



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA



Técnicas Inteligentes para Identificação de Linha de Visada e Alocação de Fator de Espalhamento em Redes LoRaWAN

Lucas Lima de Oliveira

DISSERTAÇÃO DE MESTRADO
Juiz de Fora, MG
2025



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA



Técnicas Inteligentes para Identificação de Linha de Visada e Alocação de Fator de Espalhamento em Redes LoRaWAN

Lucas Lima de Oliveira

Dissertação apresentada ao Departamento de Engenharia Elétrica da Universidade Federal de Juiz de Fora como parte dos requisitos exigidos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de Concentração: Sistemas Eletrônicos

Orientador: Prof. Dr. Álvaro Augusto Machado de Medeiros

Coorientador: Prof. Dr. Vicente Ângelo de Sousa Junior

Juiz de Fora, MG

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Oliveira, Lucas Lima de.

Técnicas Inteligentes para Identificação de Linha de Visada e Alocação de Fator de Espalhamento em Redes LoRaWAN / Lucas Lima de Oliveira. -- 2025.

76 f. : il.

Orientador: Álvaro Augusto Machado de Medeiros

Coorientador: Vicente Ângelo de Sousa Junior

Dissertação (mestrado acadêmico) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia. Programa de Pós-Graduação em Engenharia Elétrica, 2025.

1. LoRaWAN. 2. Alocação de Fator de Espalhamento. 3. Aprendizado por Reforço. 4. Eficiência Energética. 5. Perda de Percurso. I. Medeiros, Álvaro Augusto Machado de, orient. II. Sousa Junior, Vicente Ângelo de, coorient. III. Título.

Lucas Lima de Oliveira

Técnicas Inteligentes para Identificação de Linha de Visada e Alocação de Fator de Espalhamento em Redes LoRaWAN

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do título de Mestre em Engenharia Elétrica. Área de concentração: Sistemas Eletrônicos

Aprovada em 13 de março de 2025.

BANCA EXAMINADORA

Prof. Dr. Álvaro Augusto Machado de Medeiros - Orientador

Universidade Federal de Juiz de Fora

Prof. Dr. Vicente Ângelo de Sousa Júnior - Coorientador

Universidade Federal do Rio Grande do Norte

Dr. André Mendes Cavalcante

Ericsson Research

Prof. Dr. Luciano Jerez Chaves

Universidade Federal de Juiz de Fora

Juiz de Fora, 14/02/2025.



Documento assinado eletronicamente por **VICENTE ANGELO DE SOUSA JUNIOR, Usuário Externo**, em 13/03/2025, às 17:27, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Alvaro Augusto Machado de Medeiros, Professor(a)**, em 13/03/2025, às 17:27, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **André Mendes Cavalcante, Usuário Externo**, em 13/03/2025, às 17:29, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Luciano Jerez Chaves, Professor(a)**, em 13/03/2025, às 17:32, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2247213** e o código CRC **65A244C5**.

Agradecimentos

Agradeço à minha mãe (*in memoriam*) que me ensinou a ter coragem e força para seguir em frente e acreditou sempre na pessoa que um dia eu me tornaria. Meu pai, que nunca mediu esforços para me auxiliar sempre que possível e pelo apoio. Foi um período de muita felicidade e desenvolvimento, com muitos desafios que engradeceram o processo.

À Lízia, minha irmã, por ser quem ela é: minha melhor amiga e pessoa que me faz querer acordar uma pessoa melhor a cada dia.

À Letícia, pelo amor, carinho, paciência, compreensão e apoio durante esse período.

Agradeço ao meu orientador, a quem felizmente posso chamar de amigo, que foi peça fundamental do início ao fim desse ciclo, pela amizade, incentivo, aprendizado, participação em projetos e contribuição neste trabalho. Álvaro sempre esteve presente nos momentos difíceis e a confiança depositada em mim foi essencial para esta conquista. Agradeço pela oportunidade a mim permitida, levarei com muito carinho os momentos de aprendizado, desenvolvimento e descontração.

Agradeço também ao meu co-orientador Vicente Sousa, pela amizade, dedicação e por proporcionar grande aprendizado em conjunto com Álvaro e Gabriel durante esse período. Sentirei saudades das reuniões sexta pela manhã.

Aos meus amigos Raphael Sachetto, Francisco Freitas e Filipe de Jorge que sempre se fizeram presente nesta caminhada.

Ao Gabriel Macêdo pela parceria, discussões e contribuições neste trabalho.

Ao Leonardo Azalim pela contribuição na campanha de medição.

À UFJF, por todos os excelentes anos, incluindo graduação, vividos com grandes alegrias, crescimento e desenvolvimento.

Ao PPEE e à CAPES, pelo apoio e suporte durante o trabalho.

Dedico este trabalho à minha mãe, que apesar de não estar mais nesse plano, olha por mim de onde estiver.

Resumo

Este trabalho investiga estratégias inteligentes para otimizar o desempenho e reduzir o consumo energético em redes LoRaWAN, por meio do uso de aprendizado por reforço para alocação dinâmica de fatores de espalhamento fundamentada na identificação da presença de linha de visada entre os nós da rede. Para tanto, o trabalho integra uma campanha de medição real no ambiente da Universidade Federal de Juiz de Fora (UFJF) junto a simulações utilizando o simulador ns-3 para validar as estratégias propostas. Os resultados evidenciam que a integração de técnicas de modelagem de canais e a adoção de aprendizado por reforço possibilitam uma alocação mais eficiente dos parâmetros de transmissão, resultando em ganhos relevantes na taxa de entrega de pacotes e na eficiência energética dos dispositivos.

Palavras-chave: LoRaWAN, Alocação de Fatores de Espalhamento, Inteligência Artificial, Perda de Percurso, Análise de Desempenho, Aprendizado por Reforço, Classificação, Eficiência Energética.

Abstract

This work investigates intelligent strategies to optimize performance and to reduce energy consumption in LoRaWAN networks by using Reinforcement Learning for the dynamic allocation of spreading factors, based on the identification of line-of-sight conditions between network nodes. For this, this work incorporates a real-world measurement campaign conducted at the Federal University of Juiz de Fora (UFJF) alongside simulations using the ns-3 simulator to validate the proposed strategies. The results indicate that the integration of channel modeling techniques and the adoption of reinforcement learning enable a more efficient allocation of transmission parameters, yielding significant improvements in packet delivery rates and energy efficiency of devices.

Keywords: LoRaWAN, Spreading Factor Allocation, Artificial Intelligence, Machine Learning, Path Loss, Performance Evaluation, Reinforcement Learning, Energy Efficiency.

Lista de ilustrações

Figura 1 – Topologia LoRaWAN. Fonte: [46]	7
Figura 2 – Comportamento da classe A. Adaptado de [56]	12
Figura 3 – Comportamento da classe B. Adaptado de [56]	13
Figura 4 – Comportamento da classe C. Adaptado de [56]	13
Figura 5 – Corrente para cada classe. Adaptado de [56]	14
Figura 6 – Comparação entre o modelo analítico (a) e o modelo simulado (b). Adaptado de [22]	16
Figura 7 – Consumo energético para cada SF. Elaborado pelo Autor	18
Figura 8 – Consumo energético por algoritmo. Elaborado pelo Autor.	19
Figura 9 – PLR e PIR para cada algoritmo. Elaborado pelo Autor.	20
Figura 10 – Impacto em consumo e desempenho aumentando potência de transmissão. Elaborado pelo Autor.	22
Figura 11 – Impacto no desempenho aumentando SF. Elaborado pelo Autor.	23
Figura 12 – Mapa da campanha de medição com destaque para posição do GW. Elaborado pelo Autor.	28
Figura 13 – Matriz de Correlação entre os parâmetros. Elaborado pelo Autor.	32
Figura 14 – Diagrama de Radiação no plano de Elevação da antena utilizada. Elaborado pelo autor.	40
Figura 15 – Gráfico Perda de percurso (dB) em função de $\log_{10}(d)$ (m) para LOS. Elaborado pelo autor.	42
Figura 16 – Gráfico Perda de percurso (dB) em função de $\log_{10}(d)$ (m) para NLOS. Elaborado pelo autor.	43
Figura 17 – PDR em função do raio para EDs com canais 100% NLOS. Elaborado pelo autor.	46
Figura 18 – PDR em função do raio para EDs com canais 100% NLOS. Elaborado pelo autor.	47
Figura 19 – Convergência do MAB para QoSE ($\alpha = 1,0$) x Raio (m) , com $\delta =$ $1,0$ na primeira metade e $\delta = 0,0$ na segunda metade da simulação. Elaborado pelo autor.	57
Figura 20 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 100% NLOS. Elaborado pelo autor.	58
Figura 21 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 100% LOS. Elaborado pelo autor.	59
Figura 22 – QoSE ($\alpha = 1,0$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.	60
Figura 23 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.	61
Figura 24 – QoSE ($\alpha = 0,5$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.	63

Figura 25 – QoSE ($\alpha = 0,25$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.	64
Figura 26 – Vida útil da bateria em situação $\delta = 0,75$ e $\alpha = 0,75$ para ADR e MAB. Elaborado pelo autor.	66

Lista de tabelas

Tabela 1 – Sensibilidade dos dispositivos para cada SF. Fonte: [51]	8
Tabela 2 – Corrente em cada modo de operação para SX1272. Fonte: [22]	12
Tabela 3 – Tipos de baterias utilizadas em LoRaWAN	17
Tabela 4 – Configurações da simulação.	19
Tabela 5 – Parâmetros de simulação.	21
Tabela 6 – Aumento de consumo ao aumentar a potência de transmissão para o SF7.	21
Tabela 7 – Configurações da quinta simulação.	22
Tabela 8 – Aumento de consumo ao aumentar a potência de transmissão no SF7.	23
Tabela 9 – Configurações da antena.	27
Tabela 10 – Configurações do <i>Gateway</i>	27
Tabela 11 – Configurações do <i>End Device</i>	27
Tabela 12 – Desempenho dos modelos - média e desvio-padrão.	36
Tabela 13 – Parâmetros para propagação dos canais LOS e NLOS.	42
Tabela 14 – Parâmetros de simulação.	44
Tabela 15 – Ganho de desempenho de MAB na comparação com ADR e <i>Random</i> para Cenário 1 e $\alpha = 0,75$	57
Tabela 16 – Ganho de desempenho de MAB na comparação com ADR e <i>Random</i> para Cenário 2 e $\alpha = 0,75$	59
Tabela 17 – Ganho de desempenho de <i>Multi-Armed Bandits</i> (MAB) na comparação com ADR e <i>Random</i> para Cenário 3 e $\alpha = 1,0$	60
Tabela 18 – Ganho de desempenho de MAB na comparação com ADR e <i>Random</i> para Cenário 3 e $\alpha = 0,75$	62
Tabela 19 – Ganho de desempenho de MAB na comparação com ADR e <i>Random</i> para Cenário 3 e $\alpha = 0,50$	62
Tabela 20 – Ganho de desempenho de MAB na comparação com ADR e <i>Random</i> para Cenário 3 e $\alpha = 0,25$	63
Tabela 21 – Vida útil de bateria 1000 mAh para MAB e ADR.	65

Lista de Abreviaturas

LoRaWAN *Long Range Wide Area Network*

IoT *Internet of Things*

LPWAN *Low-Power Wide Area Network*

CAGR *Compound Annual Growth Rate*

SF *Spreading Factor*

LoRa *Long Range*

ED *End Devices*

ADR *Adaptative Data Rate*

GW *Gateway*

NS *Network Server*

MAC *Media Access Control Layer*

ITU-R *International Telecommunication Union-Radio*

3GPP *Third Generation Partnership Project*

UFJF *Universidade Federal de Juiz de Fora*

SIoT *Symposium on Internet of Things*

IEEE *Instituto de Engenheiros Eletricistas e Eletrônicos*

SNR *Relação Sinal-Ruído*

ns-3 *Network Simulator 3*

CSMA *Carrier Sense Multiple Access*

DR *Data Rate*

ADR *Adaptative Data Rate*

CSS *Chirp Spread Spectrum*

NBS *Não Baseado em Sensibilidade*

ARQ *Automatic Repeat reQuest*

TX *Transmissão*

AT *Air Time*

PLR *Packet Loss Rate*

PIR *Packet Interference Rate*

TxPower *Potência de Transmissão*

PDR *Packet Delivery Ratio*

RSSI *Received Signal Strength Indicator*

LOS *Line of Sight*

NLOS *Non Line of Sight*

TTN *The Things Network*

ADB *Android Debug Bridge*

MQTT *Message Queue Telemetry Transport*

RF *Random Forest*

SVM *Support Vector Machine*

MLP *Multi Layer Perceptron*

KNN *K-Nearest Neighbour*

VP *Verdadeiros positivos*

TA *Total de Amostras*

VN *Verdadeiros Negativos*

FN *Falsos Negativos*

FP *Falsos Positivos*

FIR *Finite Impulse Response*

RMSE *Root Mean Squared Error*

RL *Reinforcement Learning*

DQN *Deep Q-Networks*

PGM *Policy Gradient Methods*

MAB *Multi-Armed Bandits*

QoSE *Quality of Service Energy*

Sumário

	Agradecimentos	vii
	Resumo	viii
	Abstract	ix
	Lista de ilustrações	ix
	Lista de tabelas	xi
1	INTRODUÇÃO	1
1.1	Trabalhos Relacionados	2
1.2	Objetivos	3
1.2.1	Objetivo Geral	3
1.2.2	Objetivos específicos	4
1.3	Produção científica	4
1.4	Contribuições	5
1.5	Estrutura da Dissertação	5
2	CONSUMO ENERGÉTICO E ALOCAÇÃO DE SF E DE POTÊNCIA EM SISTEMAS LORAWAN	6
2.1	Arquitetura LoRaWAN	6
2.2	Adaptative Data Rate	7
2.3	Simulador Network Simulator 3	9
2.4	Consumo Energético em Redes LoRaWAN	11
2.4.1	Modulação LoRa	11
2.4.2	Simplicidade do <i>End Device</i>	11
2.4.3	Classes de operação do <i>End Devices</i> (ED)	11
2.5	Modelagem de consumo energético	13
2.5.1	Modelo analítico de consumo	14
2.5.2	Modelo de simulação do consumo energético	15
2.5.3	Baterias	16
2.6	Simulações e Resultados	17
2.6.1	Consumo em função do SF	17
2.6.2	Análise de desempenho e consumo energético do ADR	18
2.6.3	Potência de Transmissão e Consumo Energético	21
2.6.4	Fator de Espalhamento e Consumo Energético	22
2.7	Conclusões	24

3	IDENTIFICAÇÃO INTELIGENTE DE LINHA DE VISADA EM REDES LORAWAN	25
3.1	Objetivo	25
3.2	Configuração dos equipamentos	26
3.3	Coleta de dados	27
3.4	Classificação	28
3.4.1	RF	29
3.4.2	SVM	29
3.4.3	MLP	29
3.4.4	KNN	30
3.4.5	Busca por Hiperparâmetros	30
3.5	Classificação Inteligente de Visada	30
3.5.1	Extração de Parâmetros	31
3.5.2	Validação Cruzada	32
3.5.3	Pré-Processamento	33
3.5.4	Métricas para avaliação das técnicas	33
3.5.5	Tempo de processamento	34
3.5.6	Hiperparâmetros	34
3.6	Resultados	35
3.7	Conclusão	36
4	ALOCAÇÃO DE SF EM FUNÇÃO DA LINHA DE VISADA	38
4.1	Identificação de Linha de Visada e Aprimoramento de Redes LoRaWAN	38
4.2	Caracterização do canal	38
4.2.1	Perda de Percurso Medida	39
4.2.2	Remoção de <i>Outliers</i>	39
4.2.3	Modelagem dos Canais LOS e NLOS	41
4.3	Simulação	42
4.3.1	Resultados	45
4.3.2	Cenário 1: $\delta = 1,0$	45
4.3.3	Cenário 2: $\delta = 0,0$	46
4.4	Conclusões	47
5	ALOCAÇÃO INTELIGENTE DE SF BASEADA EM APRENDIZADO POR REFORÇO	49
5.1	Aprendizado por Reforço	49
5.1.1	<i>Multi-Armed Bandits</i>	50
5.1.2	Dilema Exploração-Exploração	50
5.1.3	Estratégia $\epsilon - greedy$	51
5.1.4	Aplicação no cenário LOS/NLOS	51
5.2	Métricas de Desempenho	52
5.2.1	Consumo Normalizado	52

5.2.2	QoSE	53
5.3	Recompensa	54
5.4	Simulação e Resultados	55
5.4.1	Cenário 0: Mudança de δ	56
5.4.2	Cenário 1: $\delta = 1,0$	56
5.4.3	Cenário 2: $\delta = 0,0$	57
5.4.4	Cenário 3: $\delta = 0,75$	59
5.4.5	Vida útil bateria	64
5.5	Conclusão	66
6	CONCLUSÕES	68
6.1	Trabalhos Futuros	69
7	APÊNDICE	70
7.1	Principais mudanças para consumo energético	70
7.2	Principais mudanças para canal	70
	Referências	72

1 Introdução

Com base nos recentes avanços tecnológicos, o número de aplicações de Internet das Coisas (*Internet of Things* (IoT)) cresceu significativamente nos últimos anos [1]. A IoT é uma área da tecnologia que conecta dispositivos físicos, sensores, atuadores, controladores e outros objetos inteligentes à Internet, permitindo a troca de informações e colaboração entre eles, fornecendo soluções inteligentes para vários cenários de aplicação.

De acordo com o mais recente relatório da Ericsson [2], projeta-se que, até 2029, o número de usuários de IoT alcance 38,8 bilhões, com uma taxa de crescimento anual de 16% no número de dispositivos e conexões. Esse crescimento é impulsionado pela demanda por soluções que proporcionem melhor aproveitamento de recursos, aumento da produtividade e redução de custos operacionais [3]. A implementação de IoT, além de conectar dispositivos à Internet, permite uma coleta massiva de dados, estimulando outras áreas, como aprendizado de máquina, para análise preditiva e o monitoramento contínuo, sendo possível a utilização de vários tipos de tecnologias de comunicação de acordo com a demanda da aplicação [4].

Comunicações sem fio tradicionais, como redes celulares e tecnologias de comunicação de curto alcance (*Bluetooth, WiFi, Zigbee, etc*) não podem fornecer baixo consumo de energia e longo alcance ao mesmo tempo. Enquanto as redes celulares podem fornecer longo alcance, alta taxa de dados ao custo de complexidade e alto consumo de energia, as redes de tecnologias de comunicação de curto alcance podem fornecer menor consumo de energia do que a rede celular, mas o alcance também é consideravelmente menor [5]. A maioria das aplicações IoT não requer altas taxas de dados, portanto neste cenário, tecnologias *Low-Power Wide Area Network* (LPWAN) surgem como uma solução que permite comunicação de longo alcance e baixo consumo de energia.

Dentre as principais tecnologias LPWAN utilizadas em IoT, temos a *Long Range Wide Area Network* (LoRaWAN), que se baseia na técnica de camada física *Long Range* (LoRa) para fornecer um sinal que sobressaia sobre ruídos e interferências [6]. Para isso, define sinais modulados sob seis Fatores de Espalhamento (*Spreading Factor* (SF)s) quase ortogonais entre si [7], os quais são SF7, SF8, SF9, SF10, SF11 e SF12. A implementação de redes LoRaWAN tem se destacado principalmente como boa opção para cenários de agricultura inteligente, com monitoramento de pecuária [8], e *smart cities* [9], nos quais problemas como mobilidade urbana são abordados [10].

Atualmente, mais de 2 bilhões de dispositivos utilizam LoRaWAN, e estima-se que o mercado global de LoRaWAN atinja um valor de 8 bilhões de dólares até o final de 2025, englobando serviços como implementação, manutenção, desenvolvimento de *software* e servidores de rede [2]. Esse mercado deve expandir para 32,7 bilhões de dólares até 2029, com uma Taxa de Crescimento Anual Composta (*Compound Annual*

Growth Rate (CAGR)) de 32,4%. No que diz respeito exclusivamente aos *chipsets* LoRa, incluindo *Gateway* (GW) e ED, o mercado global foi estimado em 196,7 milhões de dólares em 2023, com projeção de crescimento para 1,134 bilhão de dólares até 2030, apresentando um CAGR de 28,5% durante o período de previsão.

Diante desse cenário, aumentar a eficiência energética dos dispositivos LoRaWAN torna-se essencial para a redução dos custos operacionais das redes IoT, enquanto a melhoria de desempenho contribui para difundir o uso dessa tecnologia ainda mais. O custo das baterias para dispositivos LoRaWAN pode representar uma parcela significativa dos custos totais de implantação e manutenção de uma rede, que pode variar entre 20% e 30% do custo total a depender das especificidades do projeto e do tipo de bateria empregada [11]. Dessa forma, a redução do consumo energético prolonga a vida útil das baterias e reduz significativamente os custos de manutenção. O aumento da durabilidade das baterias minimiza a necessidade de substituições frequentes, que resulta em economias substanciais e maior sustentabilidade das redes LoRaWAN, especialmente em aplicações de larga escala, nas quais a substituição de baterias pode ser logisticamente e economicamente inviável [12].

Técnicas para a seleção otimizada do SF e um planejamento eficiente para minimizar o período de transmissão de dados são fundamentais para prolongar a vida útil da bateria. No entanto, o período de transmissão é frequentemente condicionado pelo tipo de aplicação e, em muitos casos, não pode ser alterado. Sendo assim, técnicas para seleção de SF podem ser a única opção para aumentar a eficiência energética. Entretanto, escolhas de SF não ajustadas podem impactar negativamente no desempenho em relação à taxa de entrega de pacotes, portanto o *trade-off* desempenho/consumo energético é um desafio na concepção de redes LoRaWAN [9].

Nesse contexto, este trabalho de pesquisa tem como objetivo investigar técnicas inteligentes de ajuste dinâmico do SF atribuído a cada ED de modo a aumentar o desempenho e a eficiência energética, baseados na identificação da presença de linha de visada entre o transmissor e o receptor.

1.1 Trabalhos Relacionados

A presença de linha de visada é um fator que influencia diretamente no nível de potência recebida em sistemas de comunicações sem fio. Diversas soluções para classificação de linha de visada são encontradas na literatura com aplicações em localização [13]–[15], orientação do dispositivo [16] e sensoriamento [17] em diferentes redes de comunicação, tais como IoT *outdoor* [15] e *indoor* [13], veiculares [17] e industriais [18]. Entretanto há uma lacuna na literatura neste tipo de classificação para redes LoRaWAN em aplicações IoT *outdoor*. A caracterização de canal com classificação de linha de visada auxilia na otimização de parâmetros das redes LoRaWAN, propiciando um menor tempo de entrega de pacotes, e no desenvolvimento de dispositivos de menor consumo

energético [19]. Ademais, a classificação de linha de visada auxilia na caracterização da perda de percurso [20] e nos algoritmos de localização e rastreamento de EDs [21], complementando as informações obtidas por sistemas de posicionamento via satélite.

No entanto, o consumo de energia, vital no contexto LoRaWAN já que EDs podem ser alimentados por bateria, é pouco explorado [19]. Diante desse cenário, [22] busca adaptar o modelo analítico de consumo de energia para baterias apresentado em [19], no qual são mapeadas as correntes de cada modo de operação com o auxílio de um analisador de potência, para o *software* simulador de rede *Network Simulator 3* (ns-3). O modelo criado por [22] se aproxima do resultado analítico e permitiu que simulações fossem exploradas por este trabalho.

Grande parte dos trabalhos referentes à alocação de SF focam em cobertura, capacidade, e escalabilidade [23]–[25]. É possível observar as mais diferentes estratégias, como distribuição de SFs [26]–[28], que foca no uso de fatores de espalhamento fixos para alguns grupos de EDs de acordo com critérios como distância, densidade e *air time*. Há também trabalhos que utilizam de aprendizado de máquina [29]–[31] na alocação de SFs, com aprendizado supervisionado e não supervisionado para encontrar a melhor configuração de rede. Outros propõem alterações no protocolo ALOHA [32]. Alguns trabalhos se baseiam em aprendizado por reforço [33]–[35] para enfrentar cenários dinâmicos. Encontram-se também na literatura novos mecanismos de adaptação de taxa de transmissão [36]–[38], com propostas para tomada de decisão que combinam de métricas de desempenho além de camada física e adoção de *Carrier Sense Multiple Access* (CSMA) para evitar colisões e interferências.

Diante do exposto acima, é evidente o foco da comunidade científica em estratégias de alocação de SF para maximizar o desempenho de redes LoRaWAN. Entretanto, a maioria destes trabalhos focam no aumento de desempenho sob a ótica de taxa de entrega de pacotes, sem levar em consideração o consumo energético. Diferentemente delas, as soluções apresentadas neste trabalho buscam combinar abordagens com análise de uma métrica que alia o desempenho com eficiência energética, o que vai ao encontro do objetivo de redução do consumo de energia para redução do custo com baterias, porém sem deixar de lado o desempenho.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é desenvolver e validar técnicas inteligentes para a alocação de fatores de espalhamento em redes LoRaWAN baseadas nas condições de linha de visada dos nós, com foco na otimização do desempenho e na redução do consumo energético dos dispositivos finais.

1.2.2 Objetivos específicos

Para atingir o objetivo geral, os objetivos específicos deste estudo consistem em:

- Analisar o comportamento energético dos EDs submetidos às várias condições de potência, alocação de SF e de canal;
- Desenvolver modelos de simulação que permitam estimar o consumo energético dos EDs;
- Analisar condições de propagação de canais de campanha de medição e propor identificação inteligente dos canais;
- Incorporar campanha de medição em simulação a fim de explorar e propor estratégias de alocação de SF e potência que superem estratégias convencionais;
- Investigar e aplicar técnicas de aprendizado por reforço para a alocação de SF e potência, visando uma resposta rápida às variações de condições de transmissão;
- Comparar os desempenhos dos algoritmos propostos por meio de simulações, avaliando o equilíbrio entre taxa de entrega de pacotes e eficiência energética.

1.3 Produção científica

A pesquisa desenvolvida ao longo de todo o curso de Mestrado propiciou a publicação de trabalhos em congressos nacionais e internacionais que contribuíram diretamente para este trabalho. O primeiro deles modela a perda de percurso a partir de medições feitas na Irlanda [39] e compara regressões lineares e polinomiais frente à modelos clássicos como Okumura-Hata, *Third Generation Partnership Project* (3GPP) e *International Telecommunication Union-Radio* (ITU-R). Estes resultados indicaram que tais ferramentas de análise de dados, com ajustes, tornam o modelo de perda de percurso de forma mais próxima aos dados do que modelos clássicos devido ao ajuste de campanha de medição.

