1	15	4,12
1	12	4,75
1	10	4,86
1	07	4,57
1	05	4,98

de saída RSSI, a partir dos dados de entrada, ângulo, altura e distância para redes LoRa em *uplink*, com transmissor dentro da vegetação e na recepção um *end-node* acoplado a um drone para captura dos dados, parâmetros disponíveis na Tabela III, e a comparação com os modelos empíricos para ambientes com vegetação FI, FITU-R, Weissberger.

TABELA III
PARÂMETROS DO SISTEMA.

Parâmetros	Valores
SF	7
Frequência	915 MHz
Alturas	50 e 110m
Polarização	Vertical Vertical

A fim de verificar a capacidade de previsão do método, foi utilizada a métrica: *Root Mean Square Error*, que é uma métrica capaz de indicar a acurácia de modelos [6], com ela foi realizada a comparação dos dados coletados com os resultados da saída da rede como está visível na Figura 6. Vale ressaltar que o modelo foi treinado com os dados das duas alturas apresentadas, o RMSE obtido entre os dados medidos e preditos para o RSSI é de 4,13 dB.

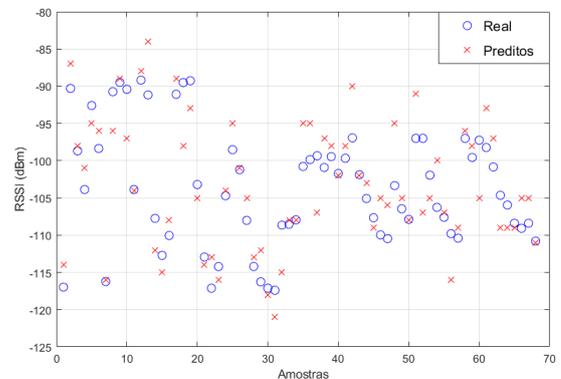


Fig. 6. Real x Preditos.

As Figuras 7 e 8 mostram que o modelo MLP para as duas alturas, 50 m e 110 m, na situação de *uplink*, foi o que melhor

se ajustou aos dados medidos, sendo seguido pelo modelo FI, FITU-R e Weissberger.

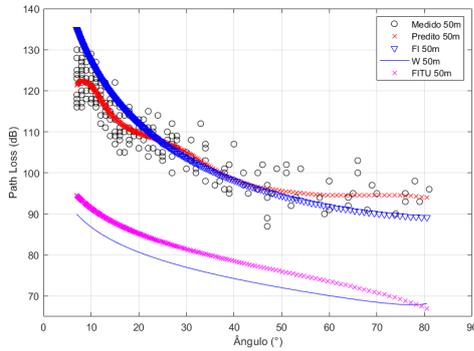


Fig. 7. Comparação dos Modelos para Distância de 50 m

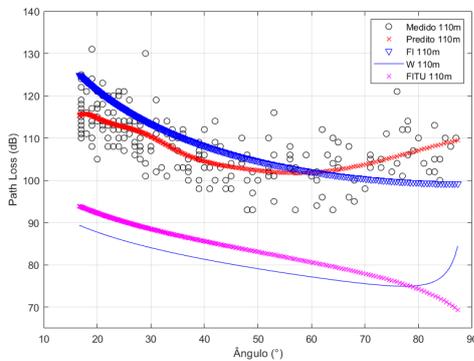


Fig. 8. Comparação dos Modelos para Distância de 110 m.

Conforme a Tabela IV, podemos analisar a comparação entre os modelos de propagação utilizados neste artigo, e observar que o modelo proposto teve uma acurácia melhor, tanto para altura de 50 m quanto para a de 110 m, 3,70 dB e 4,95 dB, respectivamente.

TABELA IV
COMPARAÇÃO DO PARÂMETRO RMSE ENTRE OS MODELOS.