Em seguida, [40] propõe a identificação de linha de visada a partir de uma nova campanha de medição realizada na Universidade Federal de Juiz de Fora (UFJF). Com isso, foram empregados algoritmos de aprendizado de máquina, os quais obtiveram bons resultados de identificação de visada e forneceram *insights* valiosos para esse trabalho. Enquanto isso [41], versão estendida de [40], explorou um pouco mais sobre a arquitetura da campanha de medição e explicitou os hiperparâmetros obtidos para cada algoritmo de aprendizado de máquina, bem como a inserção de uma nova métrica de desempenho, o que propiciou maior entendimento ao trabalho e contribuições à comunidade acadêmica. Diante disso, [41] recebeu a premiação de Melhor Artigo do *Symposium on Internet of Things* (SIoT) 2024, congresso internacional padrão Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE) com foco em IoT, evidenciando a relevância e destaque do trabalho.

Por fim, [42] discute e analisa o consumo energético sob a ótica de alocação de SF. Os resultados indicaram que estratégias não baseadas em sensibilidade podem ser mais eficientes energeticamente do que estratégias baseadas em sensibilidade, além de, sob a perspectiva de desempenho, evitarem parte de pacotes interferidos que ocorrem em estratégias baseadas em sensibilidade.

1.4 Contribuições

Dentre as contribuições desta dissertação, destacam-se:

- Estudo sobre consumo energético e fatores que o impactam;
- Desenvolvimento de algoritmos utilizados no *software* de simulação;
- Classificação de linha de visada com técnicas de aprendizado de máquina para ambientes *outdoor*;
- Campanha de medição e modelagem de canais com linha de visada e sem linha de visada de um ambiente real;
- Propostas de alocação de SF baseadas em canais com e sem linha de visada;
- Emprego de aprendizado por reforço para tomada de decisão de alocação de SF inteligente.

1.5 Estrutura da Dissertação

Esta dissertação está organizada em seis capítulos. O Capítulo 1 apresenta a introdução, contextualização, objetivos, trabalhos publicados, trabalhos relacionados e as contribuições deste trabalho. O Capítulo 2 detalha os fundamentos teóricos relacionados ao consumo energético em redes LoRaWAN, abordando impacto da alocação de SF e potência. Enquanto isso, o Capítulo 3 descreve a campanha de medição realizada para coleta de dados e a identificação inteligente de linha de visada para separação de canais. No Capítulo 4, é caracterizado e incorporado os canais da campanha de medição ao simulador e são apresentados os resultados das simulações com propostas de alocação de SF baseadas no cenário da campanha. O Capítulo 5 explora a implementação de aprendizado por reforço para escolha de propostas de alocação de SF a fim de promover uma alocação mais inteligente e adaptativa para as condições de transmissão. Finalmente, as conclusões são expostas no Capítulo 6.

2 Consumo Energético e Alocação de SF e de Potência em Sistemas LoRaWAN

Redes LoRaWAN são comumente encontradas em diversas aplicações, tais como *smart farming* [23], *smart cities* [43] e monitoramento ambiental [44]. O sucesso dessas aplicações passa pela eficiência energética entregue, a qual é influenciada pela escolha de SF [6].

Uma alocação eficiente do SF, quando bem executada, pode minimizar o consumo de energia ao mesmo tempo em que assegura a cobertura. Contudo, quando essa alocação é mal projetada, ela pode acarretar em perda de pacotes entregues, afetando o desempenho da rede, ou em um consumo de energia excessivo. A dinâmica de alocação de SF é possível graças à arquitetura LoRaWAN, que inclui os elementos ED, GW e *Network Server* (NS) e fornece a estrutura que viabiliza a comunicação e o gerenciamento dos dispositivos na rede, permitindo ajustes dos parâmetros de transmissão [45].

2.1 Arquitetura LoRaWAN

A Figura 1 apresenta a topologia da rede LoRaWAN. Os elementos se dispõem em uma topologia em estrela, em que o ED representa o dispositivo final, normalmente sensores e atuadores, que coletam dados e enviam para o GW. Este atua como o ponto de coleta e transmissão dos sinais recebidos a partir dos EDs, conectando-os ao NS através de conexões de alta velocidade sendo normalmente através da Internet. Por fim, o NS é responsável pela gestão, processamento e análise dos dados, sendo ele o elemento de maior capacidade computacional da arquitetura [6].

Essa arquitetura apresenta vantagens como baixa latência devido à comunicação direta entre ED e GW; escalabilidade pelo fato de apenas um GW ser capaz de suportar múltiplos dispositivos; otimização da comunicação graças à presença do NS, o que permite que o ED e o Relação Sinal-Ruído (SNR) sejam mais simples. A presença do NS também contribui com a coleta de métricas de desempenho, tais como *Packet Delivery Ratio* (PDR), SNR, *Received Signal Strength Indicator* (RSSI), e ajuste de potência de transmissão e SF a partir de tais métricas. Sua capacidade computacional, capaz de realizar um grande processamento de dados, aliada a coleta de métricas, torna o NS a melhor escolha para embarcar algoritmos de inteligência computacional [46].

O padrão LoRaWAN utiliza a camada física LoRa, que define sinais com seis SFs ortogonais [7] entre si, de forma a aumentar cobertura (SF maior) ou taxa de transmissão (SF menor), bem como reduzir a interferência entre os dispositivos de SFs diferentes.

A escolha de SF pode ser feita de SF7 até SF12 e o uso de SFs maiores possibilita um

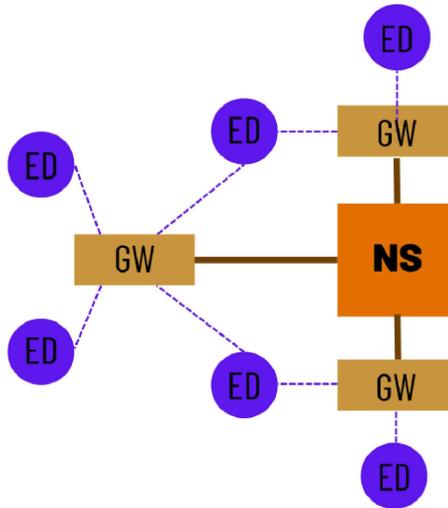


Figura 1 – Topologia LoRaWAN. Fonte: [46]

maior alcance da transmissão, porém com menor *throughput* e maior tempo para a entrega de pacotes (*air time*) e, conseqüentemente, maior consumo energético pelos EDs. Os SFs também podem ser associados à outros termos relacionados à *Data Rate* (DR): DR5 (*Data Rate 5*), DR4 (*Data Rate 4*), DR3 (*Data Rate 3*), DR2 (*Data Rate 2*), DR1 (*Data Rate 1*) e DR0 (*Data Rate 0*). Essa alcunha se dá pela relação de cada SF com a taxa de transmissão, sendo SF7 o de maior taxa de transmissão (DR5) e o SF12 o de menor (DR0). Devido à gama de SFs disponíveis, a *LoRaWAN Alliance* desenvolveu um mecanismo ADR como possível alternativa de determinação de SF de forma automática [47].

2.2 *Adaptative Data Rate*

O mecanismo *Adaptative Data Rate* (ADR) é parte das especificações do protocolo LoRaWAN [47] e foi desenvolvido para aproveitar as vantagens da camada física do LoRa. Seu principal objetivo é expandir a cobertura dos EDs que compõem a rede LoRaWAN ao adaptar, de forma inteligente, o SF e a potência de transmissão em cada ED com base no nível de potência recebida no SNR: quanto maior o nível de potência recebida, menor o valor de SF atribuído [48]. Por conseguinte, obtém-se uma maior taxa de transmissão com o menor consumo energético possível, tornando a rede mais eficiente do ponto de vista energético e desempenhando maior taxa de entrega de pacotes com maior taxa de transmissão. O ADR do LoRaWAN é constituído de duas etapas, sendo a primeira obrigatória e de responsabilidade do ED, enquanto a segunda opcional e de responsabilidade do NS.

Na primeira, ao identificar a perda de conexão com o servidor, o ED possui capacidade para aumentar o valor de potência de transmissão até o limite permitido pelas legislações locais vigentes ou determinado pelo usuário, na tentativa de reestabelecer a conexão. Caso ainda esteja sem conexão, o ED mantém a potência máxima e incrementa

seu SF até alcançar o SF12, valor máximo para as redes LoRaWAN, até que a conexão seja reestabelecida.

Já no segundo momento, sob responsabilidade do NS, o comportamento do algoritmo ADR é observado através dos valores de RSSI e SNR das transmissões de cada ED. Quando o ADR está ativado, o NS envia os valores escolhidos de SF e potência de transmissão para cada ED por meio de comandos da camada *Media Access Control Layer* (MAC) e um critério de decisão pode ser definido para alterar a potência de transmissão ou o SF [49]. A Tabela 1 apresenta a sensibilidade do receptor relacionada a cada SF [50]. Superar a sensibilidade do receptor é equivalente a ter uma SNR forte o suficiente para uma demodulação com taxa de erro adequada. Quanto maior a quantidade de EDs fazendo uso do mesmo SF, maior é a probabilidade de interferência co-canal, resultando em um aumento da taxa de erro de pacotes.

Tabela 1 – Sensibilidade dos dispositivos para cada SF.
Fonte: [51]

SF	Sensibilidade (dBm)
SF7	-123
SF8	-126
SF9	-129
SF10	-132
SF11	-134,5
SF12	-137

Dessa forma, o ADR influencia significativamente a cobertura, a capacidade e a eficiência energética da rede. A *Semtech Corporation* [50] fornece um algoritmo ADR de sugestão, chamado *Semtech Adaptive Data Rate*, embora não seja uma solução ótima [49]. Nesse algoritmo fornecido pela *Semtech*, o NS mantém em memória os valores de SNR dos últimos 20 quadros recebidos de cada ED. Os valores de potência de transmissão e SF são escolhidos de forma a estabelecer uma margem pré-configurada entre o SNR dos futuros pacotes transmitidos (com os novos valores de potência e SF) e a sensibilidade mínima do receptor. Com esse método, é combinada a cobertura com eficiência energética e taxas de dados adequadas para cada ED [48], já que o objetivo é utilizar o menor SF que estabeleça a comunicação predeterminada.

Entretanto, apesar da suposta otimização em cada ED, o ADR da *Semtech* parte do pressuposto que apenas as características individuais de cada ED são relevantes para a comunicação, ou seja, não considera a influência que o conjunto de dispositivos exercem entre si na rede. Com isso, em situações de alta densidade de dispositivos, por exemplo, esse algoritmo pode impor a transmissão de pacotes com o mesmo valor de SF para uma grande quantidade de EDs próximos. Como consequência, há um impacto significativo na interferência co-canal na rede, aumentando o índice de pacotes interferidos e levando ao efeito inverso da melhoria da rede [49].

2.3 Simulador *Network Simulator 3*

A capacidade de simular redes complexas tem auxiliado o desenvolvimento de pesquisas. O ns-3 [52] é um simulador *open source* de rede de eventos discretos muito utilizado para esse fim [49] e se destaca por sua flexibilidade, permitindo a reprodução de cenários reais com um elevado grau de detalhamento e diversos módulos disponíveis para simulação, tais como Wi-Fi, 4G, 5G, entre outros. Esse *software* também possibilita a exploração de novos cenários, a análise do comportamento de redes em diferentes níveis que incluem camadas física, MAC e rede, além de permitir a inserção de novos módulos de diferentes tecnologias e autores.

Nesse contexto, uma contribuição ao desenvolver um módulo LoRaWAN para o ns-3 encontra-se em [46]. Este trabalho é amplamente reconhecido como um dos mais relevantes na área [49], uma vez que integra a modelagem de parâmetros de rede e a implementação de um novo mecanismo ADR, viabilizando experimentos que aproximam a simulação do comportamento real de uma rede e permitindo uma análise do desempenho das redes LoRaWAN. Dentro do módulo, é possível configurar parâmetros como frequência de operação, largura de banda, SFs, potência de transmissão, modelagem do canal, posicionamento dos dispositivos da rede, entre outros. Existem outros módulos de LoRaWAN disponíveis para ns-3 como [53], mas este trabalho foca nas simulações com o módulo desenvolvido por [46] devido à sua popularidade, ao bom desempenho para redes LoRaWAN com apenas um SNR e à possibilidade de explorar novos cenários [49] de rede mais desafiadores.

Entretanto, a implementação do mecanismo ADR no módulo LoRaWAN de Magrin não seguiu inicialmente como a proposta fornecida pela *Semtech* devido à dificuldade de codificação desse algoritmo [46]. Apesar de muito utilizado no ambiente acadêmico, o ns-3 é um *software* que exige profundos conhecimentos em linguagem de programação C++ e domínio de sua extensa arquitetura. Portanto, isto somado à complexidade de implementar um algoritmo como o ADR da *Semtech*, Magrin optou por implementar parte do algoritmo.

O ADR do módulo Magrin adota um critério mais simples, ajustando apenas o valor de SF dos EDs observando a sensibilidade do receptor conforme apresentada pela Tabela 1, sem alterar a potência de transmissão de forma dinâmica como o ADR da *Semtech*. Como este trabalho faz uso de simulações com o módulo de Magrin, a partir deste ponto o termo ADR estará referenciando àquele implementado por esse módulo.

Ao iniciar a transmissão de pacotes, o ADR calcula o RSSI do pacote a ser enviado, a partir do canal e da potência de transmissão inicialmente configurados, compara com a sensibilidade do SF7 e, se o RSSI for maior que essa sensibilidade, o NS atribuirá o SF7 para o ED em questão e a transmissão de pacote é realizada. Caso a sensibilidade seja menor que o RSSI calculado, o ADR compara novamente com a sensibilidade do SF8 e assim por diante, até encontrar uma sensibilidade maior que a RSSI calculada

entre os SFs disponíveis ou optar pelo SF12, caso não haja sensibilidade maior que a RSSI do pacote a ser enviado. Com isso, os EDs da rede LoRaWAN fazem uso do menor SF possível para a transmissão do pacote ocorrer, de modo a economizar energia do dispositivo e maximizar a cobertura. O ADR não utiliza estratégias relacionadas à segunda etapa de implementação descrita pelo *LoRaWAN Alliance*, ou seja, não há métricas de desempenho personalizadas no NS para tomada de decisão de alocação de SF ou potência de transmissão, sendo considerada apenas a RSSI antes do envio dos pacotes. Além disso, o ADR não realiza mudanças na potência de transmissão, sendo o mecanismo de adaptação restrito à atribuição de novos SFs para os EDs presentes na rede.

Devido à varredura da tabela de sensibilidade para tomada de decisão, o algoritmo ADR pode ser classificado como algoritmo baseado em sensibilidade e possui custo computacional mais elevado que algoritmos não baseados em sensibilidade. Entretanto, caso haja a presença da interferência co-canal, a sensibilidade do receptor pode não ser a melhor métrica alvo, para determinar escolha de SFs e atuar no monitoramento da qualidade do enlace [49].

Diante desse contexto, [24] propôs algoritmos ADRs Não Baseado em Sensibilidade (NBS), que são algoritmos de atribuição simples que podem ser aplicados a EDs com capacidades de processamento modestas. Para isso, define-se o vetor de atribuição $\vec{a} = \{a_7, a_8, \dots, a_{12}\}$, em que a_7 denota a fração do total de EDs da rede LoRaWAN que são alocados para SF7, a_8 para SF8, e assim por diante. Assim, tem-se que $\sum_{i=7}^{12} a_i = 1$. De [24], destacam-se os seguintes algoritmos:

- Fixo em SF7 - Todos os EDs usam o SF mais baixo. Neste caso, $a_7 = 1$ e $a_i = 0 \forall a_i \neq 7$.
- Fixo em SF12 - Todos os EDs usam o SF mais alto. Neste caso, $a_{12} = 1$ e $a_i = 0 \forall a_i \neq 12$.
- *Equal Split* - Os N EDs na rede são classificados por potência recebida em ordem decrescente e em seguida igualmente divididos em seis grupos de forma que o primeiro grupo seja alocado para SF7, o segundo para SF8 e assim por diante, priorizando os maiores valores de potência recebida para grupos de SFs menores. Neste caso, $a_i = N/6$, ou ainda $a_7 = a_8 = a_9 = a_{10} = a_{11} = a_{12} = 0,166$.

Apesar da diferença de implementação em relação a adaptação de potência de transmissão e determinação de um critério personalizado para que o NS tome uma decisão se comparado com o ADR proposto pela Semtech, a inclusão do ADR no módulo possibilita a simulação de cenários nos quais a rede se adapta em tempo real a variações de sinal recebido, interferência e cobertura, permitindo o estudo de comportamento de um algoritmo adaptativo. Além disso, propostas de algoritmos não baseados em sensibilidade, mesmo sendo menos complexos, podem contornar a interferência entre SFs em redes

LoRaWAN com mecanismo de ADR baseado em sensibilidade que tendem alocar um maior número de dispositivos no mesmo SF. O consumo energético médio também sofrerá alteração de acordo com a política de alocação de SF utilizada.

Por fim, é importante destacar que este trabalho não faz uso de ferramentas como *Automatic Repeat reQuest* (ARQ), método de controle de erro que permite a retransmissão de pacotes quando a entrega não é confirmada. Como o ARQ é opcional em LoRaWAN, optou-se por desabilitá-lo devido a seu aumento do consumo energético, uma vez que cada retransmissão realizada exige que o rádio fique ativo por mais tempo.

2.4 Consumo Energético em Redes LoRaWAN

A tecnologia LoRaWAN se tornou uma das mais utilizadas em aplicações de baixo *throughput* que demandam alta cobertura em virtude da sua eficiência energética [54]. Tal eficiência se dá por alguns fatores, tais como a modulação LoRa, as classes de operação do ED e a simplicidade do ED.

2.4.1 Modulação LoRa

A modulação LoRa, baseada na modulação *Chirp Spread Spectrum* (CSS), permite um maior alcance com baixa potência de transmissão sem uso obrigatório de retransmissões devido a resistência à interferências e ao ruído. Sua taxa de bits por segundo R_b é definida como

$$R_b = \frac{SF}{T_s} = \frac{SF \times BW}{2^{SF}}, \quad (2.1)$$

em que SF é o Fator de espalhamento que determina o número de bits no símbolo e pode variar de 7 a 12. Além disso, o SF determina a duração de um símbolo T_s , que é o tempo necessário, em segundos, para escanear toda a banda do sinal BW .

2.4.2 Simplicidade do *End Device*

A alta eficiência energética também é explicada pela simplicidade do ED, sendo o processamento concentrado no NS e auxiliado pelo mecanismo ADR, que ajusta o SF de acordo com a sensibilidade do receptor, possibilitando que os EDs consumam o limite mínimo de energia que viabiliza a comunicação com o SNR.

2.4.3 Classes de operação do ED

Os EDs possuem três modos de operação: TX, *standby* e *sleep*. O modo Transmissão (TX) é ativado no momento em que há transmissão de mensagens *uplink*, período em que há maior demanda computacional do ED e, portanto maior consumo energético. Enquanto isso, o modo *standby* se inicia no momento que o ED aguarda as mensagens de *downlink*, momento chamado de janela de recepção, e, por não necessitar tanto processamento,

possui algumas funções reduzidas, consumindo menos energia se comparado com o estado TX. Por fim, o estado *sleep* é estabelecido em dois momentos, entre as janelas de recepção, e após o fim da última janela de recepção configurada. Por operar em ocasiões de menor necessidade computacional, o período de *sleep* do ED é o de maior eficiência energética entre todos os modos.

Cada modo é acionado de formas e em quantidades diferentes a depender das classes de operação das quais os EDs podem fazer parte em uma rede LoRaWAN. A Tabela 2 apresenta uma comparação da corrente, em mA, para cada modo de operação em uma rede LoRaWAN classe A e ilustra a ordem de grandeza de consumo para cada modo de operação. Os valores apresentados se referem a uma rede LoRaWAN com ADR ativado, periodicidade de envio de pacotes de 10 minutos, tamanho do pacote 51 *bytes* e potência de transmissão de 14 dBm [22].

Tabela 2 – Corrente em cada modo de operação para SX1272.
Fonte: [22]

Estado	Corrente (mA)
TX	$54 \pm 0,408$
<i>Standby</i>	$1.6 \pm 0,042$
<i>Sleep</i>	10^{-3}

Os EDs têm a capacidade de operar nas classes A, B e C, sendo a classe A a mais utilizada [55] e a única que deve ser obrigatoriamente implementada [47] nos EDs. As demais classes são opcionais. Cada classe possui um foco e é recomendada para determinadas situações.

Na classe A, o ED se comunica diretamente com o servidor e, nessa classe, os dados do servidor são recebidos após o envio dos pacotes, o que garante a maior eficiência energética dentre as três classes de LoRaWAN [55]. Os EDs abrem pequenas janelas de recepção após a transmissão, minimizando o tempo ativo e consumo de energia. Com isso, os EDs não precisam permanecer no estado de transmissão, transitando facilmente para os estados *sleep* ou *standby*. Em razão da maior eficiência energética, é recomendada para dispositivos de bateria com capacidade reduzida, pois garante um consumo reduzido de energia e, assim, maior longevidade para a bateria. Por esse motivo, a classe A foi adotada nesse trabalho. A Figura 2 apresenta o comportamento da classe A ao longo da comunicação.

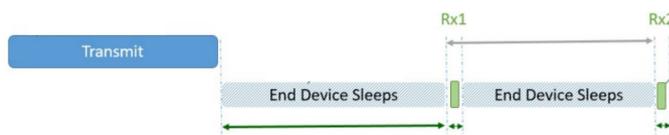


Figura 2 – Comportamento da classe A.
Adaptado de [56]

A classe B atua com os EDs abrindo múltiplas janelas de recepção em tempos

determinados. Para determinar quando uma janela será aberta, o ED detecta uma mensagem do tipo *beacon* enviada pelo SNR. Desta forma, os EDs e o servidor passam a funcionar em sincronia, o que mantém janelas abertas por mais tempo e em maior quantidade em comparação com a classe A, ocasionando em um maior consumo de energia, embora mantendo níveis reduzidos [56]. Essa classe é mais recomendada por dispositivos que precisam receber mensagens de *downlink* ou comandos MAC com alguma periodicidade pré-definida ou aplicações comandadas remotamente. A Figura 3 apresenta o comportamento da classe B ao longo da comunicação.

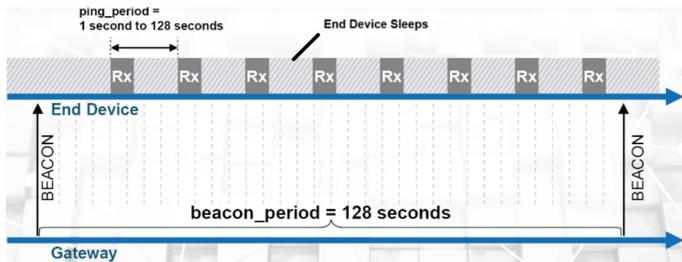


Figura 3 – Comportamento da classe B.
Adaptado de [56]

Por fim, dispositivos de classe C abrem apenas duas janelas de recepção, como os de classe A. A diferença é que a segunda janela só será fechada quando o ED for enviar pacotes, ou seja, o ED está sempre aberto para receber pacotes do SNR, implicando na manutenção do estado *standby* ao longo do tempo, sem que haja a mudança para o estado *sleep* como nas outras classes [56]. Logo, estar com uma janela aberta sempre esperando por pacotes ocasiona em um consumo muito maior de energia do que os dos dispositivos de classe A, tornando a classe C apenas recomendada para dispositivos com maior capacidade energética. A Figura 4 apresenta o comportamento da classe C ao longo da comunicação.

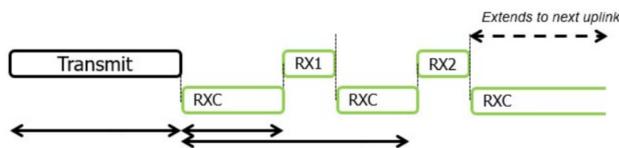


Figura 4 – Comportamento da classe C.
Adaptado de [56]

A Figura 5 compara a corrente, em mA, entre as classes A, B e C para uma aplicação que envia mensagens a cada 8 horas, ADR ativado e potência de transmissão de 14 dBm.

2.5 Modelagem de consumo energético

Devido às características que possibilitam o baixo consumo energético, muitos trabalhos em LoRaWAN focaram em capacidade e cobertura, deixando fora do foco

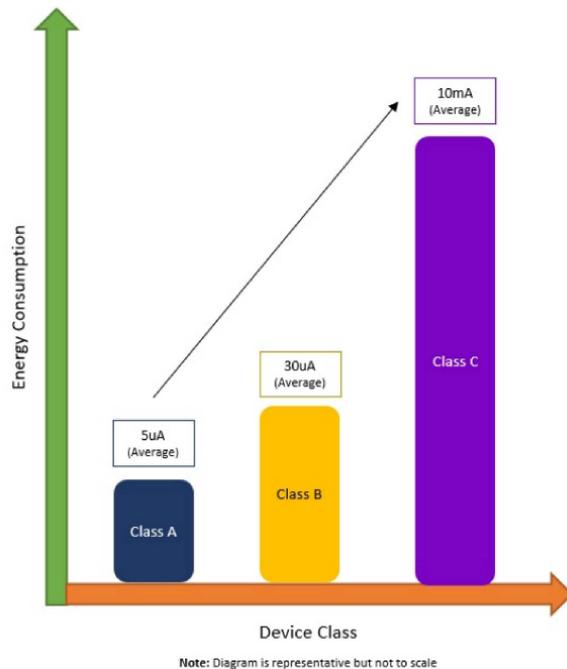


Figura 5 – Corrente para cada classe.
Adaptado de [56]

principal o estudo sobre comportamento energético [19]. Diante disso, surgiu a necessidade de analisar o consumo energético dos EDs frente aos algoritmos de alocação de SF, de forma a otimizar o desempenho da rede e prolongar a vida útil das baterias.

2.5.1 Modelo analítico de consumo

De forma a encontrar um resultado preciso, um modelo analítico para o consumo energético de dispositivos LoRaWAN de classe A é apresentado em [19]. Para isso, é utilizado um analisador de potência para observar a corrente de cada modo de operação de uma transmissão, bem como detalhes de janelas de recepção e transição para os modos *standby* e *sleep*. Com isso, obteve-se onze estados com correntes diferentes, que, se somadas, resultam na corrente total durante o período em que o ED está conectado a uma rede LoRaWAN, conforme descritos abaixo:

1. *Wake up* - momento em que o dispositivo é inicializado;
2. *Radio Preparation* - momento em que o dispositivo está em preparação para iniciar a transmissão de pacotes;
3. *TX* - momento em que o dispositivo está fazendo a transmissão de pacotes;
4. *Wait First Window* - momento em que o dispositivo está na transição entre o estado de TX e início da primeira janela de recepção;
5. *First Reception Window* - momento em que o dispositivo está na primeira janela de recepção;

6. *Wait Second Window* - momento em que o dispositivo está na transição entre o estado de TX e início da segunda janela de recepção;
7. *Second Reception Window* - momento em que o dispositivo está na segunda janela de recepção;
8. *Radio Off* - momento em que o dispositivo finalizou a segunda janela de recepção e está desligando o rádio;
9. *Preprocessing* - momento em que o dispositivo está finalizando o processamento de dados a serem enviados para o NS;
10. *Turn off sequence* - momento em que o dispositivo está na transição entre o fim do *Preprocessing* e o estado de *sleep*;
11. *Sleep* - momento em que o dispositivo entra no estado de *sleep*;

Com isso, é possível obter o período de vida da bateria, dado por

$$T_{bateria} = \frac{C_{bateria}}{I_{final} * 24}, \quad (2.2)$$

em que $T_{bateria}$ é a vida útil teórica da bateria em dias, $C_{bateria}$ a capacidade energética da bateria em J e I_{final} é a soma das correntes dos onze estados em mA.

2.5.2 Modelo de simulação do consumo energético

Contudo, a análise do consumo energético com onze estados é complexa e o modelo analítico pode ser difícil de ser implementado em situações *real time*. Conforme descrito na Seção 2.4.3, a *LoRaWAN Alliance* considera apenas os estados TX, *standby* e *sleep* para o consumo energético, uma vez que possuem maior valor de corrente nominal ou são mais duradouros na rede LoRaWAN [50], promovendo uma aproximação fidedigna em relação aos onze estados encontrados por [19].

Levando em consideração a recomendação da *LoRaWAN Alliance* e os resultados obtidos pelo modelo analítico, um *script* que calcula a corrente do ED durante a comunicação em uma rede LoRaWAN é apresentado em [22]. A comparação entre o modelo analítico e o simulado é apresentada pela Figura 6, a qual consta a corrente média em mA para envio de pacotes a cada 2, 4, 8, 16, 32, 64, 128, 256, 512 e 1024 minutos utilizando um SF fixo, sendo DR0 o SF12, DR1 o SF11 e assim por diante até DR5 igual a SF7. Tem-se na Figura 6(a) o desempenho da rede segundo o modelo analítico, enquanto na Figura 6(b) encontra-se o desempenho da rede segundo o modelo simulado.

Realizando a simulação com os mesmos parâmetros de rede de [19], [22] atingiu uma boa aproximação do modelo simulado em relação ao modelo analítico para periodicidade de transmissão de pacotes maior que 8 minutos. Para configurações de rede com periodicidade igual ou menor a 8 minutos, o modelo de [22] não fornece uma boa

aproximação, especialmente para os SFs de maior consumo. Isso se dá porque, embora os oito estados de [19] tenham baixa corrente nominal e pouca duração durante o envio de um pacote, considerando uma periodicidade menor, o ED passará por estes estados mais vezes durante uma hora. Portanto os oito estados desconsiderados pela *Semtech* geram um impacto nesse tipo de cenário.

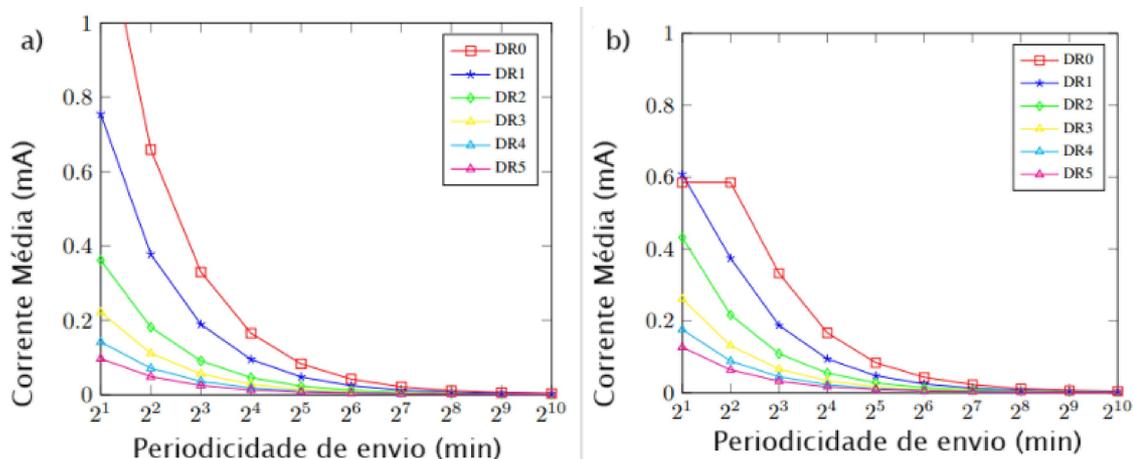


Figura 6 – Comparação entre o modelo analítico (a) e o modelo simulado (b). Adaptado de [22]

Outra limitação da implementação do módulo LoRaWAN do ns-3 utilizado é a ausência de configuração para potências de transmissão diferentes de 14 dBm no *script* do código para ns-3. Uma das contribuições desta dissertação é a melhoria no *script* de ns-3 do modelo simulado. Foi necessário realizar mudanças no código referente ao consumo energético disponibilizado, bem como nos arquivos que fazem uso do código de consumo energético. Mais detalhes se encontram no Apêndice em 7.1.

2.5.3 Baterias

Por fim, para melhor planejamento da rede LoRaWAN, é necessário escolher a bateria a qual alimentará os EDs. Eles geralmente usam uma bateria de 3 ou 3,6 V, e raramente são utilizadas baterias recarregáveis pelo seu alto custo, tamanho e dificuldade para carregamento [12].

Além disso, é recomendado utilizar até 70% da capacidade total de baterias. Esse é um fator que deve ser considerado porque ultrapassar esse percentual permite a queda de tensão da bateria à medida que ela descarrega. Quando a tensão cai abaixo do valor mínimo de fornecimento permitido no *datasheet*, o dispositivo é reiniciado ou desligado, resultando em operação instável [12]. Outro fator importante a ser destacado é que, quando a capacidade cai abaixo dessa faixa, a resistência interna da bateria aumenta, diminuindo o fornecimento de corrente da bateria para o dispositivo e tornando a bateria instável, sendo observado os mesmos problemas de desligamento ou reinício [57].

Tabela 3 – Tipos de baterias utilizadas em LoRaWAN

Tipo	Capacidade	Vantagem	Desvantagem
CR2450 3V	750mAh = 8100 J	Pequena, baixo custo	Baixa capacidade
CR2477 3V	1000mAh = 10800 J	Capacidade média	Custo elevado
LR6(AA) 1,5V	2200mAh = 11880 J	Capacidade média	Ocupa muito espaço
LR6(AA) 3,6V	2600mAh = 33693 J	Alta capacidade	Custo elevado
Modelo ns-3	10000 J	-	-

A escolha da bateria é fundamental para o planejamento de dispositivos IoT, uma vez que incluirá não só o funcionamento dos EDs como também o planejamento de manutenção e troca das baterias. Como os EDs possuem baixo consumo energético, baterias com menor capacidade energética são as mais utilizadas [12]. A Tabela 3 apresenta os modelos de baterias mais utilizados nas aplicações de LoRaWAN, a capacidade total em Joules (J), bem como as vantagens e desvantagens de optar por cada tipo de bateria [12]. As baterias CR2450 e CR2477 são de Lítio, enquanto LR6(AA) 1,5V é alcalina e LR6(AA) 3,6V é Lítio-Tionilo. A bateria definida no ns-3 tem capacidade equivalente às baterias de capacidade média. Esta é a bateria utilizada nas campanhas de simulação apresentadas a seguir.

2.6 Simulações e Resultados

Tendo em vista o modelo de simulação de consumo energético para ns-3 e os conceitos apresentados, são realizadas simulações no *software* ns-3 para explorar a eficiência energética do padrão LoRaWAN. Parte dos resultados a seguir também se encontram em [42]. Foram realizadas 10 simulações com sementes diferentes para garantir a confiança dos resultados.

2.6.1 Consumo em função do SF

A primeira campanha de simulação avalia o consumo para cada SF de um ED classe A para diferentes valores de periodicidade de transmissão de pacotes. A Figura 7 apresenta o comportamento desse ED, situado a 2 km do SNR, com potência de transmissão igual a 14 dBm e largura de banda de 125 kHz, para diferentes periodicidades de transmissão de pacotes. É possível observar a diferença em consumo para SF maiores, principalmente em situações em que as transmissões são mais frequentes, além de comportamento similar a uma função exponencial. Como esperado, o SF12 possui o maior consumo, enquanto o SF7 o menor, e isso é explicado pelo *Air Time* (AT) maior para SFs maiores. O AT indica o tempo em que um pacote leva para chegar ao destino final, logo, quanto maior este tempo, mais tempo o ED passará no estado de TX, que possui maior consumo energético.

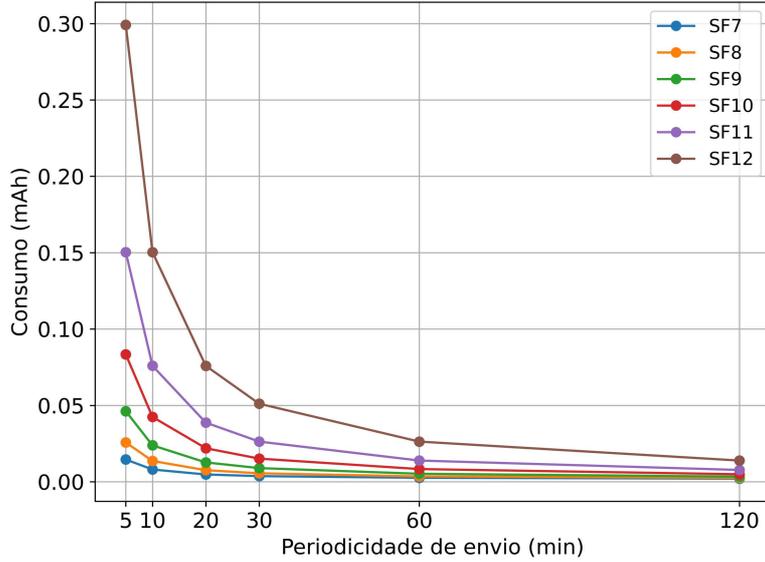


Figura 7 – Consumo energético para cada SF. Elaborado pelo Autor

2.6.2 Análise de desempenho e consumo energético do ADR

Para análise do consumo energético e do desempenho do ADR, essa campanha de simulação avalia o consumo energético do ADR em comparação aos algoritmos de atribuição do vetor \vec{a} descritos na Seção 2.3, isto é, fixo em SF7, fixo em SF12 e a atribuição *Equal Split*. A simulação contempla apenas um SNR no centro de um círculo de raio variável, no qual os EDs de classe A são posicionados de forma uniformemente aleatória. Assim, à medida que esse raio aumenta, os EDs ficam mais espalhados na área, reduzindo a densidade de nós, mas aumentando a distância média entre ED e SNR. Cada ED envia um pacote em um tempo aleatório dentro de um intervalo de 10 minutos. A Tabela 4 apresenta os parâmetros da simulação. O modelo de propagação de perda de percurso log-distância [58] pode ser descrito por:

$$PL(d) = PL(d_0) + 10 n_a \log_{10} \left(\frac{d}{d_0} \right), \quad (2.3)$$

em que $PL(d)$ é a perda de percurso na distância de interesse d , $PL(d_0)$ é a perda de referência do modelo, d_0 a distância de referência, n_a simboliza o expoente de atenuação.

Tal modelo determinístico é adotado para não incluir as aleatoriedade imposta por modelos de canal mais complexos, o que facilita focar no *trade-off* cobertura-consumo. Os resultados apresentados são considerados para uma rede em estado estacionário e as colisões entre SF são tratadas de forma quase ortogonal, ou seja, podem ocorrer mesmo com diferença de potência recebida entre sinais simultâneos.

A Figura 8 apresenta o consumo médio por ED de classe A em função do raio de ocupação dos EDs, na qual é possível observar a adaptabilidade do ADR em função do

Tabela 4 – Configurações da simulação.

Parâmetro	Valor
Tamanho do pacote	23 Bytes
Raios	2,4,6,8,10,12,15 km
Número de EDs	1000
Tráfego	<i>Uplink</i>
Potência de transmissão	14 dBm
Largura de banda	125 kHz
Fatores log-distância	$d_0 = 1$ m; $PL(d_0) = 7,7$ dB; $n_a = 3,48$
Periodicidade de envio	600 s

aumento de raio. Visando um maior alcance, SFs maiores são alocados, aumentando o consumo energético. Como os outros algoritmos alocam SFs de forma estática, o consumo médio não muda, uma vez que o AT, que depende do SF atribuído, é o mesmo independente da distância dos EDs em relação ao SNR. Os algoritmos que usam apenas o SF7 e o SF12 atuam como limitantes inferior e superior para o consumo energético, respectivamente. Para raios maiores que 6 km, o algoritmo *Equal Split* apresenta menor consumo que o ADR por manter a alocação em SFs menores, o que gera um aumento na perda de pacotes recebidos. Em geral, o consumo energético de qualquer proposta de atribuição de SF e ADR pode ser descrito por

$$j_{medio} = \sum_{n=7}^{12} k_n * j_{SFn}, \quad (2.4)$$

em que j_{medio} é o consumo médio dos EDs em mAh, k_n é a proporção, entre 0 e 1 de dispositivos utilizando o SFn e j_{SFn} é o consumo energético, em mAh, provido pelo SFn , de modo que k_7 seja a proporção de EDs utilizando $SF7$ e consumo j_{SF7} , k_8 a proporção de EDs utilizando $SF8$ e consumo j_{SF8} , e assim por diante.

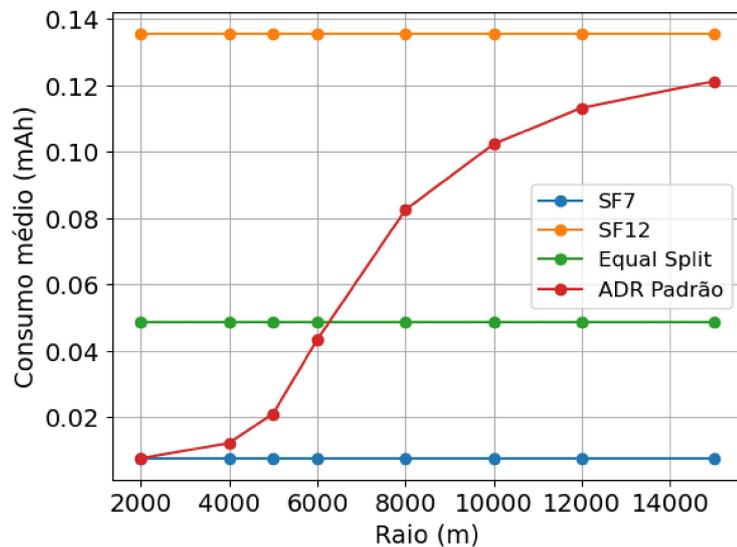


Figura 8 – Consumo energético por algoritmo. Elaborado pelo Autor.

A Figura 9 mostra a porcentagem de pacotes perdidos ou *Packet Loss Rate* (PLR), em linha cheia, e a porcentagem de pacotes perdidos por interferência ou *Packet Interference Rate* (PIR), em linha tracejada. Nota-se que a interferência entre EDs com mesmo SF é a principal causa da perda de pacotes até o raio de 8 km. Após esse raio, há uma redução da PIR, indicando uma perda maior por falta de cobertura, pois a PLR aumenta mesmo para o SF12. Em termos de desempenho, o ADR prevalece em relação as outras propostas, com maior porcentagem de acerto de pacotes para quase todos os raios, exceto para o intervalo entre 6 e 8 km. Nessa região, o *Equal Split* apresenta tanto consumo quanto PLR menores que o ADR.

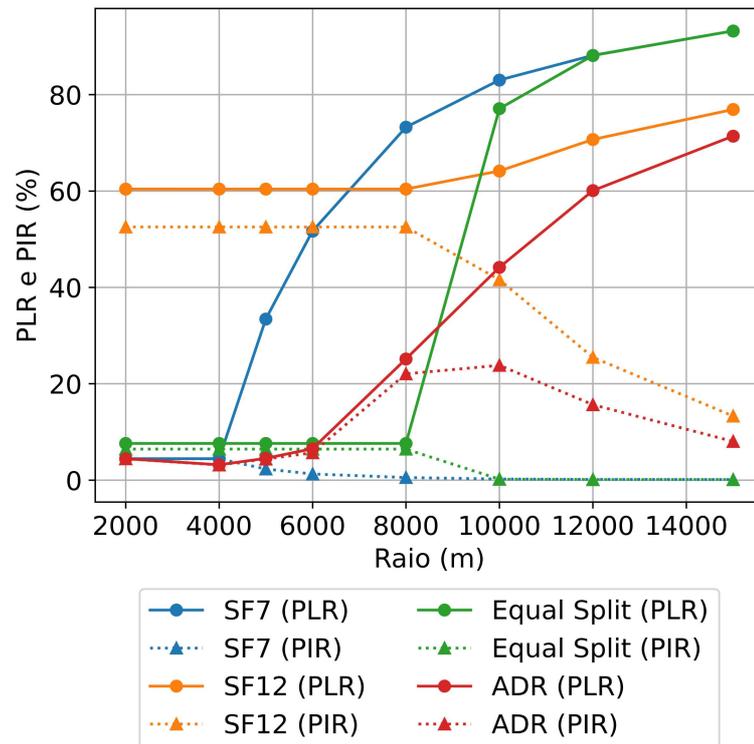


Figura 9 – PLR e PIR para cada algoritmo. Elaborado pelo Autor.

Ao verificar a PIR na Figura 9, nota-se que há um aumento da interferência no ADR na região de final de cobertura, enquanto o *Equal Split* mantém o nível de interferência, visto que sua alocação de SF é a mesma para qualquer densidade de nós. Como o ADR é baseado na sensibilidade, o algoritmo tende a atribuir mais EDs ao SF12 para raios maiores. Com mais nós no mesmo SF, há um aumento da colisão entre pacotes e, por conseguinte, da interferência. Já o *Equal Split* apresenta menores consumo e interferência nessa região de borda. Isso mostra que há oportunidades para melhorias do ADR para EDs na borda da área de cobertura do SNR, e que propostas de novos algoritmos podem superá-lo não só em desempenho de taxa de pacotes entregues mas também em termos de consumo energético.

2.6.3 Potência de Transmissão e Consumo Energético

Essa campanha de simulação tem o objetivo de mensurar o aumento de consumo e PDR, caso os dispositivos mantenham o mesmo SF, porém aumentando a potência de transmissão. Inicialmente, o SF escolhido foi o SF7 por apresentar o menor consumo. Devido a sua menor sensibilidade, em uma rede que faz uso apenas desse SF, existem mais pacotes que chegam até o receptor abaixo da sensibilidade. A Tabela 5 apresenta os parâmetros de simulação. São avaliadas o impacto de aumentar as potências a cada 3 dB partindo do valor de 3 dBm até 12 dBm e 12 para 14 dBm. Tais valores de potência apresentam valores de corrente disponibilizados pelo *datasheet* [51] e a cada 3 dB tem-se o dobro de potência de transmissão em relação ao anterior, sendo 14 dBm o valor máximo de potência de transmissão disponibilizado pelo *datasheet*.

Tabela 5 – Parâmetros de simulação.

Parâmetro	Valor
Tamanho do pacote	23 Bytes
Raios	2,3,4,5,6,8 km
Número de EDs	1000
Tráfego	<i>Uplink</i>
Potências de transmissão	3, 6, 9, 12, 14 dBm
Largura de banda	125 kHz
SF	7
Fatores log-distância	$d_0 = 1$ m; $PL(d_0) = 7, 7$ dB; $n = 3, 48$
Periodicidade de envio	600 s

A Tabela 6 apresenta o aumento de consumo ao aumentar a Potência de Transmissão (TxPower) no SF7. Como o consumo energético independe da distância que o ED está do SNR, já que o SF está fixo, a distância não influencia na eficiência energética. A Figura 10 apresenta, o impacto em termos de desempenho médio para EDs de classe A em função do raio de ocupação dos EDs, ainda mantendo SF7 fixo. O eixo Y exibe o ganho de PDR sob mesma mudança. Cada linha do gráfico representa o impacto de aumentar certa potência de transmissão em um mesmo raio, para os raios 2, 3, 4, 5, 6 e 8 km.

Tabela 6 – Aumento de consumo ao aumentar a potência de transmissão para o SF7.

Aumento de <i>TxPower</i> (dB)	Aumento de consumo (mAh)
3 para 6 dBm	0,0003367
6 para 9 dBm	0,0005050
9 para 12 dBm	0,0007575
12 para 14 dBm	0,0009259

É possível observar na Tabela 6 que o consumo energético tem um aumento muito baixo, na casa de $10^{-1}\mu\text{Ah}$, enquanto a PDR tem o ganho variando entre 0 e 25,3% dependendo do raio da rede. O ganho de PDR existe devido à presença de pacotes que foram enviados, mas que estão abaixo da sensibilidade do receptor. Portanto, ao aumentar a potência de transmissão, uma parcela destes pacotes se tornam bem sucedidos, aumentando a PDR.

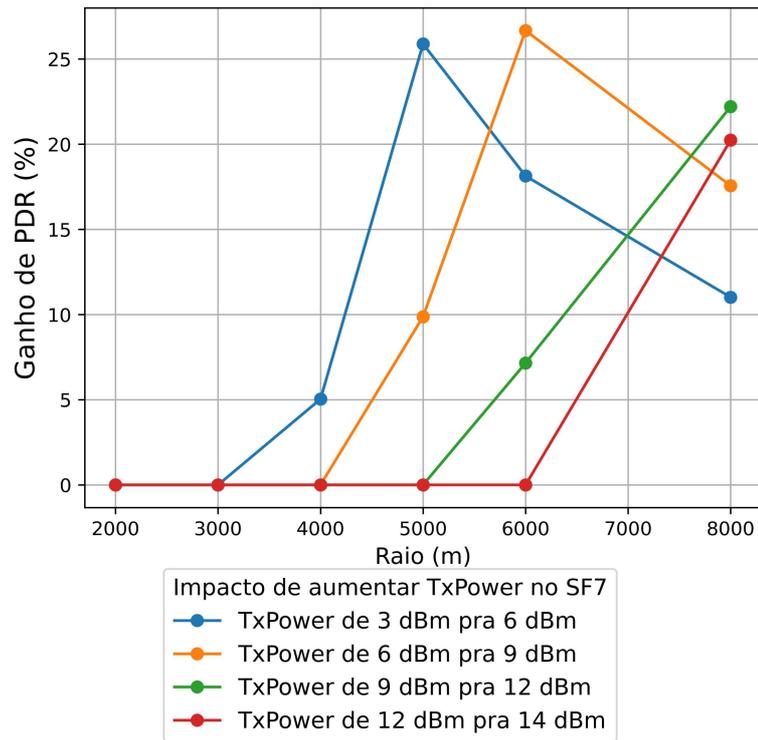


Figura 10 – Impacto em consumo e desempenho aumentando potência de transmissão. Elaborado pelo Autor.

2.6.4 Fator de Espalhamento e Consumo Energético

Por fim, essa campanha de simulação busca mensurar o aumento do consumo energético e a PDR caso os dispositivos mantenham a mesma potência de transmissão, porém aumentem o SF. A potência de transmissão escolhida foi 3 dBm por ser a menor, destacando a flutuação de PDR e o impacto do aumento de SF. A Tabela 7 apresenta os parâmetros de simulação. São avaliados todos os SFs disponíveis com potência de 3 dBm.

Tabela 7 – Configurações da quinta simulação.

Parâmetro	Valor
Tamanho do pacote	23 Bytes
Raios	2,3,4,5,6,8 km
Número de EDs	1000
Tráfego	<i>Uplink</i>
Potência de transmissão	3 dBm
Largura de banda	125 kHz
SF	7,8,9,10,11,12
Fatores log-distância	$d_0 = 1$ m; $PL(d_0) = 7,7$ dB; $n = 3, 48$
Periodicidade de envio	600 s

A Tabela 8 apresenta o aumento de consumo ao aumentar o SF com potência de transmissão igual a 3 dBm. Conforme o esperado, o aumento de consumo independe da distância que o ED está do SNR, já que todos os EDs trocam os SFs conjuntamente e

sem aumento de potência de transmissão. A Figura 11 apresenta o impacto em termos de desempenho médio para EDs em função do raio de ocupação dos EDs. O eixo Y exibe o ganho de PDR ao aumentar o SF. Cada linha do gráfico representa o impacto de trocar para o SF seguinte em um mesmo raio para os raios 2, 3, 4, 5, 6 e 8 km.

Tabela 8 – Aumento de consumo ao aumentar a potência de transmissão no SF7.

Aumento de SF	Aumento de consumo (mAh)
SF7 para SF8	0,0033670
SF8 para SF9	0,0062289
SF9 para SF10	0,0114479
SF10 para SF11	0,0204545
SF11 para SF12	0,0454544

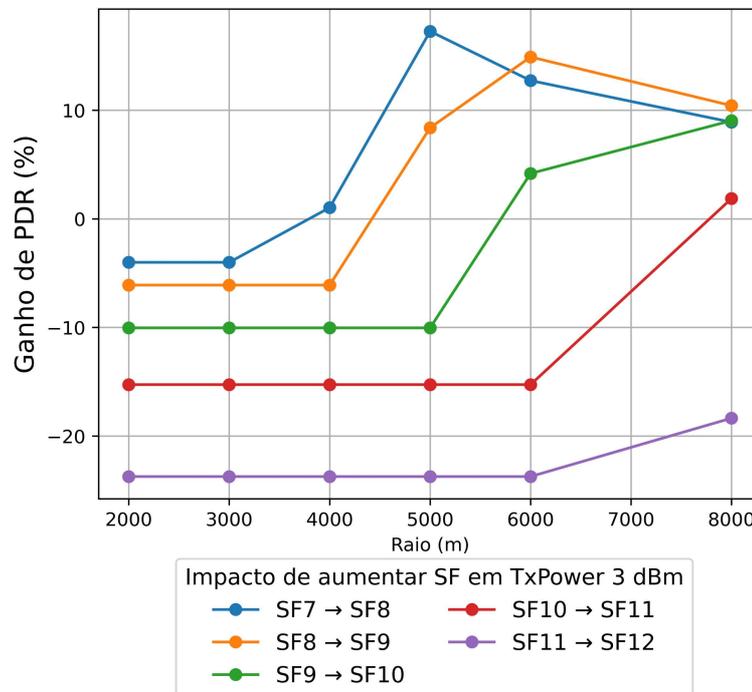


Figura 11 – Impacto no desempenho aumentando SF. Elaborado pelo Autor.

É possível observar que o consumo energético tem um aumento significativamente maior do que no caso anterior apresentado na Tabela 6, na casa de 10^{-3} mAh para SFs menores e 10^{-2} mAh para SFs maiores. Enquanto isso, a PDR varia entre -23,3% e 15,0% dependendo do raio da rede. Para todas as possibilidades de aumento de SF nos raios de 2 km e 3 km, nota-se uma redução da PDR (ganho negativo) e que o aumento de SF11 para SF12 resultou em queda de PDR para todos os raios disponíveis. Essa variação com maior intervalo, incluindo queda de desempenho, se dá porque SFs maiores possuem maior AT, portanto, há maior probabilidade de interferência de pacotes com o mesmo SF. Com isso, há o risco de pacotes que estavam sendo recebidos corretamente pelo receptor, ou até mesmo pacotes que estavam abaixo da sensibilidade, se tornarem pacotes interferidos.