Modelos	110m	50m
FI	7,35 dB	5,56 dB
FITU-R	23,09 dB	28,74 dB
MLP	4,95 dB	3,70 dB
WEISSB.	26,71 dB	32,99 dB

VI. CONCLUSÕES

Este estudo apresenta a aplicação bem-sucedida de redes neurais artificiais, MLP, para prever o RSSI em ambientes florestais utilizando a tecnologia LoRa em situações de *Uplink*. A comparação com modelos empíricos demonstra a eficácia e precisão do modelo proposto, com erros de 3,70 dB e de 4,95 dB, em relação aos dados medidos.

A modelagem do canal de propagação em ambientes arborizados é crucial para o desenvolvimento de redes LoRa mais eficientes e robustas, com potenciais aplicações em setores como agricultura, monitoramento ambiental e infraestrutura urbana inteligente.

Por tanto, para trabalhos futuros pretende-se estudar o comportamento de outras técnicas com IA aplicados para ambientes com vegetação, mas faz-se necessário a realização de mais medições para aumentar a complexidade e variabilidade dos dados.

AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação de Engenharia Elétrica (PPGEE) da UFPA, por meio do grupo de pesquisa do Laboratório de Computação e Telecomunicações (LCT), a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior- Brasil (CAPES).

REFERÊNCIAS

- [1] Carvalho, A.R. Jovel, et. al. "Transmissão de Dados em um sistema IoT Utilizando Tecnologia LoRaWan". 20º Simpósio Brasileiro De Micro-Ondas E Optoeletrônica 2022.
- [2] Jouhari, M., Saeed, N., Alouini, M.-S., and Amhoud, E. M. (2023). A survey on scalable lorawan for massive iot: Recent advances, potentials, and challenges. IEEE Communications Surveys Tutorials, 25(3):1841–1876.
- [3] J. Supramongkonset, et. al., "A WiFi Link Budget Analysis of Drone-based Communication and IoT Ground Sensors,"2021 7th International Conference on Engineering, Applied Sciences and Technology (ICE-AST),Thailand, 2021, pp.234-237.
- [4] F. De Rango and D. Stumpo, "Supporting Path Planning in LoRa-based UAVs for dynamic Coverage for IoT devices,"2023 IEEE 20th Consumer Communications and Networking Conference (CCNC), Las Vegas, NV, USA, 2023, pp. 337-340.
- [5] Paiva, B. S., da Luz, L. M., and da Silva, C. N. (2022). Sistemas de áreas verdes da Cidade Universitaria Professor José da Silveira Netto, da UFPA, em Belém (PA). v. 25, n. 1, p. 297-323, jan-abr 2022, ISSN485 1516-6481 / 2179-7536
- [6] Barbosa, BSdS; Cruz, HAO; Macedo, AS; Cardoso, CMM; Fernandes, FC; Eras, LEC; Araújo, JPLd; Calvacante, GPS; Barros, FJB. Application of Artificial Neural Networks for Prediction of Received Signal Strength Indication and Signal-to-Noise Ratio in Amazonian Wooded Environments. Sensors 2024 , 24 , 2542. <https://doi.org/10.3390/s24082542>
- [7] Lima, WG; Lopes, AVR; Cardoso, CMM; Araújo, JPL; Neto, MCA; Tostes, MEL; Nascimento, AA; Rodríguez, M.; Barros, FJB. LoRa Technology Propagation Models for IoT Network Planning in the Amazon Regions. Sensors 2024 , 24 , 1621. <https://doi.org/10.3390/s24051621>
- [8] Macedo, AS et al. 2023. Channel Analysis for 3.5 GHz Frequency in Airport. Journal of Communication and Information Systems. 38, 1 (agosto de 2023), 115–120. DOI: <https://doi.org/10.14209/jcis.2023.13>
- [9] G. M. Bianco, R. Giuliano, G. Marrocco, F. Mazzenga and A. Mejia-Aguilar, "LoRa System for Search and Rescue: Path-Loss Models and Procedures in Mountain Scenarios,"in IEEE Internet of Things Journal, vol. 8, no. 3, pp. 1985-1999, 1 Feb.1, 2021, doi: 10.1109/JIOT.2020.3017044.