Além disso, é avaliado o desempenho de aumentar a potência de transmissão e o SF. Analisando as Figuras 10 e 11, observa-se que a troca de SF impacta mais no desempenho e no consumo do que a potência de transmissão. Porém esse impacto nem é sempre positivo e possui um custo energético elevado, podendo alcançar 49,09 vezes o aumento de consumo que se obtém com a troca de potência de transmissão. Sendo assim, conclui-se que aumentar a potência de transmissão é a escolha prioritária para buscar melhoria de desempenho, já que com um pequeno valor de consumo a mais obtém-se um ganho de PDR relevante. Ademais, a troca de SF não traz, necessariamente, um impacto positivo no desempenho da rede. A PDR sofre redução quando uma grande parcela dos EDs faz uso do mesmo SF, pois há aumento da interferência entre dispositivos com mesmo SF. Outro fator de redução da PDR é a maior concentração de EDs em SFs elevados, que possuem maior AT e, conseqüentemente, sofrem mais interferência.

2.7 Conclusões

Este capítulo apresentou o conceito do mecanismo de *Adaptive Data Rate*, bem como propostas já conhecidas, como o algoritmo sugerido pela *Semtech* e o implementado no simulador de redes ns-3, além de novas propostas que não fazem uso de sensibilidade para escolha do SF utilizado pelo ED [24]. Em seguida, foi explicitado como o consumo energético se dá em redes LoRaWAN e o impacto da escolha de SF e de potência de transmissão no consumo.

Por fim, simulações evidenciaram a importância de alocação adequada de SF para redução do consumo sem perda de desempenho. Os efeitos de mudança de SF apresentaram mais impacto no consumo energético do que a mudança de potência. Foi observado que, sem uma estratégia bem definida, a troca de SF pode impactar negativamente na taxa de entrega de pacotes e aumentar o consumo médio dos EDs, diminuindo a eficiência da rede.

Um outro fator que influencia no desempenho e no consumo é a linha de visada entre o ED e a antena, uma vez que permite caracterizar dois canais de transmissão distintos: canal com visada direta (*Line of Sight* (LOS)) e canal sem visada direta (*Non Line of Sight* (NLOS)). Essa caracterização permite a diferenciação de propagação entre os dois canais, além de facilitar a implementação de ajuste dinâmico de parâmetros de transmissão personalizados para cada canal. Dessa forma, realizar um estudo sobre o canal com identificação de uma linha de visada é importante não só por contribuir no ganho de desempenho, mas também para a eficiência energética dos EDs, fator relevante em aplicações de IoT que demandam operação contínua e prolongada

3 Identificação Inteligente de Linha de Visada em Redes LoRaWAN

As redes LoRaWAN apresentam potencial para diversas aplicações no mercado de IoT. Essas aplicações são estratégicas, contribuindo para o desenvolvimento de *smart cities* e aprimorando o planejamento urbano ao possibilitar o monitoramento em tempo real do trânsito, a identificação de congestionamentos, a análise de condições meteorológicas, como chuvas, que afetam a mobilidade urbana e o plano de ação para minimizar alguns desses problemas.

A caracterização de canal de acordo com a linha de visada, isto é, com linha de visada (LOS) ou sem linha de visada (NLOS), pode auxiliar na otimização de parâmetros das redes LoRaWAN. Identificar a presença de linha de visada pode auxiliar na determinação do SF apropriado, propiciando um menor tempo de entrega de pacotes, e no desenvolvimento de dispositivos de menor consumo energético, nos quais um amplificador de radiofrequência pode ser acionado de forma mais eficiente. Outrossim, a distinção entre visadas LOS e NLOS auxilia para a análise da perda de percurso [20], além de aprimorar o desempenho de algoritmos de localização e rastreamento de EDs [21], servindo como complemento aos dados fornecidos por sistemas de posicionamento por satélite.

Este capítulo tem como principal contribuição a aplicação de técnicas de aprendizado de máquina para a classificação de cenários LOS/NLOS em ambientes externos. É primeiramente apresentada a campanha de medição realizada e posteriormente a etapa de classificação. Em relação à campanha de medição, é detalhado o percurso e ambiente de propagação, bem como os equipamentos utilizados para compreender a coleta de dados e a arquitetura da solução. Em relação à classificação inteligente de linha de visada, discute-se inicialmente por conceitos de aprendizado de máquina e os algoritmos utilizados para, em um segundo momento, detalhar como foram utilizados para classificação de linha de visada e, por fim, analisar o desempenho de cada algoritmo proposto.

A campanha de medição, realizada inicialmente por [59], é atualizada para este trabalho a fim de identificar qual o estado do enlace (LOS ou NLOS) de cada ponto de amostra coletada na campanha de medição.

3.1 Objetivo

Buscando a caracterização do canal com a identificação de visada, a campanha de medição foi realizada no campus da UFJF percorrendo os pontos de maior circulação dos ônibus circulares. Visando cobrir uma região de relevo acidentado e composta de prédios com diferentes alturas, o GW foi instalado no prédio Itamar Franco da Faculdade

de Engenharia, visto que este ponto está localizado em uma região de maior altitude e possui visada direta para alguns prédios da universidade. Para aumentar a cobertura do GW, uma antena que opera na faixa de 915 MHz foi instalada no topo do mesmo prédio. Completando a rede LoRaWAN, um ED foi implementado para capturar os dados em movimento pelo campus da UFJF. Por fim, o GW foi conectado à infraestrutura da (TTN!) ((TTN!)) [60] e o armazenamento de dados foi realizado a cada 8 segundos. A Tabela 9 detalha as especificações técnicas da antena.

3.2 Configuração dos equipamentos

Para redução de custos, o GW e o ED foram implementados a partir de um kit de desenvolvimento LoRaWAN composto de módulos MTAC, utilizado como GW, [61] e mDot, utilizado como ED [62], ambos da Multitech. Seguindo a mesma linha, optou-se por utilizar um ED mais simples, que não possui função de geolocalização nativa, conectado a um celular responsável por capturar sinais de GPS. Além da economia financeira, a conexão ao celular permite maior precisão de GPS se comparado com outros modelos de ED que possuem a função de geolocalização nativa disponíveis no mercado. As Tabelas 10 e 11 detalham os dispositivos utilizados como GW e ED, respectivamente.

A comunicação com o celular é realizada através de um cabo USB e auxílio do módulo *Android Debug Bridge* (ADB). Com isso, o celular captura os dados de altitude, latitude, longitude, número de satélites utilizados e precisão do GPS. Tais informações são enviadas para um computador que também está conectado ao módulo mDot através de um cabo USB, permitindo que elas sejam salvas no disco local em tempo real. Enquanto o celular é responsável por capturar as informações descritas, o módulo mDot foca apenas na coleta de valores de RSSI medidos tanto do lado do ED quanto do GW.

Dois *scripts* relacionados a *The Things Network* (TTN) são executados em sequência, o primeiro para conectar a TTN ao ED através do protocolo *Message Queue Telemetry Transport* (MQTT) e o segundo para consultar o registro dos pacotes armazenados [59]. Como cada pacote possui seu identificador, pode-se integrar as informações referentes à localização junto às demais armazenadas pela TTN. Os parâmetros coletados são: *Time* (UTC -3), *GPS Time* (UTC +0), *id*, Latitude (graus), Longitude (graus), Altitude (m), *GPS Precision*, *# Satellites*, ED RSSI (dB), GW RSSI (dB).

Os parâmetros *Time* e *GPS Time* são marcadores temporais, sendo o horário da coleta da amostra de acordo com o fuso horário local (UTC-3) e com o fuso horário do meridiano de Greenwich (UTC+0), respectivamente, enquanto o parâmetro *id* indica o número da amostra do conjunto de dados. Latitude, Longitude e Altitude são parâmetros de localização obtidos pelo GPS presente na configuração montada, *GPS Precision* representa a precisão do GPS, em que o menor valor indica mais precisão e o maior valor menos precisão, sendo sua variação de 1 a 5 e *# Satellites* indica o número de satélites

Tabela 9 – Configurações da antena.

Parâmetro	Valor
Tipo	Polidesign PLD COL890-9605
Material Externo	Alumínio
Material Interno	Fibra de Vidro
Comprimento	1,80 m
Diâmetro	44 mm
Diretividade	Omnidirecional
Ganho	9 dBi
Impedância	50 Ω

Tabela 10 – Configurações do *Gateway*.

Parâmetro	Valor
Processador	Raspberry Pi 3B+
RAM	1GB
Armazenamento	Samsung SD Card EVO Plus 64GB (130MB/s)
Fonte de alimentação	12 V / 3 A
Módulo LoRa	MTAC-LORA 94557300LF4
Ganho do Módulo	3 dBi
Impedância	50 Ω

Tabela 11 – Configurações do *End Device*.

Parâmetro	Valor
Tipo	Multitech mDot 9153
Modo de operação	<i>Over-the-Air</i>
Largura de banda	125 kHz
Fator de espalhamento	12
Potência de transmissão	14 dBm
Ganho da Antena	5 dBi
ADR	Desligado
Frequência	915 MHz
Sensibilidade	RSSI $\in [-140, 0]$ dB

utilizados para obter essas informações. Por fim, ED RSSI e GW RSSI são indicadores de potência do sinal recebido para o *End Device* e *Gateway*, respectivamente.

3.3 Coleta de dados

Com a rede configurada, a campanha foi executada seguindo o trajeto dos ônibus circulares no campus da UFJF e foi dividida em dois dias de medição. No primeiro dia, o ED é carregado por um indivíduo a pé, posicionado a uma altura aproximada de 1 m em relação ao solo e percorrendo os prédios de Engenharia, Restaurante Universitário, Artes, Ciências Exatas, Biologia, Letras, Reitoria, Direito, Jornalismo e Ciências Humanas com uma velocidade média aproximada de 4 km/h.

Enquanto isso, no segundo dia o ED é posicionado no banco de um carro, a uma distância aproximada de 80 cm em relação ao solo, percorrendo os prédios de Educação

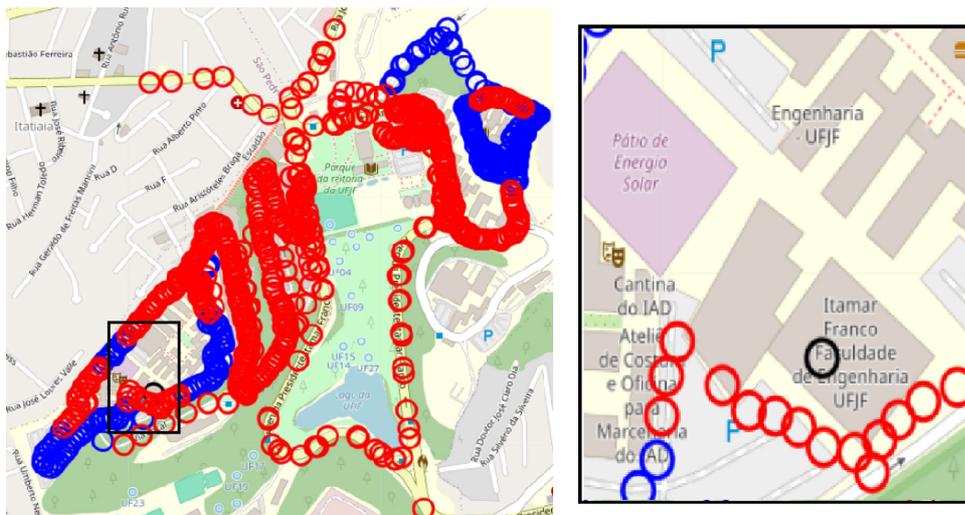


Figura 12 – Mapa da campanha de medição com destaque para posição do GW. Elaborado pelo Autor.

Física, Medicina e Hospital Universitário, com uma velocidade média de aproximadamente 20 km/h. As condições climáticas de ambos dias estavam favoráveis, isto é, sem chuva e ventos fortes, além de pouca variação de temperatura entre os dias.

A Figura 12 apresenta os pontos registrados durante a campanha de medição, em que os pontos azuis são LOS, em vermelho NLOS e em preto a localização da antena do GW, que pode ser observada de forma mais próxima no quadro em destaque. A identificação de visada é realizada a partir de inspeção visual, com auxílio de um binóculo 60x60 e alcance até 10km, em cada ponto registrado pelo GPS. De forma manual, a identificação de visada de cada amostra é registrada durante a coleta e, posteriormente, inserida no banco de dados.

3.4 Classificação

A classificação é uma aplicação do aprendizado de máquina supervisionado que tem como objetivo prever classes a partir de dados conhecidos fornecidos como entradas. Um modelo preditivo de classificação é aquele que aproxima uma função de mapeamento F a partir de variáveis de entrada X para saídas discretas Y . Há quatro tipos principais de classificação: binária, multi classes, desbalanceada e multi rótulo [63]. Neste trabalho, é utilizada a classificação binária, isto é, presença ou não de linha de visada.

Para realizar a classificação em cada classe, o classificador separa uma parte dos dados como treinamento a fim de conhecer e compreender os padrões das variáveis de entrada e como se relacionam a categoria que as representam. Neste trabalho, amostras NLOS (classe 0) e amostras LOS (classe 1) devem estar contidas no conjunto de dados separados pelo classificador. Um conjunto de dados de treinamento é considerado bom quando o classificador reconhece os padrões das variáveis de entrada de tal forma que

consegue generalizá-los para situações ainda não vistas no conjunto de dados de treino.

Muitos são os algoritmos de classificações. Neste trabalho, serão utilizados *Random Forest* (RF), máquinas de vetor de suporte (*Support Vector Machine* (SVM)), Rede Neural Multi Camadas Perceptron (*Multi Layer Perceptron* (MLP)) e vizinho mais próximo (*K-Nearest Neighbour* (KNN)). Cada algoritmo utiliza conceitos base diferentes, portanto é importante conhecer as principais de características para escolher os algoritmos adequados para a situação de uso [64].

3.4.1 RF

O algoritmo RF constrói várias árvores de decisão de forma independente, adicionando recursos que geram aleatoriedade no momento do treinamento. Primeiramente, é preciso saber que a árvore de decisão é uma técnica que contém 3 elementos, nós, ramos e folhas. Sua construção se inicia pelo nó, um objeto que contém um teste sobre algum dos atributos de entrada X_i do conjunto de treino. O teste é aplicado e o nó raiz se divide, dando origem a um nó filho para cada resultado possível do teste, sendo que os ramos são responsáveis pela interligação entre os nós pai e nós filhos. Esse processo é efetuado de forma recursiva até que a profundidade máxima da árvore seja atingida, obtendo uma classe ao final [64].

3.4.2 SVM

O SVM é um algoritmo que tem como objetivo encontrar um hiperplano ou um conjunto de hiperplanos com a capacidade de separar duas classes distintas, realizando ainda uma otimização para alcançar a maximização da margem entre as classes. A margem é determinada pela distância entre o hiperplano e as amostras das classes que estiverem mais próximas a ele, as quais são chamadas de vetores de suporte [64].

Com isso, o método traça os vetores de suporte e, assim, um hiperplano que separa as categorias, compondo uma superfície de decisão. O hiperplano está posicionado de modo a maximizar a margem de separação [63] e, para problemas não linearmente separáveis, como neste trabalho, o SVM usa o recurso das funções de Kernel. Essa é uma função que modifica o espaço amostral para mapear os dados em um novo espaço com um número maior de dimensões, utilizando os produtos escalares.

3.4.3 MLP

O algoritmo MLP constitui uma arquitetura de rede neural *feedforward* que modela relações não-lineares entre variáveis de entrada e saída através de múltiplas camadas de neurônios interconectados. Cada neurônio processa uma combinação linear de suas entradas seguida da aplicação de uma função de ativação não-linear, permitindo à rede aproximar funções complexas [63].

O treinamento do MLP se baseia no método de retropropagação, o qual utiliza a descida de gradiente para minimizar uma função de custo. Nesse método, o erro entre a saída prevista e o valor desejado é propagado de forma reversa pelas camadas, e os gradientes parciais são calculados para ajustar iterativamente os pesos sinápticos [63]. Por fim, a decisão final da saída é obtida pela aplicação da função de ativação da camada de saída ao somatório ponderado dos sinais provenientes da camada anterior, transformando os resultados internos da rede em uma resposta interpretável, que neste trabalho representará, as categorias discretas 0 (NLOS) ou 1 (LOS).

3.4.4 KNN

O KNN é um algoritmo de aprendizado de máquina popular em virtude de ser de fácil implementação do que os outros algoritmos pelo fato de conter poucos parâmetros se comparados a outras arquiteturas mais complexas, como MLP [64].

Seu funcionamento baseia-se na premissa de que instâncias semelhantes tendem a pertencer à mesma classe, ou seja, a classificação de uma nova amostra é determinada pelas classes das amostras mais próximas a ela em um espaço multidimensional. Dado um conjunto de dados de treinamento contendo n amostras classificadas (x_i, y_i) , em que x_i representa um vetor de características e y_i a classe associada, o KNN realiza a classificação de uma nova amostra x calculando a distância entre x e todas as amostras no conjunto de treinamento. Após isso, as k amostras mais próximas à nova amostra observada são selecionadas e a classe da nova amostra é definida com base na classe predominante entre os k vizinhos selecionados [64]. O valor de k é um hiperparâmetro que influencia diretamente no desempenho do algoritmo.

3.4.5 Busca por Hiperparâmetros

Os hiperparâmetros são aqueles cujos valores são empregados para aprimorar o processo de aprendizagem dos modelos. Para encontrá-los em cada aplicação desenvolvida, utilizou-se a técnica conhecida como pesquisa por grade, *Grid Search* [65]. Ela é um método de otimização que consiste em realizar numerosas combinações dos hiperparâmetros a fim de encontrar uma solução ótima. Para isso, é necessário definir o intervalo de valores possíveis para cada um dos hiperparâmetros relativos a cada técnica, que podem ser números máximos de iterações que a pesquisa deve realizar, função de perda que será minimizada, tolerância de iteração, número de folhas, entre outros.

3.5 Classificação Inteligente de Visada

A campanha de medição resultou um total de 794 amostras, das quais 238 são LOS (29,97%) e 556 NLOS (70,03%). Com isso, pode-se aplicar as técnicas de aprendizado de máquina a fim de classificar os sinais coletados. As amostras classificadas como LOS tem valor de visada igual a 1, enquanto as classificadas como NLOS possuem valor igual a 0.

As técnicas KNN, MLP e SVM foram escolhidas por serem técnicas clássicas da literatura [64] e, portanto, referências na comparação com outros modelos. Além disso, MLP e SVM são algoritmos robustos contra *outliers*, sendo capazes de compreender relações complexas sem ser afetado por eles. Por fim, a escolha do modelo RF se dá pelo fato de ser um algoritmo de aprendizado de máquina conjunto que combina várias árvores de decisão para criar um modelo assertivo mais robusto contra *outliers*. A combinação de várias árvores de decisão descorrelacionadas permite uma variação de resultados de cada ramo e sua diversificação garante que os erros sejam sobrepostos por acertos, fornecendo um modelo mais robusto em termos de desempenho [64].

Antes de iniciar o processo de treinamento, é necessário realizar a extração de parâmetros, a validação cruzada e o pré-processamento, etapas cruciais para aumentar a confiabilidade das técnicas de aprendizado, ampliar a qualidade do treinamento e otimizar o desempenho das técnicas avaliadas.

A extração de parâmetros visa reduzir a complexidade do conjunto de dados, mantendo apenas as características mais relevantes para a classificação, acelerando a convergência da técnica e melhorando a generalização dos dados de entrada. Em outras palavras, alguns parâmetros podem não contribuir significativamente para a tarefa de classificação, enquanto outras podem ser altamente correlacionadas. Portanto, a remoção de características irrelevantes ou redundantes reduz a complexidade do modelo e evita *overfitting*. Uma forma comum de avaliar a redundância de característica é através da avaliação da matriz de correlação linear entre os parâmetros [64], enquanto a remoção de características irrelevantes pode ser realizada utilizando a seleção de parâmetros baseada em relevância como critério. Este trabalho adotou ambas abordagens para efetuar a extração de parâmetros.

O pré-processamento trata os dados antes de serem inseridos nos modelos de aprendizado de máquina, visando identificar e tratar valores ausentes, e, principalmente, balancear os dados. Dados balanceados minimizam valores *outliers* e facilitam o entendimento dos modelos para a classificação, acelerando a convergência e melhorando os resultados finais. Neste trabalho, o balanceamento de dados de entrada utilizado foi a normalização, ou seja, todos os parâmetros pertencem ao intervalo entre 0 e 1. Com isso, 0 representa o valor mínimo e 1 o valor máximo do parâmetro em questão avaliado.

3.5.1 Extração de Parâmetros

Primeiramente é necessário selecionar os parâmetros de entrada com base na relevância. O foco desta etapa está na seleção dos parâmetros que possuem relação direta com o problema em análise, garantindo que apenas as informações mais valiosas sejam consideradas para a classificação. Portanto, de imediato são eliminados os parâmetros ‘id’, ‘Time’, ‘GPS Time’, ‘GPS Precision’ e ‘# Satellites’, uma vez que o identificador da amostra e marcadores temporais podem indicar correlações inexistentes e grau de precisão do GPS e número de satélites são irrelevantes, já que todas as amostras compartilham o

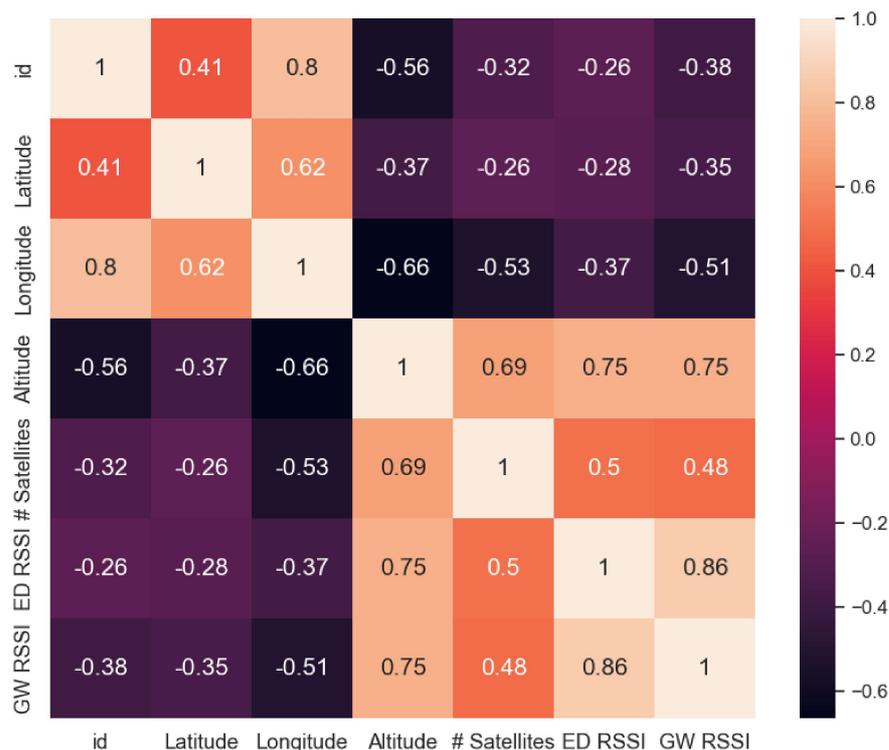


Figura 13 – Matriz de Correlação entre os parâmetros. Elaborado pelo Autor.

mesmo grau de precisão e número de satélites.

Seguindo adiante, a Figura 13 apresenta a matriz de correlação linear entre os parâmetros. É possível identificar, nessa figura, que os pares ‘ED RSSI’ e ‘GW RSSI’; ‘Longitude e Altitude’; ‘Longitude e Latitude’; ‘ED RSSI’ e ‘Altitude’; ‘GW RSSI’ e ‘Altitude’ possuem, em módulo, alta correlação linear entre si. Entretanto, os parâmetros ‘Latitude’, ‘Longitude’ e ‘Altitude’, são imprescindíveis para a classificação correta das amostras em LOS e NLOS, assim, não serão eliminados mesmo que possuam alta correlação com outros parâmetros ou entre si. Com isso, restam os parâmetros ‘ED RSSI’ e ‘GW RSSI’ com maior correlação linear. Como ambos apresentam, em módulo, a mesma correlação entre todos os outros parâmetros avaliados, optou-se por retirar o parâmetro ‘GW RSSI’, pois o objeto de interesse de classificação deste trabalho é a classificação de visada LOS e NLOS de acordo com o comportamento do *End Device*, ou seja, o observado pelo ED. Portanto, o parâmetro ‘ED RSSI’ possui maior relevância, sendo ele adotado como critério de desempate. Desta forma, foram eliminados quatro parâmetros da análise, facilitando a atuação dos métodos de aprendizagem e identificação dos padrões necessários para atingir um bom resultado na classificação. Assim, os parâmetros utilizados como entrada de cada método de classificação são latitude, longitude, altitude e ED RSSI.

3.5.2 Validação Cruzada

A forma mais comum de validação cruzada é através do *k-fold* [63], técnica que divide o conjunto de dados em *k* subconjuntos (*folds*), em que o modelo é treinado em *k – 1 folds*

e validado no *fold* restante. Este processo é repetido k vezes, garantindo que cada *fold* seja utilizado como conjunto de validação exatamente uma vez. Ao treinar e validar o modelo em diferentes subconjuntos, o *k-fold* proporciona uma avaliação mais abrangente do desempenho, minimizando o risco de *overfitting* ou *underfitting*. Isso é especialmente relevante em conjuntos de dados limitados, como neste trabalho, nos quais a variabilidade na distribuição dos dados pode impactar a capacidade do modelo de generalização.

3.5.3 Pré-Processamento

A normalização garante que todos os parâmetros de entrada tenham o mesmo peso durante o treinamento, evitando um viés com tendência para aqueles com maior valor, em módulo, dentro do conjunto de amostras do parâmetro avaliado. Após a transformação, os dados pertencem ao intervalo entre 0 e 1, isto é

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}, \quad (3.1)$$

em que X_{norm} é o valor normalizado, X é a amostra a ser normalizada, X_{max} é o maior valor do conjunto de dados e X_{min} é o menor valor do conjunto de dados.

3.5.4 Métricas para avaliação das técnicas

No contexto de aprendizado de máquina, muitas métricas podem ser utilizadas para avaliar a qualidade dos resultados obtidos para cada técnica. Neste trabalho são adotadas as métricas *Score*, *Precision*, *Recall*, *F1 Score* e Tempo de Processamento.

O *Score* é a métrica mais simples para técnicas de classificação [64]. Ele apresenta a relação entre Verdadeiros positivos (VP) e Verdadeiros Negativos (VN) e Total de Amostras (TA) analisados pelo problema, ou seja,

$$Score = \frac{(VP + VN)}{TA} \quad (3.2)$$

Embora simples, essa métrica é muito utilizada em problemas de classificação binária, como neste trabalho, pois permite a visualização da taxa de acerto de forma rápida e intuitiva.

O *Recall* é uma métrica que indica a proporção de VP que foram corretamente identificados em relação ao número total de classificações dadas como positivas, ou seja, a soma de VP e Falsos Negativos (FN) [64], isto é,

$$Recall = \frac{VP}{(VP + FN)} \quad (3.3)$$

A relevância dessa relação se dá em situações em que FN são considerados mais prejudiciais do que Falsos Positivos (FP). Portanto, um alto índice de *Recall* implica em um modelo com baixo número de falsos negativos, o que nesse trabalho representa um baixo número de amostras LOS classificadas como NLOS.

A *Precision* é uma métrica relevante [64] para esse tipo de problema, dada sua capacidade de detectar FP presentes na classificação do modelo utilizado. Tal fator é fundamental no contexto deste trabalho, uma vez que classificar um ponto como LOS de forma errônea prejudica o desempenho da rede LoRaWAN, visto que acarreta em uma decisão de redução de recursos por parte da rede, como potência de transmissão e redução de SF. Desta forma, é necessário conhecer a ocorrência FP para dimensionar a porcentagem de pontos que estão susceptíveis a classificação errônea de acordo com cada modelo. Um alto índice de *Precision* apresentado pelo modelo de classificação implica em um modelo com baixa presença de FP, ou seja, amostras LOS são corretamente classificadas LOS. Assim, a *Precision* é dada por

$$Precision = \frac{VP}{(VP + FP)} \quad (3.4)$$

Por fim, o *F1 Score* é uma métrica que combina *Recall* e *Precision*, de tal forma que estabeleça uma média harmônica entre as duas, unindo a detecção de FN e FP [64], conforme

$$F1 = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (3.5)$$

Um *F1 Score* alto indica um equilíbrio entre a capacidade do modelo de identificar corretamente as amostras NLOS e evitar a classificação incorreta de amostras de NLOS como LOS.

3.5.5 Tempo de processamento

Em aplicações IoT, o tempo de processamento é uma métrica de desempenho importante, uma vez que técnicas complexas de maior carga computacional não são viáveis para classificação LOS/NLOS em aplicações com dispositivos móveis. Além disso, vale ressaltar que grande parte dos dispositivos IoT são limitados em termos de recursos e energia, portanto, é recomendado reduzir os recursos computacionais o máximo possível para aumentar a vida útil da bateria. Por esse motivo, o tempo de processamento para cada técnica é avaliado.

3.5.6 Hiperparâmetros

Todas as métricas de desempenho são avaliadas para cada subconjunto k , sendo $k = 10$, escolha mais comum na literatura [66]. Assim, a média e o desvio padrão dos resultados obtidos nas iterações fornecem uma estimativa mais precisa do desempenho do modelo, reduzindo a sensibilidade a variações específicas do conjunto de treinamento. Por fim, para encontrar os melhores hiperparâmetros para cada técnica, foi implementado o algoritmo *GridSearch* com várias combinações de hiperparâmetros distintas. A descrição desse método, bem como todos os valores de hiperparâmetros testados pode ser encontrada em [67]. Os melhores hiperparâmetros encontrados para cada modelo são apresentados abaixo. Todos os algoritmos desse capítulo foram implementados com a biblioteca *Scikit Learn* do *Python*.

- **KNN: n_neighbors:** 2; Número de Vizinhos
weight: uniform; Todos os vizinhos possuem pesos iguais.
algorithm: brute; Esse valor indica que a busca para encontrar os vizinhos mais próximos foi de força bruta, sem um critério específico para iniciar a busca.
p: 2; Esse valor indica que a distância utilizada foi a Euclidiana.
- **MLP: hidden_layer_size:** (3, 3, 3); Número de neurônios em cada camada oculta.
activation: tanh; Função de ativação para todas as camadas ocultas.
solver: lbfgs; Solucionador para otimização de peso é do tipo lbfgs, o qual é um otimizador na família de métodos quase-Newton.
alpha: 0,1; Peso do coeficiente de regularização L2.
max_iter: 10000; Número máximo de iterações.
tol: 0,0001; Tolerância para otimização.
- **SVM: C:** 10; Parâmetro de regularização também chamado de margem.
kernel: poly; Tipo de Kernel usado pelo algoritmo. Nesse caso, Kernel polinomial.
degree: 3; Grau do polinômio do Kernel.
coef0: 20,0; Termo independente do Kernel.
tol: 0,01; Tolerância para otimização.
gamma: scale. Coeficiente do Kernel.
- **RF: n_estimator:** 20; Número de árvores da floresta.
criterion: entropy; Função utilizada para mensurar a qualidade do ramo.
min_leaf_sample: 1; Número mínimo de amostras requeridas para ser considerado uma folha.
max_feature: log2; Número máximo de *features* que RF considera para dividir um nó. Nesse caso, $max_features = \log_2(n_features)$, em que $n_features$ é o número de *features* utilizadas.
class_weight: balanced_subsample. Pesos associados com as classes.

3.6 Resultados

Os algoritmos desse estudo foram implementados em *Python* 3,11 e executados em um computador com processador i7-8565U (2,7 GHz) e 8 GB de RAM. Mais detalhes sobre a implementação podem ser encontrados em [67]. É obtida a predição da classificação proposta pelos métodos apresentados na Seção 3.4 com os hiperparâmetros determinados e em seguida são calculados a média e o desvio padrão para cada uma das métricas de desempenho, que estão apresentados na Tabela 12.

A partir da Tabela 12, é possível afirmar que as técnicas aplicadas tiveram desempenho satisfatório na classificação. Entretanto, conforme destacado na

Tabela 12 – Desempenho dos modelos - média e desvio-padrão.

	<i>KNN</i>	<i>MLP</i>	<i>SVM</i>	<i>RF</i>
<i>Score (%)</i>	94,08 ± 2,50	95,34 ± 2,95	92,07 ± 2,93	97,48 ± 1,69
<i>Precision (%)</i>	96,04 ± 3,71	91,61 ± 8,08	85,66 ± 7,67	97,28 ± 2,31
<i>Recall (%)</i>	82,03 ± 8,17	92,75 ± 4,41	86,06 ± 7,56	93,47 ± 5,08
<i>F1 Score (%)</i>	88,24 ± 5,57	91,93 ± 4,73	85,57 ± 5,92	95,29 ± 3,46
Tempo (ms)	41,70 ± 5,26	4636,44 ± 1,74	383,60 ± 180,72	61,82 ± 6,69

Subseção 3.5.4, é importante observar a classificação errônea, para levar em consideração o peso dos FP e FN, a fim de evitar que a rede LoRaWAN remaneje os recursos computacionais de forma equivocada. Deste modo, o modelo com o melhor desempenho foi o RF, visto que obteve o maior valor para *Score* com um excelente resultado para as métricas *Precision* e *Recall*, resultando no maior valor de *F1 Score* entre todos os modelos. Isso indica uma melhor relação entre baixa presença de FP e FN, sendo esta a razão pela qual o RF se sobressai sobre KNN. Além disso, o desvio padrão de RF foi baixo, principalmente se comparado com os modelos MLP e SVM, indicando que há uma baixa variância na classificação, ou seja, os dados estão sendo classificados de forma próxima em cada um dos *folds* implementados pelo método *k-fold*. Por fim, o tempo de processamento do RF é o segundo mais baixo, mas pouco maior do que o KNN, evidenciando suas capacidades para aplicações IoT.

Embora o desempenho do KNN seja próximo ao do RF, a diferença de desempenho para os outros dois algoritmos é maior. A técnica SVM tem a média mais baixa em todas as métricas de classificação, chegando a quase 10% menor, em média, quando comparada ao RF, com tempo de processamento 6,205 vezes maior do que o do RF. Enquanto isso, o MLP tem uma média geral de classificação mais alta quando comparado ao SVM, mas o tempo de execução é aproximadamente 75 vezes maior do que o do RF, desencorajando seu uso em aplicações IoT.

3.7 Conclusão

Neste capítulo foi apresentado um estudo que compara o desempenho de alguns dos principais modelos clássicos de classificação de aprendizado de máquina presentes na literatura, que são MLP, KNN, SVM e RF. O desempenho dos algoritmos, considerando as métricas avaliadas, foi satisfatório, com destaque para o algoritmo RF, que obteve, em média e desvio padrão, os melhores resultados para o tipo de problema discutido. Todos os dados coletados e os programas desenvolvidos para a análise aqui descrita foram disponibilizados em [67].

Tendo em vista os resultados deste trabalho, é possível realizar testes de soluções que auxiliam na solução de problemas de tráfego de veículos no campus, tais como semáforos inteligentes, detectores de colisão ou até mesmo sensores dispostos ao longo do campus. Em complemento, o consumo de energia obtido a partir da execução de cada algoritmo

de classificação, bem como o canal o qual o fará uso, contribuem para a viabilidade de sua aplicação em um cenário de cidade inteligente e para o planejamento da manutenção dos dispositivos.

Por fim, a campanha de medição permitiu a diferenciação e caracterização entre os canais de LOS e NLOS. A partir da caracterização, é possível realizar simulações a fim de explorar mais profundamente os canais obtidos e escolher estratégias de alocação de SF e potência em função da linha de visada que melhoram o desempenho da rede neste cenário.

4 Alocação de SF em Função da Linha de Visada

A partir dos resultados obtidos na campanha de medição realizada no Capítulo 3, são exploradas novas alocações de SF e de potência de transmissão com base na identificação dos pontos LOS e NLOS. Tais investigações visam otimizar o desempenho de redes LoRaWAN, promovendo tanto a redução do consumo energético quanto o aumento da PDR. Para tanto, os dados coletados foram incorporados em simulações realizadas no ns-3, criando uma relação direta entre os dados coletados e os resultados simulados, possibilitando a análise de novos cenários baseados em sistemas reais, o aperfeiçoamento de parâmetros e a validação dos vetores \vec{a} de proporção de alocação de SF propostos.

4.1 Identificação de Linha de Visada e Aprimoramento de Redes LoRaWAN

A identificação precisa de pontos LOS e NLOS é um fator relevante para caracterização do canal. Nos ambientes identificados como visada, a propagação do sinal ocorre com menor atenuação, permitindo que haja redução da potência de transmissão e a alocação em SFs mais baixos, o que resulta em menor consumo de energético. Por outro lado, quando há detecção de barreiras que prejudicam a visada, a propagação do sinal sofre uma atenuação mais acentuada, exigindo a utilização de SFs mais elevados e o aumento da potência de transmissão para compensar a diminuição do RSSI, o que implica em um consumo energético mais elevado.

Portanto, a diferenciação entre cenários LOS/NLOS é fundamental para implementar estratégias inteligentes de alocação de SF que não só otimizem o uso dos recursos energéticos dos dispositivos, mas também ajustem a taxa de entrega de pacotes de modo a tornar a rede operável. A fim de encontrar os parâmetros para caracterizar os canais, é necessária um processamento prévio dos dados da campanha de medição.

4.2 Caracterização do canal

Para caracterização do canais LOS e NLOS, optou-se pela utilização do modelo de propagação log-distância devido à sua capacidade de capturar o comportamento da atenuação do sinal em função da distância, além de estar em conformidade com as simulações apresentadas na Seção 2.6. Nesse sentido, o modelo apresenta uma formulação [58] que incorpora parâmetros como o expoente de atenuação n_a , que sintetiza os efeitos combinados de reflexão, difração e espalhamento, além de perda de referência P_0 e distância de referência d_0 , conforme Equação 2.3. Outrossim, o modelo log-distância

possui maior simplicidade matemática se comparado a modelos de propagação mais robustos que, aliada à facilidade de ajuste com dados reais, tem justificada a sua aplicação em análises de larga escala e simulações de redes sem fio.

4.2.1 Perda de Percurso Medida

A fim de encontrar os parâmetros para a Equação 2.3, é necessária uma série de ajustes dos dados coletados. O primeiro ajuste consiste na inserção do diagrama de radiação da antena do GW, já que foi utilizada na campanha de medição uma antena omnidirecional do tipo colinear, caracterizada por um padrão de radiação aproximadamente isotrópico no plano azimutal (horizontal), mas com variação direcional no plano de elevação (vertical) [68].

Como o ganho da antena não é uniforme em todos os ângulos de incidência verticais, foi necessário aplicar um fator de correção baseado em seu diagrama de radiação para ajustar as medições de potência recebida. Essa etapa permitiu ajustes entre pontos com maior ganho e menor ganho da antena que foram coletados ao longo da campanha de medição, eliminando a diferença de ganho relativa entre eles, conforme diagrama de radiação no plano vertical apresentado pela Figura 14. Mais detalhes do diagrama se encontram em [67].

A Figura 14 expõe, ainda, como a antena irradia ou recebe energia de acordo com o ângulo de elevação θ , de modo que o ganho é menor quando $\theta = 90^\circ$ e maior para $\theta = -5^\circ$. Ângulos de elevação menores que $\theta = 0^\circ$ indicam que os pontos coletados estão abaixo do nível da antena, enquanto os ângulos maiores que $\theta = 0^\circ$ indicam coleta acima do topo da antena.

É obtida então a perda de percurso medida PL_{medida} para cada ED subtraindo a potência de transmissão do ED P_{tx} do valor de potência recebida P_{rx} , isto é, do RSSI medido na campanha de medição, acrescido do ganho da antena de recepção G_{rx} de acordo com o ângulo de elevação, isto é subtraindo a perda em função do diagrama de radiação $L_{rx}(\theta)$, e o ganho da antena de transmissão G_{tx} . Conforme explicitado no Capítulo 3, temos que $G_{rx} = 9$ dBi, $G_{tx} = 5$ dBi e $P_{tx} = 14$ dBm. Assim, a perda de percurso medida é dada por

$$PL_{\text{medida}} = P_{tx} - P_{rx} + G_{tx} - L_{rx}(\theta). \quad (4.1)$$

A Figura 14 apresenta o diagrama de radiação no plano vertical para a antena utilizada no GW.

4.2.2 Remoção de *Outliers*

Após análise do ganho, busca-se reduzir os *outliers*. Em um primeiro momento, foram eliminadas amostras LOS que estavam a menos de 5 metros em relação as amostras NLOS, isto é, amostras próximas à decisão de visada. Essa remoção foi realizada com o

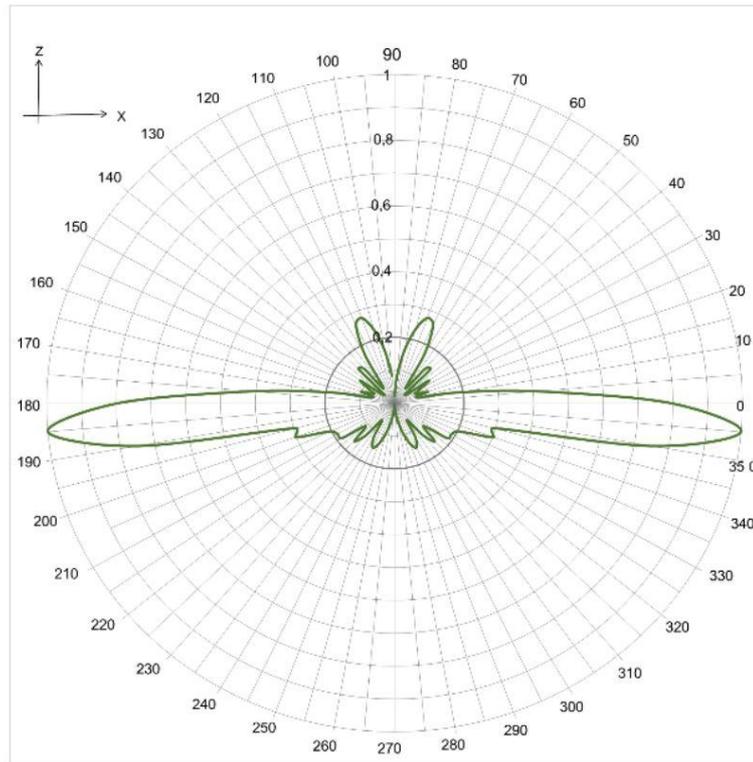


Figura 14 – Diagrama de Radiação no plano de Elevação da antena utilizada. Elaborado pelo autor.

intuito de minimizar possíveis impactos de efeitos de multi-percurso que podem gerar desvanecimento, diminuindo o RSSI de amostras LOS. Removendo essas amostras, garante-se uma independência entre amostras, o que facilita a modelagem do canal.

Após isso, separa-se os dados em dois *datasets* diferentes, um para LOS e o outro para NLOS. Com isso, são implementados filtros de média móvel para suavização dos ruídos [69] personalizado para cada caso, sendo testada uma série de combinações de ordens diferentes de filtro para cada canal.

O filtro de média móvel com janela deslizante é um filtro *Finite Impulse Response* (FIR) amplamente utilizado em processamento de sinais para suavizar sinais ruidosos [69].

Para atingir este resultado, o filtro recebe o sinal de entrada e aplica uma média ponderada dos valores presentes em uma janela definida. Ao aplicá-la, o filtro é capaz de reduzir variações bruscas, como ruídos presentes no sinal, resultando em um sinal suavizado. Desta forma, o filtro consegue diminuir a influência de valores atípicos ou extremos no sinal de entrada. A ordem do filtro é determinada pelo tamanho da janela utilizada e, à medida que a janela aumenta, o sinal se torna mais suavizado. Porém, filtros com ordem excessivamente grandes tendem a perder detalhes da informação original. Portanto, é de suma importância aplicar um filtro médio móvel com uma ordem que seja capaz de eliminar as variações bruscas, conservando a informação original [69].

Na implementação padrão, a primeira janela é utilizada para calcular a média inicial. Porém, em algumas aplicações, pode ser desejável descartar a primeira janela se ela possuir dados não representativos. Nesse caso, o cálculo da média começa apenas a partir da segunda janela em diante. Em vez de recalculer toda a soma para cada nova amostra, ele utiliza a soma anterior e ajusta apenas os valores que entram e saem da janela. A saída $y[n]$ no instante n do filtro de média móvel com janela deslizante de tamanho T_j é dada por

$$y[n] = \frac{1}{T_j} \sum_{k=0}^{T_j-1} x[n-k], \quad (4.2)$$

em que $x[n]$ é a entrada do sinal no instante n enquanto T_j é o tamanho da janela deslizante.

As combinações que apresentam os melhores resultados são as seguinte:

- LOS - É aplicado um filtro média móvel de janela deslizante de ordem 10 e que desconsidera a primeira janela, com o objetivo de suavizar o RSSI.
- NLOS - É aplicado um filtro média móvel de janela deslizante de ordem 32 que desconsidera a primeira janela, com o objetivo de suavizar o RSSI.

A partir do conjunto dados ajustados, é possível modelar os canais LOS e NLOS.

4.2.3 Modelagem dos Canais LOS e NLOS

A modelagem da perda de percurso apresentada pela Equação 2.3 pode ser linearizada para facilitar a compressão de dados. A principal transformação aplicada é a conversão da distância d para escala logarítmica de base 10, tornando a Equação 2.3 uma relação linear entre a perda de percurso $PL(d)$ e $\log_{10}(d)$, isto é,

$$PL(d) = A \log_{10}(d) + B \quad (4.3)$$

em que o coeficiente angular A é dado por $10n_a$ e o coeficiente linear B pode ser calculado por $P_0 - 10n_a \log_{10}(d_0)$. Com isso, os dados são ajustados por meio de uma regressão linear, que busca encontrar os valores para A e B .

Por fim, pode-se definir d_0 como a menor distância na qual os dados foram coletados, pois isso evita problemas de campo próximo ou transições abruptas de propagação [70].

Como os dados são divididos em dois cenários, são observados dois d_0 diferentes. A campanha se iniciou em pontos de NLOS e, com efeito dos obstáculos, obtém-se que $d_0 = 27,53$ m. Para o cenário para LOS, a campanha mostra medidas um pouco mais distantes em relação a antena, sendo observado $d_0 = 40,91$ m.

A partir dos valores de d_0 para cada ambiente, os parâmetros n_a , P_0 são obtidos com base nos coeficientes das retas, conforme apresentado na Tabela 13, que também

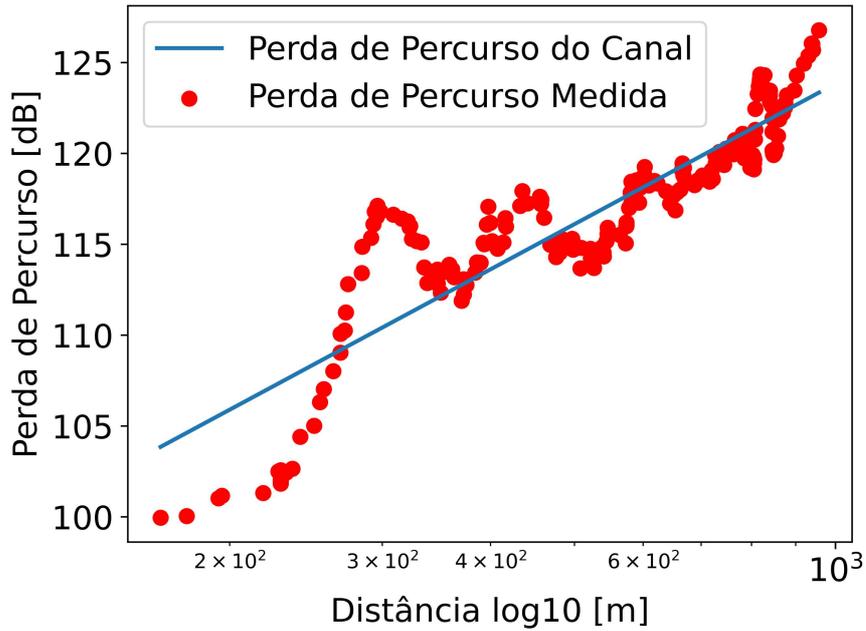


Figura 15 – Gráfico Perda de percurso (dB) em função de $\log_{10}(d)$ (m) para LOS. Elaborado pelo autor.

Tabela 13 – Parâmetros para propagação dos canais LOS e NLOS.

	n_a	$PL(d_0)$	d_0	RMSE
LOS	2.57	79 dB	40.91 m	2.42 dB
NLOS	3.02	80 dB	27.53 m	3.78 dB

mostra os valores de erro quadrático médio (*Root Mean Squared Error* (RMSE)) para cada modelo. Esses valores são integrados ao ns-3, permitindo a realização de simulações com canais realísticos. As Figuras 15 e 16 apresentam a reta que representa a perda de percurso do canal, em azul, e os valores de perda de percurso medidos, em vermelho, dos canais LOS e NLOS, respectivamente. Observa-se um ajuste apropriado dos modelos aos valores medidos, obtendo a atenuação esperada de acordo com o aumento da distância em relação à antena.

Tendo em vista os canais obtidos e implementados no ns-3, uma campanha de simulações é executada para verificar os efeitos do canal.

4.3 Simulação

Esta seção apresenta as simulações realizadas a fim de obter os melhores vetores \vec{a} para as situações de interesse. São avaliados cenários em que a rede possui uma proporção de EDs utilizando canal LOS e outra utilizando canal NLOS. A proporção de EDs utilizando o canal NLOS é denotada por δ , enquanto $1 - \delta$ indica a proporção de EDs com linha de visada. Assim, $\delta = 1.0$ representa o cenário que 100% dos EDs transmitem em um canal NLOS, enquanto $\delta = 0,0$ indica que todos os EDs estão em situação de linha

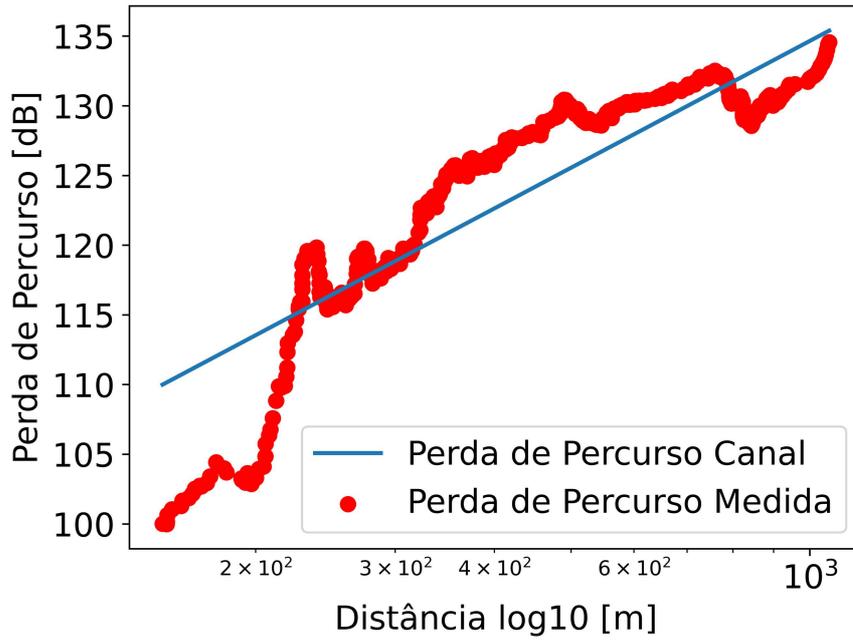


Figura 16 – Gráfico Perda de percurso (dB) em função de $\log_{10}(d)$ (m) para NLOS. Elaborado pelo autor.

de visada com o GW.

Para a campanha de simulações, são propostos 6 vetores \vec{a} , de forma que os três primeiros são escolhas apropriadas para cenários puramente LOS, enquanto os três últimos são adequados para cenários puramente NLOS. Todas as estratégias de alocação de SF usadas são não baseadas em sensibilidade, por desempenharem melhor que os algoritmos de sensibilidade, e se embasam na premissa do algoritmo *Equal Split* apresentado na Seção 2.6: os EDs na rede são classificados por potência recebida em ordem decrescente e, em seguida, divididos de forma arbitrária da seguinte forma:

- (I): $\vec{a} = \{0.65, 0.1, 0.05, 0.1, 0.05, 0.05\}$
- (II): $\vec{a} = \{0.7, 0.1, 0.1, 0.05, 0.04, 0.01\}$
- (III): $\vec{a} = \{0.6, 0.2, 0.05, 0.05, 0.05, 0.05\}$
- (IV) - *Equal Split*: $\vec{a} = \{0.16, 0.16, 0.16, 0.16, 0.16, 0.16\}$
- (V): $\vec{a} = \{0.05, 0.1, 0.2, 0.2, 0.25, 0.2\}$
- (VI): $\vec{a} = \{0.05, 0.1, 0.1, 0.1, 0.25, 0.40\}$

Tais vetores \vec{a} são escolhidos a partir de extensivos testes com os respectivos canais implementados no ns-3 que sucederam da seguinte forma:

- Busca por estratégia de alocação de SF que maximizaram PDR e minimizaram a PIR, sendo a potência de transmissão fixa e igual a 14 dBm, limitante superior de potência implementado no módulo LoRaWAN utilizado;
- Encontrada alocação com resultado satisfatório, reduz-se a potência de transmissão em 3 dB (metade da potência anterior), até que alcance o limitante inferior de potência implementado pelo *datasheet* SX1272 [51] ou o valor limite para não ocorrer perda de pacotes por sensibilidade do canal verificado.

Conforme apresentado na Seção 2.6, a potência de transmissão impacta, em termos de taxa de entrega de pacotes, apenas na relação entre pacotes não recebidos por estarem abaixo da sensibilidade do receptor. Com isso, buscou-se minimizar o valor de potência de transmissão até alcançar um valor que garante pacotes acima da sensibilidade para a maioria dos raios variados nas simulações e reduzir o consumo energético. Seguindo esse critério, adota-se a potência de transmissão igual 3 dBm para EDs LOS e 9 dBm para EDs NLOS.

As simulações são configuradas para avaliar o tráfego de 1000 EDs que são posicionados aleatoriamente com distribuição uniforme com raio variável ao redor de um único GW, enviando um pacote em um tempo aleatório com periodicidade de envio de 10 minutos, conforme apresenta a Tabela 14. A fim de testar ainda mais as alocações definidas pelos vetores \vec{a} , três sorteios aleatórios são feitos ao longo da simulação com o objetivo de alterar o canal e o posicionamento dos EDs, mantendo a proporção de LOS/NLOS configurada inicialmente, totalizando quatro reposicionamentos aleatórios em cada simulação.

Tabela 14 – Parâmetros de simulação.

Parâmetro	Valor
Tamanho do pacote	23 Bytes
Raios	2,3,4,5,6,8 km
Número de EDs	1000
Tráfego	<i>Uplink</i>
Potências de transmissão	3 dBm (LOS), 9 dBm (NLOS)
Largura de banda	125 kHz
\vec{a}	I,II,III,IV,V,VI
δ	0,0; 0,25; 0,5; 0,75; 1,0
Periodicidade de envio	600 s

O objetivo dessas simulações é comparar o desempenho do ADR e de vetores \vec{a} propostos, de modo que estes possam igualar ou superar o ADR nos cenários de variação de δ e ao longo de diferentes raios de simulação. Para garantir confiabilidade às simulações, o intervalo de confiança de 95% é preservado, com cada simulação sendo realizada dez vezes.

Entretanto, as simulações com dois canais simultâneos não são simples de serem implementadas. O módulo LoRaWAN do ns-3 utilizado não foi desenvolvido para que uma rede utilize mais de um canal de propagação, portanto uma exaustiva investigação foi realizada para desenvolver uma ferramenta capaz de simular dois canais simultâneos. Alternativas mais sofisticadas consistiriam na adaptação dos arquivos já existentes no módulo LoRaWAN utilizado, porém tais alternativas demandariam uma série de alterações, o que poderia levar a erros, caso algum arquivo do ns-3 fosse mal configurado ou não fosse atualizado por desconhecimento. Diante disso, optou-se por modificar o menor número de arquivos externos, condensando as mudanças necessárias ao arquivo ‘main.cc’ da simulação.

Portanto, uma das contribuições desta dissertação é o desenvolvimento de um recurso para simular redes LoRaWAN com dispositivos fazendo uso de mais de um canal simultaneamente para o módulo LoRaWAN adotado. Foi necessário realizar mudanças no código referente ao canal e à camada MAC. Mais detalhes se encontram no Apêndice 7.2. A partir destas mudanças nos códigos, as campanhas de simulação apresentam os resultados a seguir.

4.3.1 Resultados

Os resultados obtidos simbolizam a média das 10 simulações realizadas para garantir o intervalo de confiança desejado. Para validação dos \vec{a} propostos, a métrica PDR de 2 cenários é verificada: $\delta = 1, 0$ e $\delta = 0, 0$. A comparação é feita a fim de expor situações em que o mecanismo ADR não é a melhor escolha para a rede, para os raios de disposição dos EDs de 2, 3, 4, 5 e 8 km.

4.3.2 Cenário 1: $\delta = 1, 0$

Neste cenário, tem-se que todos os EDs da rede utilizam o canal NLOS. A Figura 17 apresenta a PDR em relação à distância de disposição dos EDs para os 6 vetores \vec{a} propostos em comparação com o ADR. É possível observar a redução de pacotes recebidos com o aumento do raio, conforme esperado. O ADR, em vermelho, se mostrou a melhor opção apenas para o cenário em que os dispositivos estão posicionados ao longo de um raio de 2 km. Como estão a uma distância baixa do GW, os EDs fazem uso do SF7, imposto pelo ADR, já que a sensibilidade do GW é suficiente para receber os pacotes enviados com tal SF.

A partir de 3 km, o ADR atribui escolhas que não são as de melhor desempenho e o principal motivo é o fato de atribuir muitos EDs com o mesmo SF, o que aumenta a ocorrência de pacotes interferidos, como mostrado no Capítulo 2. Em geral, o vetor (V) apresentou o melhor resultado ao longo dos raios, reforçando que a estratégia de distribuir EDs de forma mais próxima da igualitária pode contribuir para aumento de cobertura.

Por fim, conforme esperado, (I), (II) e (III) apresentaram os piores resultados, em

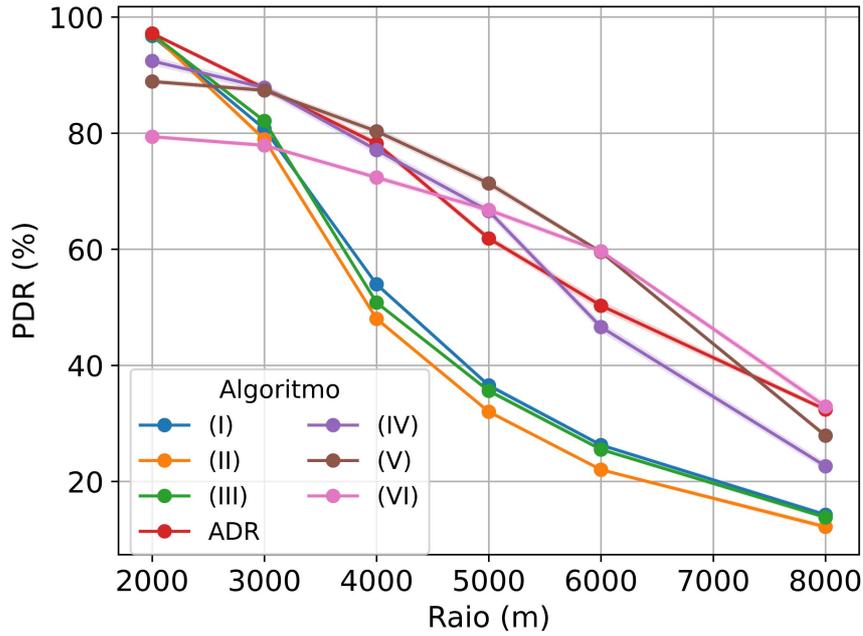


Figura 17 – PDR em função do raio para EDs com canais 100% NLOS. Elaborado pelo autor.

média, para o cenário 100% NLOS por focarem em utilizar SFs mais baixos. Desta forma, tais algoritmos proporcionaram menor SNR para um canal de maior atenuação como o NLOS e, na prática, apresentam PDR muito abaixo do limite operável, exceto para os cenários de 2 km e 3 km, nos quais os dispositivos estão mais próximos do GW.

4.3.3 Cenário 2: $\delta = 0,0$

Neste cenário, tem-se que todos os dispositivos da rede utilizam o canal LOS. A Figura 18 apresenta a PDR em relação ao raio de disposição dos EDs em torno do GW, comparando o desempenho dos 6 vetores \vec{a} propostos com o ADR. De imediato, chama atenção o desempenho baixo do ADR em relação aos outros para distâncias maiores ou iguais a 4 km, sendo crítico a partir de 5 km, raio o qual passou a ter o pior desempenho entre todos comparados, inclusive abaixo de vetores \vec{a} que focam no cenário NLOS, como (IV), (V) e (VI).

O motivo pelo qual o ADR desempenha abaixo do esperado no cenário puramente LOS é o mesmo do cenário puramente NLOS: as interferências causadas pelo uso do mesmo SF. Mais uma vez, o ADR optou por impor que os EDs usassem o SF mínimo para garantir a sensibilidade, porém este fator acabou aumentando a interferência da rede pelo AT, resultando em queda de desempenho.

Por fim, as propostas (I), (II) e (III) obtiveram o melhor desempenho para os raios entre 2 e 4 km, sendo observado queda na PDR a partir de raio igual a 5 km, embora neste ponto ainda possuam um índice de entrega de pacotes alto, próximo a 90%. Enquanto isso, as propostas (IV), (V) e (VI) desempenharam melhor para raios maiores,

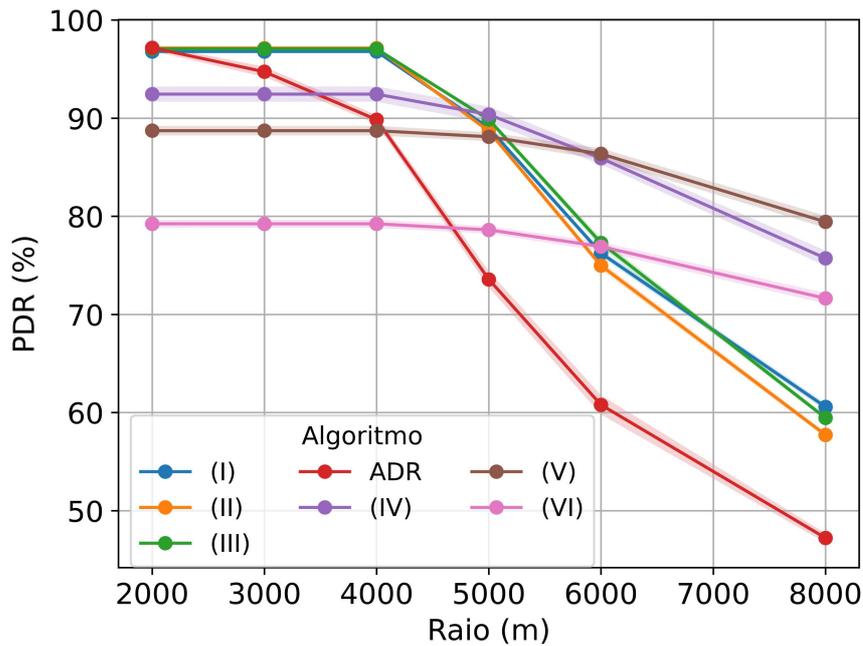


Figura 18 – PDR em função do raio para EDs com canais 100% NLOS. Elaborado pelo autor.

com destaque para (IV) e (V) que, embora não tenham apresentado as maiores PDRs para raios menores que 5 km, ainda tiveram desempenho em um patamar alto, próximo aos 90%. As propostas (IV) e (V) manifestaram a menor variância de desempenho ao longo da simulação.

4.4 Conclusões

Este capítulo apresentou alocações de SF e potência baseadas em dois canais obtidos a partir da campanha de medição: LOS e NLOS. Para encontrá-las, primeiro foi necessária uma análise dos dados a fim de determinar os parâmetros de propagação de cada canal. O modelo de propagação escolhido foi o log-distância por ser um modelo mais simples, sem aleatoriedade que outros mais complexos possuem e por estar em conformidade com as simulações apresentadas no Capítulo 2.

Em seguida, de modo a alcançar o melhor ajuste de dados, aplicou-se adequação de dados por meio da remoção do ganho relativo da antena para todos os pontos coletados e dois critérios estabelecidos para remoção de *outliers*.

Por fim, incorporou-se os modelos de canal no ns-3 e, após implementações de códigos adaptando o módulos, as simulações foram realizadas. Foram comparadas as propostas de alocação de SF com o ADR e resultados evidenciaram a importância de alocação adequada de SF para canais diferentes. Além disso, foi observado que o ADR, na maioria das vezes, optou por estratégias mal sucedidas para entregas de pacote, tendo o desempenho abaixo do que os vetores \vec{a} propostos nesse trabalho. Essa análise reforçou a hipótese de que

propostas de \vec{a} não baseadas em sensibilidade podem alcançar resultados com ganho considerável de desempenho na comparação com o ADR.

Entretanto, não é simples encontrar propostas de vetores \vec{a} que desempenham melhor em todos os raios para os dois canais. Em geral, cada proposta sugerida tem melhor desempenho em um determinado raio e para um dos dois canais, portanto não há uma escolha que pode ser feita para um cenário dinâmico. Uma possível opção é a utilização de aprendizado por reforço para a escolha do melhor \vec{a} possível para a distância e canal avaliado, a qual será abordada no próximo capítulo.

5 Alocação Inteligente de SF Baseada em Aprendizado por Reforço

Conforme elucidado no Capítulo 4, não há um vetor \vec{a} que seja ótimo para quaisquer distância e situação de linha de visada. Com isso, um vasto número de vetores \vec{a} pode ser explorado, podendo ter combinações específicas que desempenham melhor para situações particulares. Embora a estratégia de vetores seja simples, são estáticas, não sendo capazes de se adaptar às possíveis mudanças de um ambiente dinâmico.

Diante disso, torna-se necessário explorar abordagens que permitam uma adaptação contínua e inteligente dos SFs. Essa necessidade abre espaço para métodos que, ao invés de serem estáticos e apenas seguirem regras pré-definidas, aprendam com o ambiente e ajustem suas decisões em tempo real, visando um objetivo de reduzir tanto o consumo energético quanto melhorar a qualidade do enlace.

É nesse contexto que se insere a proposta de alocação inteligente de SF baseada em aprendizado por reforço, apresentada neste capítulo. A utilização do aprendizado por reforço possibilita a incorporação de um mecanismo de decisão que se aperfeiçoa com a experiência acumulada, se adaptando continuamente às condições de rede. Essa capacidade de adaptação é importante para enfrentar os desafios impostos pelas redes LoRaWAN em ambientes reais, em que a imprevisibilidade das condições de rede demanda soluções mais flexíveis e robustas [71].

5.1 Aprendizado por Reforço

Aprendizado por Reforço (*Reinforcement Learning* (RL)) consiste em aprender o que fazer, isto é, como mapear situações para ações com o objetivo de maximizar um alvo de recompensa. O agente de aprendizado não recebe instruções explícitas sobre quais ações deve tomar, mas, em vez disso, precisa descobrir quais ações resultam na maior recompensa por meio da experimentação. Nos casos mais desafiadores, as ações podem influenciar não apenas a recompensa imediata, mas também recompensas futuras [72]. Essas duas características, busca por tentativa e erro e recompensa, são as principais propriedades do aprendizado por reforço.

A ideia central de RL consiste em capturar os aspectos mais relevantes do problema real enfrentado por um agente de aprendizado que interage continuamente com seu ambiente para alcançar um objetivo. O agente deve ser capaz de identificar o estado do ambiente e tomar ações que o modifiquem. Além disso, o agente precisa ter um ou mais objetivos relacionados ao estado do ambiente, de forma a obter uma recompensa de acordo com um critério estabelecido. A recompensa é configurada previamente e

geralmente escolhida uma métrica pertencente ao intervalo entre 0 e 1 [73]

Diferentemente do aprendizado supervisionado, como a classificação apresentada no Capítulo 3, no qual o foco do algoritmo é aprender o padrão do conjunto de dados a partir de um conjunto de treinamento composto por exemplos rotulados fornecidos por um supervisor, o aprendizado por reforço possui um agente independente que deve ser capaz de aprender com sua própria experiência, maximizando a recompensa sem a identificação de rótulo ou ações a serem tomadas por um supervisor ou identificar padrões ocultos [73].

Portanto, em RL, o aprendizado ocorre por meio de um número de interações em certos contextos e, dependendo da situação e da ação desempenhada, é obtido recompensas maiores ou menores. As recompensas recebidas em cada situação mostram como se comportar melhor no futuro, a fim de receber mais recompensas. Em outras palavras, dado que foi encontrada a recompensa máxima, algoritmos de RL mantém a escolha que gerou essa recompensa, convergindo o aprendizado para uma escolha única ao longo do tempo [72].

Assim como na classificação, são muitos os algoritmos de aprendizado por reforço presentes na literatura, como *Deep Q-Networks* (DQN), *Policy Gradient Methods* (PGM), MAB, entre outros. Este trabalho, focará no algoritmo MAB devido à sua simplicidade e capacidade para solucionar problemas de tomada de decisão em ambientes dinâmicos. Mais detalhes dos outros algoritmos podem ser encontrados em [72].

5.1.1 *Multi-Armed Bandits*

Multi-Armed Bandits é um dos algoritmos de menor complexidade de RL [73]. Ele consiste em considerar C máquinas caça-níqueis, também conhecidas como “bandidos de um só braço”, cada uma equipada com uma alavanca que, quando puxada, fornece uma recompensa. As C máquinas possuem probabilidades de sucesso diferentes e desconhecidas e a tarefa do agente é determinar uma estratégia, ou política, que maximize a recompensa após T rodadas de jogo.

O agente interage com o ambiente na tomada de decisão de escolher uma alavanca, porém o ambiente permanece inalterado e não influencia a escolha do agente, sendo que a única interação ocorre entre o agente e a recompensa, a qual influencia a estratégia e a escolha da próxima ação a ser tomada. Com isso, o agente se vê preso no dilema exploração-exploração (*exploration-exploitation*), o qual representa a dúvida se mantém na mesma escolha ou se realiza uma troca.

5.1.2 Dilema Exploração-Exploração

O dilema exploração-exploração é um elemento fundamental em muitos problemas de RL, não só do algoritmo MAB. Após um tempo t_i , o agente enfrenta a seguinte decisão: verificar as informações já adquiridas e escolher a máquina caça-níquel que proporcionou a maior recompensa até o momento, período chamado de exploração, ou selecionar outra

máquina para obter mais informações e avaliar se é possível obter uma recompensa superior àquelas encontradas até o instante t_i , período chamado de exploração [73].

O problema a ser resolvido é que a distribuição de probabilidade da recompensa de cada braço não é conhecida, caso contrário se escolheria sempre o que tem a probabilidade maior de retornar a recompensa, não sendo necessário um algoritmo denso para tomada de decisão. Por isso, a necessidade de explorar as opções e explorar as melhores obtidas. Outro ponto relevante é que a distribuição de probabilidade da recompensa pode ser variante no tempo, e por definição, cada braço possui sua distribuição específica [73].

Portanto, o algoritmo MAB deve aplicar uma estratégia de modo a se adaptar e levar em consideração a exploração e a exploração na escolha dos braços, uma vez que o equilíbrio entre essas duas fases é o que resultará na melhor recompensa média. Cada estratégia define a forma com a qual o agente escolhe uma decisão [72].

Uma estratégia gananciosa (*greedy*) consiste em escolher sempre a máquina que, até aquele instante, forneceu a maior recompensa. Variações dessa abordagem que incorporam um componente exploratório incluem os algoritmos ε -ganancioso (ε -*greedy*) e ε -*primeiro* (ε -*first*) [73]. Além disso, o agente pode optar por explorar as máquinas caça-níqueis sobre as quais ainda não possui informações suficientes, com algoritmos *Upper Confidence Bound* (UCB). Esse trabalho focará na estratégia ε -*greedy* e detalhes sobre outras estratégias podem ser encontrados em [73].

5.1.3 Estratégia ε -*greedy*

Para mitigar o problema da falta de informação na estratégia gananciosa, é útil introduzir uma fase de exploração como na estratégia ε -*greedy*. Considerando $0 < \varepsilon < 1$, a estratégia seleciona aleatoriamente uma máquina caça-níquel para jogar e segue a estratégia gananciosa na proporção $1 - \varepsilon$. Dessa forma, ocasionalmente, o agente explora o ambiente aumentando assim a probabilidade de que a escolha gananciosa seja ótima. Após cada iteração M , um valor γ é dividido de ε , assim, para $M \rightarrow \infty$, tem-se a estratégia gananciosa, a qual escolhe sempre a ação de maior recompensa [73].

5.1.4 Aplicação no cenário LOS/NLOS

A partir dos conceitos apresentados, determina-se os parâmetros de RL para o contexto desse trabalho. O número de braços, denotados por A , indicando as possíveis ações de escolha do algoritmo, representa os possíveis vetores \vec{a} a serem escolhidos pelo agente para transmissão dos pacotes, logo o MAB possui 6 opções diferentes para escolher durante a simulação.

Devido ao cenário dinâmico, com mudança no posicionamento de forma aleatória e sorteio aleatório dos dispositivos os quais estão ou não em condição de linha de visada, a estratégia ε -*greedy* foi adotada com $\varepsilon = 0,94$ para iniciar o aprendizado explorando o maior número de ações, e $\gamma = 1,01$, ou seja, ε é reduzido em 1% a cada iteração,

forçando o aprendizado explorar ações por um tempo até que opte pelas ações de maior recompensa.

Para escolha das recompensas, é necessário definir métricas de desempenho que traduzam a melhor tomada de decisão do MAB.

5.2 Métricas de Desempenho

A avaliação do desempenho das estratégias de alocação de SF e de potência pode ser realizada utilizando diversas métricas e, tradicionalmente, a PDR tem sido empregada como principal indicador [74]. Porém, embora seja intuitiva e amplamente utilizada, a PDR não captura as consequências relacionadas ao consumo energético. Em cenários nos quais a eficiência energética é relevante, como nas redes **LoRAWAN!** (**LoRAWAN!**), a análise exclusiva da PDR pode levar a escolhas subótimas, pois situações que maximizam a taxa de entrega podem apresentar um consumo energético elevado, inviabilizando a aplicação.

Além disso, a PDR é uma métrica simples e pode apresentar valores muito próximos a depender do vetor \vec{a} escolhido. Diante disso, utilizar apenas essa métrica pode impedir a visualização clara de tomada de decisão para o MAB. Portanto, a PDR deve ser combinada junto à outra métrica para melhor ajuste de treinamento do MAB.

5.2.1 Consumo Normalizado

Conforme apresentado na Seção 2.6, o consumo de redes LoRaWAN é muito baixo, na escala de 10^{-4} mAh para o cenário de maior eficiência, e com baixa variação a depender dos parâmetros alterados, o que dificulta a compreensão dessa variação em um primeiro momento. Com o propósito de utilizar métricas relacionadas à eficiência energética, o consumo normalizado surge como alternativa interessante. Para tal, utiliza-se uma forma de normalização chamada Mínimo-Máximo, a qual comprime os dados para uma escala entre 0 e 1.

Sabendo da Seção 2.6 que o maior e menor consumo energético de uma rede LoRAWAN se dá ao utilizar o SF12 e SF7, respectivamente, este trabalho propõe a normalização dada por

$$j_{norm} = \frac{(j_{atual} - j_{SF7})}{(j_{SF12} - j_{SF7})}, \quad (5.1)$$

em que j_{norm} representa o consumo normalizado, j_{atual} indica o consumo no SF atual do ED, j_{SF7} é o consumo no SF7 e j_{SF12} é o consumo no SF12. Caso o consumo atual seja igual ao do SF7, esse consumo normalizado se torna nulo, indicando consumo mínimo, enquanto, caso seja igual ao do SF12, se torna 1, indicando consumo máximo do ED.

Entretanto, a visualização do consumo sem relacionar com a PDR ainda não permite a melhor compreensão do desempenho, uma vez que limita a visão de desempenho apenas

ao consumo energético, sendo necessário portanto, a utilização de uma métrica capaz de relacionar PDR e consumo energético normalizado.

5.2.2 QoSE

Para superar essa limitação, este trabalho propõe a utilização da métrica *Quality of Service Energy* (QoSE), que relaciona, de forma ponderada, a PDR e o consumo energético normalizado. Essa métrica é definida por uma combinação linear dos dois fatores, em que um coeficiente α atribui o peso à PDR e $(1-\alpha)$ pondera o consumo energético normalizado. Dessa forma, o QoSE possibilita uma avaliação global do sistema, equilibrando aspectos de desempenho e eficiência energética de acordo com o interesse da aplicação, conforme

$$QoSE = \alpha \times PDR + (1 - \alpha) \times (1 - j_{norm}) \quad (5.2)$$

Para a Equação 5.2 adota-se $\alpha \in [0.0, 1.0]$ para limitar a QoSE a um intervalo entre 0 e 1, o qual 1 implica em um serviço ótimo e 0 em um serviço deficitário. Além disso, o termo $1 - j_{norm}$ foi inserido para que seja penalizado consumos elevados, de forma que o maior consumo possível não contribua para o valor de QoSE, assim como o menor consumo gere um ganho para a métrica.

Portanto, a escolha do parâmetro α no QoSE determina o foco da análise: para $\alpha = 0$, a métrica resulta em apenas uma análise do consumo energético, desconsiderando a taxa de entrega de pacotes. Já com $\alpha = 1$, o foco está totalmente na PDR, sem levar em conta o custo energético. Com isso, os casos intermediários permitem a combinação dos fatores, com $\alpha \in [0; 0,5)$ trazendo mais relevância a eficiência energética; $\alpha = 0.5$ estabelecendo um equilíbrio entre entrega e consumo; e $\alpha \in (0,5; 1,0]$, priorizando a entrega dos pacotes. Dessa forma, o ajuste de α permite a personalização da métrica de acordo com as demandas específicas de cada aplicação.

Após vários testes com valores diferentes de α , observa-se que o valor $\alpha = 0,75$ é o que melhor se ajusta a análise de desempenho para o cenário deste trabalho, já que traduz uma relação em que a PDR possui maior peso, mas sem deixar com que o consumo energético seja irrelevante na análise. Dessa forma, é possível garantir um ponto de operação da rede, isto é uma PDR mínima, sem deixar de levar em conta o consumo energético.

Em outras palavras, para situações em que a PDR de dois \vec{a} diferentes é muito próxima, o consumo energético determina qual dos dois vetores entrega um serviço eficiente. Em contrapartida, o peso de 75% para α impede que vetores \vec{a} com PDR e consumo muito baixo sejam avaliados como escolhas eficientes, já que o consumo energético não é o principal critério para avaliação de desempenho.

Diante das características apresentadas, QoSE é utilizado como recompensa para o MAB realizar as tomadas de decisão para cada \vec{a} nos cenários simulados.

5.3 Recompensa

O objetivo do MAB é selecionar ações A ao longo do tempo de forma a maximizar a recompensa acumulada $Q(A)$. Nesse trabalho, as ações A equivalem a vetores \vec{a} de proporção de alocação de SF. Para equilibrar exploração e exploração na busca pela melhor configuração de rede, a estratégia ε -gananciosa utilizada neste trabalho implementa um mecanismo de tomada de decisão gradual, permitindo que o sistema explore diferentes ações \vec{a} e ajuste suas recompensas acumuladas ao longo do tempo. A seguir, tem-se a atualização de recompensa implementada:

1. **Inicialização:** Para a primeira execução do MAB, inicializa-se:

- $Q(\vec{a}) = 0$, representando a recompensa inicial do QoSE do vetor \vec{a} .
- $N(\vec{a}) = 0$, registrando o número de vezes que \vec{a} foi selecionado.

A ação \vec{a} é escolhida através de um sorteio aleatório e o QoSE é calculado.

2. **Registro e Atualização do QoSE:**

- A ação escolhida \vec{a} e seu respectivo QoSE são armazenados para análise posterior.
- O contador $N(\vec{a})$ é atualizado:

$$N(\vec{a}) = N(\vec{a}) + 1$$

- A estimativa $Q(\vec{a})$ é ajustada de acordo com a média incremental:

$$Q(\vec{a}) = Q(\vec{a}) + \frac{QoSE - Q(\vec{a})}{N(\vec{a})} \quad (5.3)$$

3. **Escolha da Próxima Ação:**

- Um valor aleatório e é gerado no intervalo $[0, 1]$.
- Se $e < \varepsilon$, uma ação aleatória é escolhida (exploração).
- Caso contrário, escolhe-se a ação com maior $Q(\vec{a})$ (exploração).
- Após cada iteração, ε é reduzido em 1%:

$$\varepsilon = \frac{\varepsilon}{1.01} \quad (5.4)$$

Essa estratégia permite que o agente reduza progressivamente a exploração conforme aprimora seu conhecimento sobre a melhor ação, concentrando-se nas configurações de rede que maximizam a métrica QoSE. Assim, o sistema ajusta sua operação ao longo do tempo, equilibrando eficiência energética e desempenho da comunicação. Essa estratégia é implementada nas simulações a seguir.

5.4 Simulação e Resultados

Tendo em vista a concepção do algoritmo MAB com os parâmetros escolhidos, campanhas de simulações no ns-3 são realizadas. Em um primeiro momento, busca-se repetir as condições de simulações da Seção 4.3.1, explicitadas pela Tabela 14. Entretanto, nas simulações a seguir, é realizada uma comparação entre o resultado encontrado pelo MAB e pelo ADR e por uma estratégia de alocação chamada *Random*, a qual escolhe um SF, de forma aleatória e seguindo uma distribuição uniforme, e atribui para o ED. A estratégia *Random* é utilizada como referência na comparação de soluções propostas para indicar se os objetos avaliados estão apresentando resultados melhores do que um mero sorteio uniforme.

O MAB é programado para ser executado a cada 10 minutos, mesmo tempo de cada transmissão de pacotes. A escolha dessa periodicidade tem relação com o objetivo de convergência do algoritmo: a cada 10 minutos, todos dispositivos enviaram um pacote pelo menos uma vez e ainda não enviaram o próximo pacote.

Desta forma, o MAB escolhe uma ação de forma aleatória, que pode ser um dos seis vetores \vec{a} propostos, e a rede LoRaWAN faz o envio de pacotes seguindo o vetor \vec{a} escolhido. Ao final da transmissão, o MAB captura a PDR momentânea juntamente com o consumo energético e calcula o QoSE de acordo com o α escolhido previamente. Além disso, o MAB é executado 36 vezes até o período de sorteio de posicionamento e de canal, permitindo que todas as ações disponíveis sejam escolhidas pelo menos uma vez a cada posição e disposição de canal atribuído e assegurando que o algoritmo coletou recompensas suficientes nos estados. No total, o MAB são executado 144 vezes a cada simulação e os mesmos 10 *jobs* utilizados nas simulações do Capítulo 4 para garantir intervalo de confiança de 95%.

Sendo assim, o aprendizado por reforço é realizado avaliando sempre o mesmo número de pacotes, garantindo isonomia e evitando distorções a cada iteração do MAB. Os cenários apresentaram convergência do algoritmo, sendo observada uma baixa dispersão de pontos em cada cenário.

Para validar a adaptação do MAB às mudanças de situação de linha de visada, é simulado um cenário inicial em que a proporção δ de usuários sem linha de visada é de 100% e, na metade do tempo de simulação, a proporção muda para valor nulo. Tal simulação visa verificar se o MAB seleciona o vetor \vec{a} mais apropriado para cada situação, conforme mostrado na Seção 4.3.1.

Além disso, são repetidas as simulações com as proporções LOS/NLOS $\delta = 1, 0$, $\delta = 0, 0$, como na Seção 4.3.1, desta vez com $\alpha = 0, 75$. Posteriormente, é simulado cenário $\delta = 0, 75$ por estar mais próximo da proporção de amostras NLOS encontrada no Capítulo 3. Para este cenário, é também variado o parâmetro α de QoSE entre os valores $\{0, 25; 0, 5; 0, 75; 1, 0\}$, a fim de testar a adaptação do MAB para casos diferentes de QoSE.

5.4.1 Cenário 0: Mudança de δ

Neste cenário, tem-se que todos os dispositivos da rede estão em situação NLOS para transmissão de dados na primeira metade do tempo de simulação, enquanto na segunda metade todos estão em situação LOS. Além disso, $\alpha = 1,0$ é adotado para avaliar a convergência em relação à PDR. A capacidade do MAB de se adaptar dinamicamente às mudanças nas condições de visada é essencial para garantir a escolha eficiente dos vetores \vec{a} ao longo do tempo e este cenário é o mais desafiador para o algoritmo tomar uma decisão já que acumula recompensas de uma situação por um tempo e depois o ambiente muda drasticamente.

A Figura 19 apresenta a PDR $\alpha = 0,75$, em função da distância em metros, comparando o desempenho do MAB com todos vetores \vec{a} que podem ser escolhidos e o ADR. É possível notar que o MAB acompanhou a escolha que maximiza a PDR para todos os raios.

Durante a primeira fase da simulação, o algoritmo identificou as configurações mais adequadas para um ambiente NLOS, priorizando vetores \vec{a} que maximizem a PDR. Com a mudança para um cenário totalmente LOS na segunda metade da simulação, o MAB reajustou suas escolhas, convergindo para um novo conjunto de vetores \vec{a} que melhor se adequa à nova condição. Esse comportamento é indicativo da capacidade do algoritmo de acompanhar as nuances do ambiente e reforça o potencial para adaptar à contextos mais dinâmicos.

5.4.2 Cenário 1: $\delta = 1,0$

Neste cenário, tem-se que todos os dispositivos da rede estão em situação NLOS para transmissão de dados. A Figura 20 apresenta o QoSE para $\alpha = 0,75$, em função da distância em metros, comparando o desempenho do MAB com o *Random* e o ADR. O algoritmo *Random* atribui um valor de SF de forma uniformemente aleatória para cada ED no início da simulação [24]. Prontamente, observa-se que o MAB conseguiu extrair o melhor de cada vetor \vec{a} para cada raio e desempenhou acima de ADR e *Random* para todos os raios, exceto 2 km.

Esse resultado está em linha com a simulação de PDR presente no Capítulo 4, em que várias das propostas obtiveram PDR acima de ADR. Além disso, o ADR tende escolher SFs mais altos para raios maiores, o que impacta negativamente no consumo, reduzindo, também, o QoSE. Isto posto, o QoSE do MAB atuou com aproveitamento superior ao do ADR e do *Random* ao longo da campanha, apresentando resultado mais aquém apenas à uma distância de 8 km.

A Tabela 15 apresenta os ganhos em porcentagem do MAB em relação ao ADR e ao *Random* para cada raio. Percebe-se que o MAB apresentou uma perda de desempenho em relação ao QoSE de 5,74% em relação ao ADR para o raio igual a 2 km, enquanto apresentou uma melhoria de 52,01% para o raio de 6 km, valor de impacto expressivo.

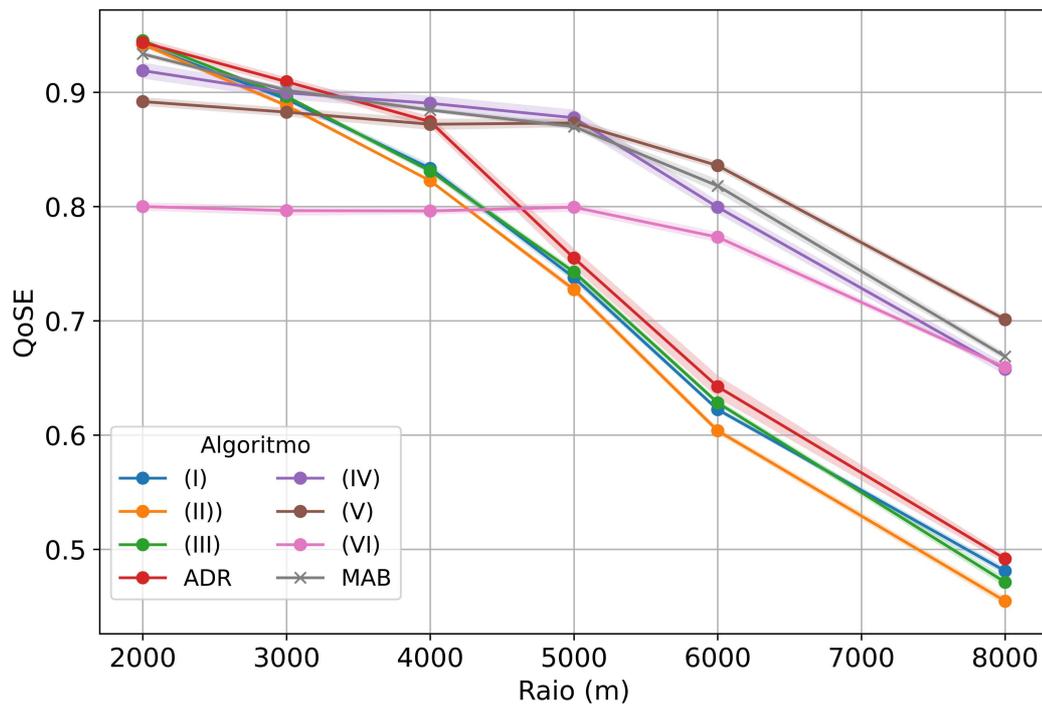


Figura 19 – Convergência do MAB para QoSE ($\alpha = 1,0$) x Raio (m) , com $\delta = 1,0$ na primeira metade e $\delta = 0,0$ na segunda metade da simulação. Elaborado pelo autor.

Em relação ao *Random*, o MAB teve desempenho melhor para todos os raios, exceto o de 8 km, o qual há uma queda de desempenho expressiva que pode comprometer o funcionamento pleno da rede.

Tabela 15 – Ganho de desempenho de MAB na comparação com ADR e *Random* para Cenário 1 e $\alpha = 0,75$.

Raio (m)	Ganho QoSE MAB/ADR (%)	Ganho QoSE MAB/ <i>Random</i> (%)
2000	-5,74	5,77
3000	0,26	7,38
4000	7,40	12,43
5000	33,71	23,43
6000	52,01	30,22
8000	32,24	-1,28

5.4.3 Cenário 2: $\delta = 0,0$

No Cenário 2, tem-se que todos os dispositivos da rede estão em situação de linha de visada. A Figura 21 apresenta o QoSE para $\alpha = 0,75$ em relação à distância em metros, comparando o desempenho do MAB com o *Random* e o ADR.

Assim como no Cenário 1, o Cenário 2 está em linha com a simulação de PDR presente no Capítulo 4, na qual todas as propostas obtiveram PDR igual ou acima de ADR e, como o ADR tende escolher SFs mais altos para raios maiores, tem o consumo

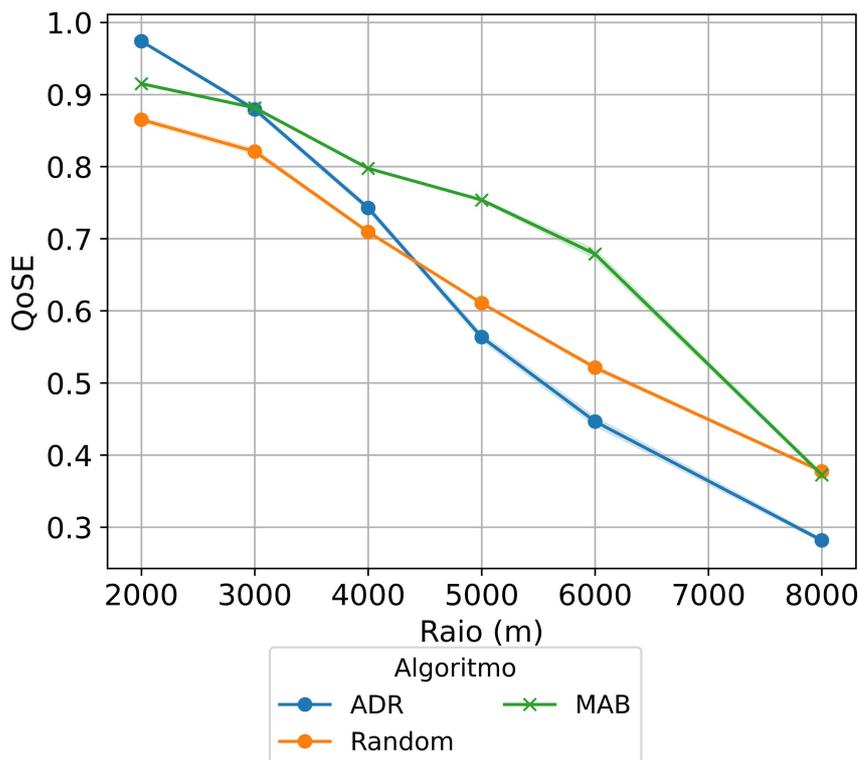


Figura 20 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 100% NLOS. Elaborado pelo autor.

maior, aumentando a diferença de QoSE do MAB para o ADR. O QoSE do MAB também apresentou bom aproveitamento ao longo da campanha, sendo maior que 80% em todos raios, exceto 8 km.

Além disso, chama atenção a comparação entre MAB e *Random*. Neste cenário, é possível identificar que o MAB possui quase o mesmo comportamento que *Random*, acrescido de um *offset*. A alocação em um ambiente com canal menos atenuante evidencia a importância de considerar a interferência entre EDs de mesmo SF. Ao escolher o SF de forma aleatória, a tendência é a distribuição uniforme dos EDs entre todos SFs. A Figura 21 mostra a mesma tendência do algoritmo MAB proposta, porém visando melhor desempenho em função do QoSE.

A Tabela 16 apresenta os ganhos em porcentagem do MAB em relação ao ADR e ao *Random* para cada raio. Nota-se, neste cenário, que o MAB não apresentou melhorias apenas para raio igual a 2 km em relação ao ADR, porém uma queda de desempenho de apenas 0,71%. Por outro lado, seus ganhos se iniciam a partir de 3 km e se estendem ao longo dos raios, alcançando uma melhoria de 125,39% em relação ao ADR para o raio de 8 km, o que representa um desempenho equivalente a mais de o dobro. Para este raio, a QoSE do ADR é muito baixa, evidenciando que o ADR é uma escolha ruim para esta situação devido ao baixo desempenho de entrega de pacotes combinado com eficiência energética. Em relação ao *Random*, o MAB também apresentou ganhos relevantes ao

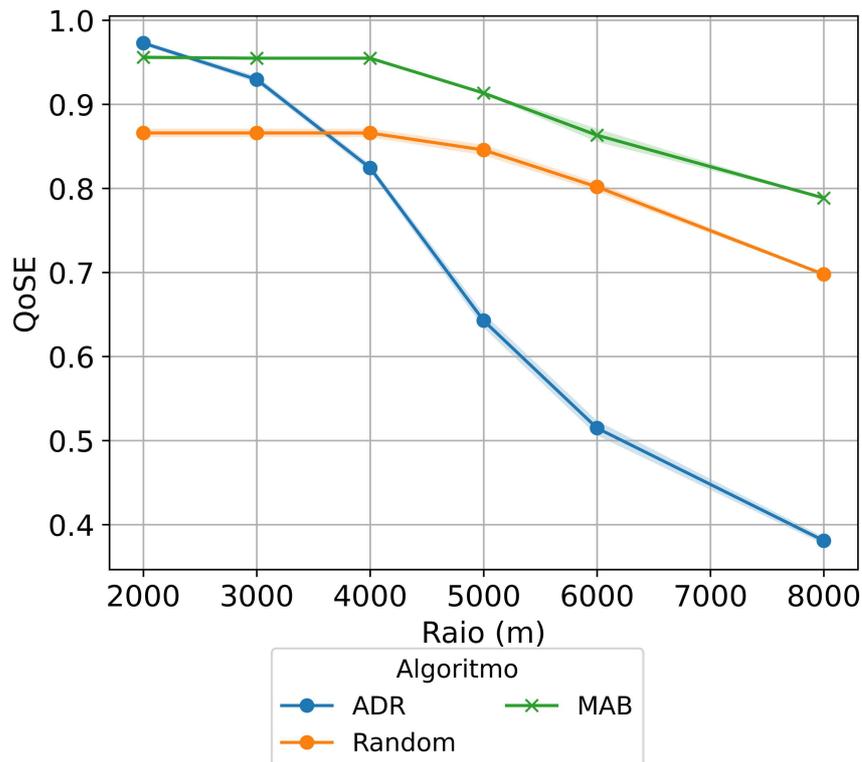


Figura 21 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 100% LOS. Elaborado pelo autor.

longo de todos os raios.

Tabela 16 – Ganho de desempenho de MAB na comparação com ADR e *Random* para Cenário 2 e $\alpha = 0,75$.

Raio (m)	Ganho QoSE MAB/ADR (%)	Ganho QoSE MAB/ <i>Random</i> (%)
2000	-0,71	11,55
3000	3,80	11,43
4000	17,05	11,43
5000	49,90	13,92
6000	81,26	16,39
8000	125,39	23,05

5.4.4 Cenário 3: $\delta = 0,75$

No Cenário 3, tem-se que 75% dos dispositivos da rede utilizam o canal NLOS, enquanto 25% utilizam o canal LOS. A Figura 22 apresenta o QoSE para $\alpha = 1.0$, o equivalente à PDR, em função da distância em metros, comparando o desempenho do MAB com o *Random* e o ADR. Nota-se um desempenho superior do MAB, mantendo a PDR acima de 80% até 5 km, exceto para o raio de 2 km, o qual há uma leve queda em relação ao ADR. Para o raio de 6 km, há uma queda de PDR e, para 8 km, a PDR cai de forma acentuada, trazendo a rede para fora de um ponto de operação apropriado. Nessa situação, nenhum algoritmo consegue um desempenho satisfatório.

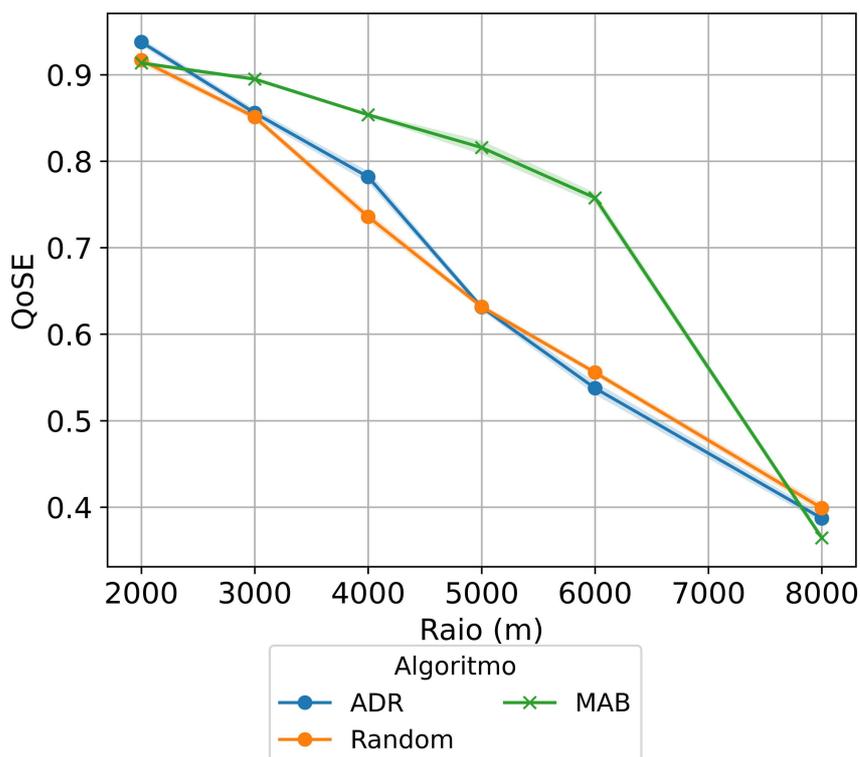


Figura 22 – QoSE ($\alpha = 1, 0$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.

A Tabela 17 expressa os ganhos em porcentagem do MAB em relação ao ADR e ao *Random* para cada raio. Assim como nos outros cenários, o MAB apresentou uma perda de desempenho para o raio de 2 km, totalizando uma redução de QoSE de 2,59% em relação ao ADR, enquanto apresentou melhorias para os raios entre 3 km e 6 km alcançando a 38,36% para o raio de 6 km, representando um aumento relevante. Para o raio de 8 km, há perda de desempenho do MAB tanto em relação ao ADR quanto em relação ao *Random*, o qual, nesta configuração, desempenha muito próximo ao ADR ao longo dos raios.

Tabela 17 – Ganho de desempenho de MAB na comparação com ADR e *Random* para Cenário 3 e $\alpha = 1, 0$.

Raio (m)	Ganho QoSE MAB/ADR (%)	Ganho QoSE MAB/ <i>Random</i> (%)
2000	-2,59	-0,35
3000	4,57	5,16
4000	9,19	16,02
5000	29,24	29,13
6000	38,36	36,34
8000	-8,20	-8,62

A Figura 23 apresenta o QoSE para $\alpha = 0, 75$ em função da distância em metros, seguindo a mesma comparação anteriormente. Este valor de α indica maior prioridade à PDR do que ao consumo energético. Esta situação é o objetivo desse trabalho e nela é

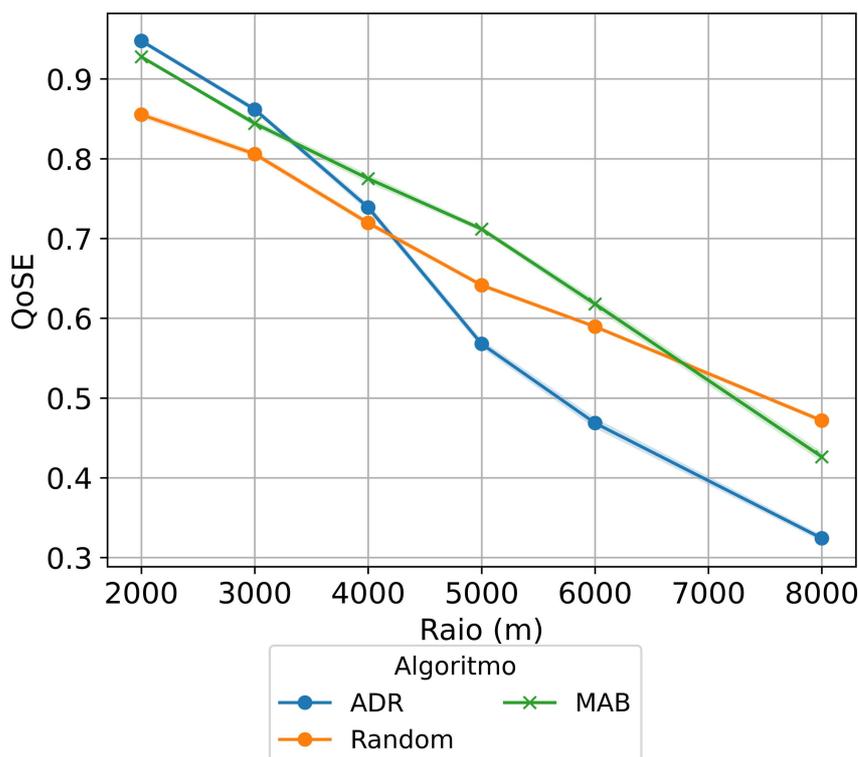


Figura 23 – QoSE ($\alpha = 0,75$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.

possível observar que o desempenho do ADR e do MAB foram muito próximos para os raios de 2 km e 3 km. A partir de 4 km, o MAB supera o ADR e segue com o melhor desempenho, até alcançar o raio de 8 km, que tem o desempenho próximo ao *Random*. Como apresentado na Figura 22, o raio de 8 km apresenta uma situação de PDR muito baixa, no qual nenhum algoritmo apresenta desempenho que possa garantir um ponto de operação da rede apropriado.

A Tabela 18 expressa os ganhos, em porcentagem, do MAB em relação ao ADR e ao *Random* para cada raio. Comparando com a Tabela 17, nota-se que o ADR consegue atribuir, em raios de 2 km e 3 km, SFs menores do que a convergência do MAB. Conforme elucidado, a PDR para $\delta = 0,75$ é muito próxima entre ADR e MAB e, na atual configuração, o MAB apresenta queda de desempenho de QoSE de 2,12 % e 2,03 % na comparação com o ADR. Como as PDRs estavam próximas e agora o QoSE apresentou redução, tem-se que $1 - \alpha$ é o responsável pela queda de QoSE nesta configuração. Por outro lado, para raios maiores do que 3 km, o MAB apresenta ganhos em relação ao ADR, atingindo até 29,11 % para o raio de 6 km. Em relação ao *Random*, o MAB expôs melhorias de desempenho, exceto para raio de 8 km.

Para o próximo caso, tem-se a Figura 24, a qual apresenta o QoSE para $\alpha = 0,50$ em função da distância em metros, ainda sob mesma ótica de comparação. Este valor de α indica uma média aritmética entre PDR e consumo energético, ou seja, ambos

Tabela 18 – Ganho de desempenho de MAB na comparação com ADR e *Random* para Cenário 3 e $\alpha = 0,75$.

Raio (m)	Ganho QoSE MAB/ADR(%)	Ganho QoSE MAB/ <i>Random</i> (%)
2000	-2,12	8,47
3000	-2,03	4,75
4000	4,89	7,72
5000	25,34	10,97
6000	29,11	4,83
8000	27,56	-9,62

possuem mesmo peso na análise. Mais uma vez, o MAB apresenta o melhor desempenho, buscando garantir o melhor QoSE. Como a eficiência energética torna-se mais relevante, o desempenho do ADR é ainda mais baixo para raios maiores.

Esse comportamento mais elevado de QoSE do MAB tem relação com as suas escolhas durante o período de convergência. Como o consumo possui impacto maior, o MAB priorizou os \vec{a} de menor consumo, o que permitiu resultados satisfatórios para esta configuração.

A Tabela 19 apresenta de forma quantitativa os ganhos, em porcentagem, do MAB em relação ao ADR e ao *Random* para cada raio. Percebe-se que o MAB apresentou uma perda de desempenho em relação ao QoSE de 1,34% em relação ao ADR para o raio igual a 2 km, enquanto apresentou uma melhoria de 102,83% para o raio de 8 km, valor muito relevante. Como esperado, o ADR atribui aos EDs o SF12 em sua maioria, ocasionando em um consumo elevado e ainda com a PDR baixa, resultando em um QoSE do ADR de apenas 0,27 nesta configuração. Nos demais casos, o MAB tem desempenho acima do ADR para raio maior do que 3 km e menor ou igual no raio de 3 km e 2 km.

Tabela 19 – Ganho de desempenho de MAB na comparação com ADR e *Random* para Cenário 3 e $\alpha = 0,50$.

Raio (m)	Ganho QoSE MAB/ADR(%)	Ganho QoSE MAB/ <i>Random</i> (%)
2000	-1,34	19,04
3000	-0,24	13,78
4000	6,29	5,20
5000	38,66	7,46
6000	54,08	1,28
8000	102,83	1,08

Por fim, a Figura 25 apresenta o QoSE para $\alpha = 0,25$ em função da distância em metros, finalizando a comparação do MAB com ADR e *Random* para diferentes valores de α . Este valor de α indica um maior peso consumo energético, evidenciando ainda mais a inadequação do ADR para aplicações em que a duração da bateria é um fator limitante. De fato, para raios maiores dos que 4 km, até escolher o SF de forma aleatória apresenta um melhor desempenho do que o ADR. Contudo, a Figura 25 também evidencia o melhor desempenho do MAB com relação ao *Random*, mostrando que o algoritmo proposto é mais

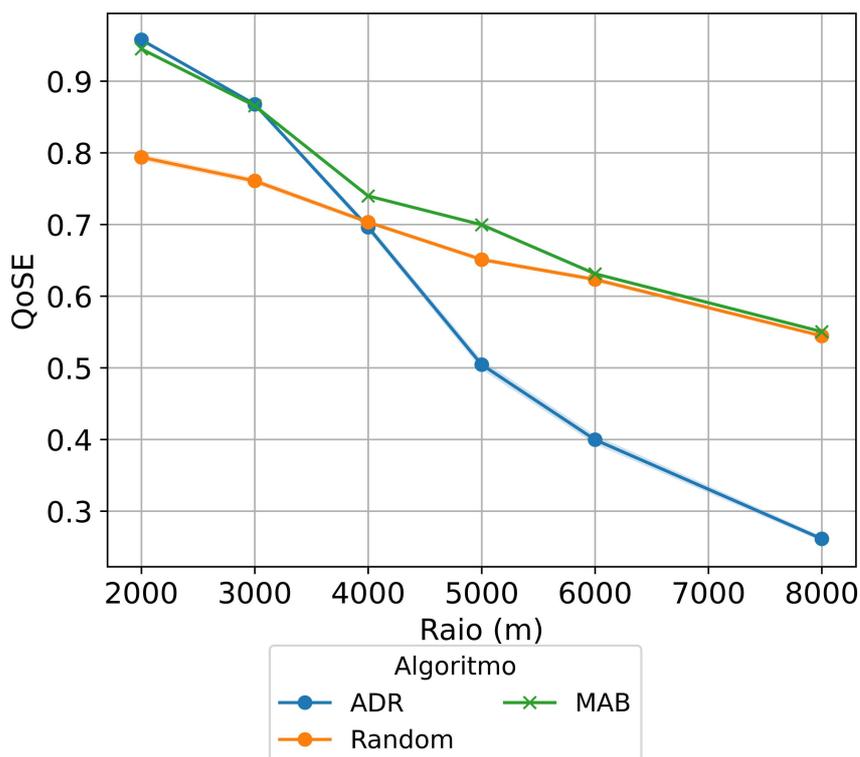


Figura 24 – QoSE ($\alpha = 0,5$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.

do que uma escolha aleatória de SFs.

A Tabela 20 apresenta de forma percentual os ganhos do MAB em relação ao ADR e ao *Random* para cada raio. Percebe-se que o MAB apresentou uma perda de desempenho em relação ao QoSE de 7,24% em relação ao ADR para o raio igual a 2 km, resultado da alocação de SF7 nos dispositivos. A partir do raio igual a 3 km, o MAB apresenta melhorias, atingindo até 253,78% para o raio de 8 km, a maior melhoria levando em consideração todos os cenários e diferentes valores de α . Este valor equivale a um desempenho de mais do triplo do MAB em relação ao ADR, evidenciando quão ineficiente energeticamente o ADR pode ser para distâncias longas. Assim, como $1 - \alpha$ é mais relevante nesta configuração, o MAB priorizou novamente os \vec{a} de menor consumo.

Tabela 20 – Ganho de desempenho de MAB na comparação com ADR e Random para Cenário 3 e $\alpha = 0,25$.

Raio (m)	Ganho QoSE MAB/ADR	Ganho QoSE MAB/Random
2000	-7,24	22,57
3000	1,73	24,19
4000	25,94	19,77
5000	83,14	22,30
6000	128,89	18,70
8000	253,78	19,50

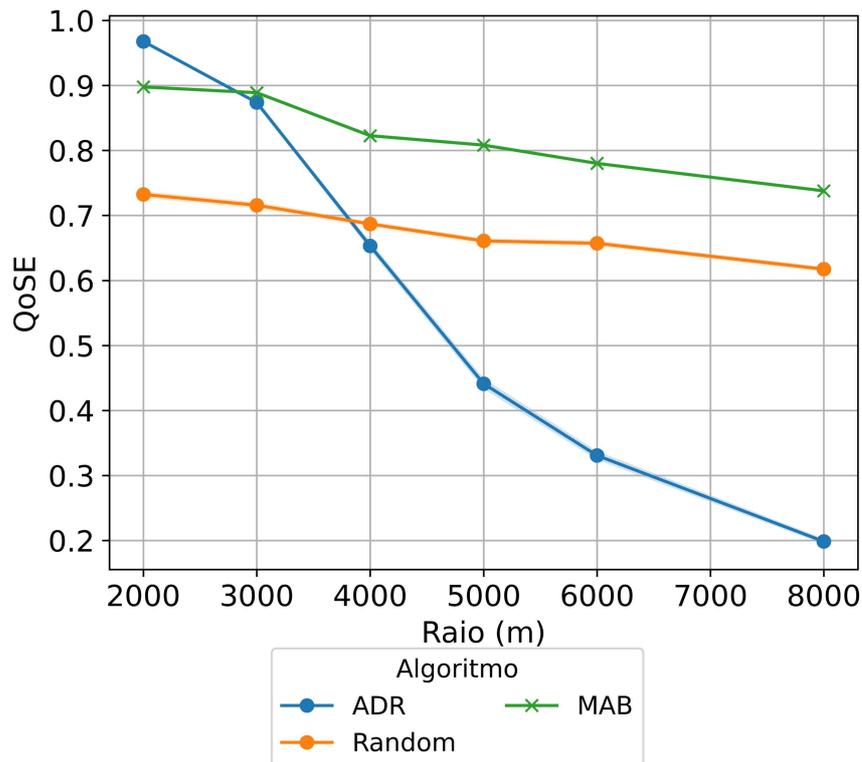


Figura 25 – QoSE ($\alpha = 0,25$) x Raio (m) para rede com 75% NLOS e 25% LOS. Elaborado pelo autor.

5.4.5 Vida útil bateria

Por fim, o consumo energético do MAB é comparado ao do ADR para uma situação em que a proporção δ de dispositivos NLOS é de 75% e $\alpha = 0,75$, representando o cenário de maior interesse devido à proximidade do encontrado na campanha de medição. Para tanto, optou-se por analisar o consumo energético de acordo com a vida útil da bateria utilizando cada estratégia, isto é, o tempo, em anos, que a bateria esgotará ao utilizar cada estratégia.

Com isso, a Figura 26 apresenta a vida útil da bateria em função do raio para o ADR e MAB. Foi considerada uma bateria de 1000 mAh por ser uma bateria de capacidade mediana apresentada na Seção 2.5.3. Além disso, devido à instabilidade apresentada pelas baterias ao ultrapassar 70% de sua capacidade, foi estimado a vida útil da bateria até atingir este valor, ou seja, o tempo necessário para a estratégia alcançar 700 mAh.

Como o ADR privilegia o uso de SF7 para raios menores, é observado um consumo energético relativamente baixo, visto que esse SF apresenta maior eficiência energética. Em contraste, o MAB, por necessitar testar todas as ações disponíveis, inclusive aquelas que demandam um maior consumo energético, acumula um consumo adicional, apresentando uma diferença significativa em comparação com o ADR em condições de menores distâncias. Neste trabalho, para raios de 2 km e 3 km, quanto menor for a exploração do MAB, menos serão escolhidos vetores \vec{a} (IV), (V) e (VI) que são focados

em cobertura e, por conseguinte, utilizam maior peso para SFs maiores. Sendo assim, o MAB tende obter um menor consumo. Porém, diminuir a exploração pode afastar do resultado ótimo em termos de QoSE, portanto cada aplicação deve avaliar o *trade-off* exploração-exploração para garantir maior eficiência energética sem perda de desempenho.

Para raios maiores, essa dinâmica se inverte. O ADR passa a optar pela atribuição mais frequente SF11 e SF12, que são fundamentalmente mais custosos em termos de consumo energético, enquanto o MAB apresenta uma redução no consumo para esses cenários, uma vez que, com o tempo, o algoritmo converge para ações que equilibram melhor o desempenho com a eficiência energética. Além disso, não há entre as ações disponíveis neste trabalho um vetor \vec{a} que concentre alocação massiva em SF11 e SF12, isto é, que aloque 100% dos dispositivos junto à SF11 e SF12. Portanto, mesmo ações mais custosas do MAB apresentarão menor consumo energético que o ADR.

A Tabela 21 apresenta o tempo, em anos que cada algoritmo levaria para consumir a vida útil da bateria na comparação entre MAB e ADR. Chama atenção os dois extremos da tabela: como o cenário não apresenta muitas dificuldades de propagação para raio igual a 2 km, o ADR consegue seguir usando o SF7, o que o torna o algoritmo com menor consumo energético e, na mesma situação, tendo o MAB consumindo a bateria em 47,83% do tempo do ADR. Em compensação, o outro extremo evidencia quão elevado pode ser o custo energético do ADR, não só para o raio de 8 km, mas para todos os raios a partir de 4 km, tendo, no pior caso, o consumo da bateria 3 vezes mais rápido do que o MAB.

A Tabela 21 é ainda mais interessante quando é relacionada com o QoSE da Tabela 18. A partir dessa relação, é possível compreender que o ADR, nas situações acima de 4 km, não só está apresentando um consumo elevado, como o consumo está ineficiente, já que a taxa de entrega de pacotes também está baixa, resultando em uma baixa qualidade de serviço. Em compensação, embora o MAB não seja o algoritmo de maior economia energética para raios de 2 km e 3 km, apresenta uma taxa de entrega de pacotes alta para ambos casos e razoável para raios maiores, com a adição de economia de bateria que pode variar de 1 a 2 anos em relação ao ADR, a depender do raio.

Tabela 21 – Vida útil de bateria 1000 mAh para MAB e ADR.

Raio (m)	MAB (anos)	ADR (anos)	MAB/ADR (%)
2000	3,75	7,84	-47,83
3000	3,26	4,43	-73,59
4000	2,60	1,84	141,30
5000	2,66	1,22	218,03
6000	2,47	1,03	239,81
8000	2,67	0,89	300

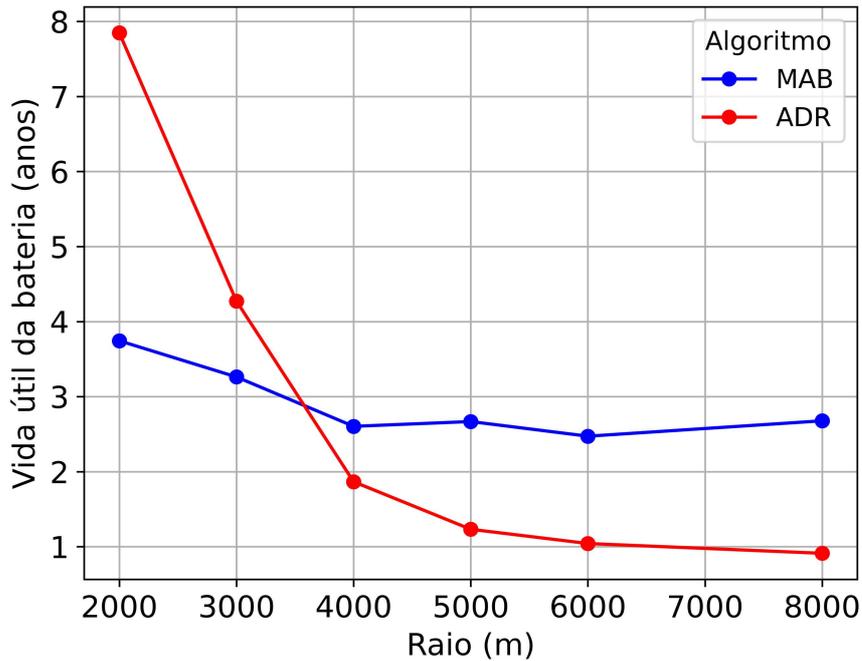


Figura 26 – Vida útil da bateria em situação $\delta = 0,75$ e $\alpha = 0,75$ para ADR e MAB. Elaborado pelo autor.

5.5 Conclusão

Este capítulo desenvolveu uma estratégia para a alocação inteligente de fatores de espalhamento em redes LoRaWAN utilizando aprendizado por reforço. Essa estratégia foi motivada não só pela ausência de um vetor \vec{a} ótimo para todos os cenários avaliados, mas também por cada \vec{a} desempenhar melhor diante situações particulares, configurando um cenário de dinamismo em que a identificação de melhor \vec{a} é um fator preponderante para melhor desempenho de taxa de entrega de pacotes e redução de consumo energético.

Para tanto, foi utilizado o algoritmo *Multi Armed Bandits*, o qual pôde convergir para a melhor opção em todos os cenários avaliados. A métrica de recompensa escolhida para emprego do MAB foi o QoSE, métrica normalizada entre 0 e 1 proposta neste trabalho para equalizar a PDR e o consumo energético através do peso α , em que $\alpha \in [0, 1]$ e indica o peso dado para a PDR, enquanto $1 - \alpha$ é o peso dado para o consumo energético na análise. Neste trabalho, optou-se por $\alpha = 0,75$ para atribuir maior importância a PDR, mas sem deixar de lado o consumo energético.

As simulações realizadas neste capítulo atingiram a convergência do algoritmo, mesmo no Cenário 0, o mais desafiador diante a mudança brusca de proporção de dispositivos NLOS depois de metade do tempo total de simulação. Também houveram variações no valor de δ e no α a fim de verificar se a convergência seria alcançada, o que foi bem sucedido. Os resultados apontaram para melhorias significativas para raios maiores que 3 km, com o MAB absorvendo as melhores características de cada \vec{a} disponível para desempenhar de forma satisfatória, configurando uma alternativa promissora frente ao

ADR e ao *Random*. Para raio menor ou igual a 3 km, não houveram melhorias e isso se explica pela escolha do ADR em priorizar SF7 e SF8 nessas situações, enquanto o MAB não possuía como alternativa um \vec{a} que focasse em concentração absoluta nesses dois SFs.

No Capítulo 2, discutiu-se a importância da redução do consumo energético para prolongar a vida útil de baterias sem perda de desempenho, principalmente para aplicações de difícil manutenção. Diante disso, neste capítulo também foi avaliado o impacto de optar pela utilização de MAB em termos de vida útil da bateria e comparado com o ADR. Uma bateria de 1000 mAh foi escolhida para análise pelo fato de apresentar capacidade energética mediana. Considerou-se um cenário em que haveria troca de bateria quando esta consumisse 70% de sua capacidade total, conforme elucidado no Capítulo 2. Com isso, os resultados apontaram que a aplicação do MAB possibilita uma extensão da vida útil das baterias dos EDs para raios superiores a partir de raio de 4 km, superando a vida útil do ADR em até 300% a depender do raio. Para raio menor ou igual a 3 km, o ADR provê maior vida útil à bateria pela concentração em SF7 e SF8, que consomem menos energia em relação a SFs maiores.

Combinando esta análise de vida útil com a de desempenho, conclui-se que o MAB é uma alternativa interessante para melhoria de qualidade de serviço e redução de custos, especialmente para raios maiores que 4 km, em que o ADR tem um consumo elevado e baixo desempenho.

6 Conclusões

Este trabalho abordou a otimização de desempenho e consumo energético de redes LoRaWAN a partir da identificação da linha de visada utilizando técnicas de inteligência artificial. Para este resultado, foi proposta uma estratégia de alocação inteligente do fator de espalhamento por meio da aplicação de técnicas de aprendizado por reforço. Com isso, o trabalho teve como objetivo principal melhorar o desempenho da rede e reduzir o consumo energético dos dispositivos finais, superando estratégias de alocação baseados apenas na sensibilidade do receptor.

Foram investigados modelos analíticos e simulados que permitiram não só a compreensão do consumo energético em redes LoRaWAN, mas também a influência de parâmetros de canal. A partir de uma campanha de medição, foi proposta uma separação de canal em cenários com linha de visada ou sem linha de visada e, posteriormente, a identificação inteligente destes canais.

Uma vasta quantidade de algoritmos foram estudados e avaliados, visando uma comparação entre as melhores técnicas para classificação do ambiente em LOS e NLOS. Primeiramente, algoritmos relacionados ao pré-processamento foram aplicados e, em um segundo momento, a seleção de características empregada a fim de reduzir a complexidade do modelo de aprendizado. Por fim, os algoritmos RF, KNN, MLP e SVM foram propostos para a classificação e, para avaliação de melhor desempenho, foram utilizadas as métricas *Score*, *Precision*, *Recall*, *F1 Score* e tempo de processamento, as quais indicaram que o algoritmo RF foi o que melhor desempenhou, obtendo 97.48% em *Score* e 97.28% de *Precision*, métricas mais relevantes neste trabalho.

Como resultado disso, obteve-se a caracterização dos canais, os quais foram separados em LOS e NLOS. A implementação dos dados coletados no ns-3 foi realizada e permitiu a realização de simulações baseadas em ambientes reais, as quais permitiram variação de estratégias de alocação de fator de espalhamento. Logo, foram propostas novas estratégias não baseadas em sensibilidade e foram comparadas com o ADR.

Os resultados expostos demonstraram que estratégias não baseadas em sensibilidade, e personalizadas de acordo com o canal de transmissão, apresentam ganhos se comparado com o ADR. Entretanto, tais estratégias possuem desempenho melhor ou pior a depender de condições como o canal utilizado e raio da rede, portanto devem ser escolhidas apropriadamente.

Diante disso, a utilização de aprendizado por reforço no contexto dinâmico apresentou-se como uma ótima alternativa, já que houve melhoria no desempenho da rede. A aplicação de estratégias como o $\epsilon - greedy$ e o algoritmo MAB permitiu com que o algoritmo fosse se adaptando e absorvendo o melhor de cada estratégia.

Essa adaptabilidade validou a proposta de utilizar aprendizado por reforço neste trabalho. Para avaliar os resultados de cada estratégia, este trabalho propôs a utilização do QoSE, métrica que leva em consideração o desempenho e o consumo por meio de pesos, possibilitando ajuste de acordo com a aplicação. Analisando os resultados, é possível observar que o MAB tomou escolhas provendo equilíbrio entre desempenho e consumo energético, conforme o objetivo deste trabalho.

6.1 Trabalhos Futuros

Como continuidade desse trabalho, algumas sugestões são indicadas para contribuições e aprimoramentos, as quais são:

- Comparar os vetores \vec{a} aqui apresentados com o algoritmo sugerido pela *Semtech*. Para isso é necessária uma implementação do ADR no ns-3 mais próxima do algoritmo da *Semtech*. Uma sugestão pode ser uma melhoria recente do módulo do Magrin [75];
- Implementar o algoritmo MAB em um *Network Server* a fim de colocar a proposta de alocação inteligente de SF baseada em aprendizado por reforço em uma rede LoRaWAN real;
- Testar arquiteturas com mais de um *Gateway* no ns-3;
- Implementar outros algoritmos de RL para avaliar desempenho computacional;
- Acrescentar os algoritmos de classificação deste trabalho ao ns-3, de modo que possa realizar a classificação em tempo real combinada ao processo de aprendizado por reforço aqui desenvolvido.

7 Apêndice

Consta, neste Apêndice, um resumo das principais mudanças de código realizadas no ambiente ns-3. É apresentado alguns conceitos e dificuldades encontradas para implementação das simulações ao longo desse trabalho sem especificidades técnicas extensivas.

Para mais detalhes de implementação, acesse www.github.com/lucas-lima99

7.1 Principais mudanças para consumo energético

No total, houveram mudanças nos arquivos:

- `end-device-lora-mac.cc` `end-device-lora-mac.h`: Anteriormente, não havia variação de potência nos EDs, sendo 14 dBm o valor fixo de potência. Poranto, foi necessária a criação de métodos para alterar (*Set*) e retornar (*Get*) o valor de potência de transmissão desejada e realizar conexão entre os ponteiros da camada MAC com os novos métodos, transformando a potência de transmissão em um parâmetro de entrada configurável no começo da simulação e podendo ser alterada a qualquer instante.
- `lora-radio-energy-model.cc` `lora-radio-energy-model.h`: Criação do método `'SetTxCurrentFromModel'`, o qual busca o modelo de modo de transmissão escolhido no início da simulação e calcula a corrente de transmissão com base no valor de potência de transmissão de cada ED.
- `lora-tx-current-model.cc` `lora-tx-current-model.h`: Criação da classe `'SX1272LoRaWANCurrentModel'`, a qual faz parte da super classe `'LoraTxCurrentModel'`, a partir da continuação do *script* disponibilizado por [22]. Além disso, foi adicionado o atributo `'TxPowerToTxCurrent'`, responsável criar um mapeamento de valores de potência de transmissão com correntes TX, permitindo a variação de potência de transmissão para o modo TX e alterações em relação ao cálculo da corrente. Esta nova classe segue o modelo de consumo do *datasheet* SX1272 [51].

7.2 Principais mudanças para canal

No total, houveram mudanças nos arquivos:

- `main.cc`: Anteriormente, o canal de transmissão era instalado automaticamente nos EDs a partir do emprego de um *helper* pertencente à camada física, porém, esse *helper* tem como limitação a restrição de uso apenas um canal como parâmetro. Em outras palavras, o módulo do Magrin não suportava redes em que parte dos EDs utiliza um canal e outra parte utiliza um canal diferente. Com isso, ao tentar usar o *helper* para instalar um segundo canal em parte dos EDs, o canal anterior era removido e, o grupo dos EDs que faziam uso do canal anterior permaneciam sem canal. Com isso, foi necessário reformular o arquivo ‘main’, criando uma nova lógica para instalação manual de canais em todos os EDs.

Para isso, utilizou-se de métodos já presentes no ns-3 para impor o endereço do canal nos EDs. Posteriormente, habilitou-se o envio de pacotes dentro dos ponteiros pertencentes aos canais para que eles pudessem realizar transmissões *uplink*. Por fim, foi necessário buscar o ponteiro relativo ao GW para atribuir o endereço de todos os EDs, bem como todos os canais que foram utilizados pelos EDs, em sua estrutura, de modo que o GW seja capaz de receber os pacotes transmitidos pelos EDs de acordo com cada canal estabelecido.

- `lora-mac-helper.cc` `lora-mac-helper.h`: Diante das mudanças no arquivo ‘main.cc’, alterações nos arquivos referentes a ‘lora-mac-helper’ foram exigidas. O método ‘SetSpreadingFactorsUp’ recebia como parâmetro o canal o qual faria a transmissão dos pacotes. Entretanto, com a adição de um novo canal, utilizar o método da forma anteriormente configurada implicaria em pacotes não enviados.

Portanto, foi necessário mudar a lógica de obtenção do canal para o método. Da arquitetura de [46], tem-se que o objeto referente ao ED pertence à uma subclasse de ‘LoraNetdevice’, classe que guarda todas as informações referentes às camada da rede LoRaWAN e acessada a partir da inclusão do arquivo ‘lora-phy-helper.h’. Ao incluir este arquivo nas bibliotecas, o método ‘SetSpreadingFactorsUp’ passou estar habilitado a buscar o canal na camada física de cada ED o qual envia pacotes.

Com isso, utilizando como base o ponteiro que contém o ED, foi obtida a camada física a qual o ED fará uso. Sendo assim, as informações referentes ao canal foram acessadas e salvas em uma nova variável não havendo mais necessidade de utilizar a variável do canal como parâmetro de entrada no método, já que as informações relevantes foram alcançadas internamente a partir do momento que o ponteiro que contém o ED é recebido.

Referências

- [1] S. Sinha, “State of IoT 2023: Number of connected IoT devices growing 16% to 16.7 billion globally,” *Available: <https://iot-analytics.com/number-connected-iot-devices>*, May, 2023.
- [2] Ericsson, “Ericsson Mobility Report - November 2024,” *Ericsson*, n. November, p. 36, 2024. endereço: www.ericsson.com/mobility-report.
- [3] J. Carvalho, “Internet das Coisas (IoT) vai movimentar US\$ 285.9 bilhões no mercado de energia até 2032,” em *Disponível em https://ipnews.com.br/internet-das-coisas-iot-no-mercado-de-energia-vai-movimentar-us-2859-bilhoes-ate-2032/#Principais_impulsionadores*, 2024.
- [4] A. Aldahiri, B. Alrashed e W. Hussain, “Trends in Using IoT with Machine Learning in Health Prediction System,” *Forecasting*, v. 3, n. 1, pp. 181–206, 2021, ISSN: 2571-9394. DOI: 10.3390/forecast3010012. endereço: <https://www.mdpi.com/2571-9394/3/1/12>.
- [5] J. Lee, M. Dong e Y. Sun, “A preliminary study of low power wireless technologies: ZigBee and Bluetooth Low Energy,” *2015 IEEE 10th Conference on Industrial Electronics and Applications (ICIEA)*, June, 2015. DOI: 10.1109/ICIEA.2015.7334098.
- [6] W. Ayoub, E. Samhat, F. Nouvel, M. Mroue e J.Prevotet, “Internet of Mobile Things: Overview of LoRaWAN, DASH7, and NB-IoT in LPWANs Standards and Supported Mobility,” *IEEE Communications Surveys Tutorials*, vol. 21, no. 2, pp. 1561–1581, 2019. DOI: <https://doi.org/10.1109/COMST.2018.2877382>.
- [7] A. Mahmood, E. Sisinni, L. Guntupalli, R. Rondon, S. A. Hassan e M. Gidlund, “Scalability Analysis of a LoRa Network Under Imperfect Orthogonality,” *IEEE Transactions on Industrial Informatics*, vol. 15, no. 3, pp. 1425, March, 2019. DOI: <https://doi.org/10.1109/TII.2018.2864681>..
- [8] M. Langote, “System for IoT Agriculture Using LoRaWAN,” em *2023 1st DMIHER International Conference on Artificial Intelligence in Education and Industry 4.0 (IDICAIEI)*, vol. 1, 2023, pp. 1–5. DOI: 10.1109/IDICAIEI58380.2023.10406617.
- [9] D. Magrin, M. Centenaro e L. Vangelista, “Performance evaluation of LoRa networks in a smart city scenario,” *IEEE International Conference on Communications (ICC)*, May, 2017. DOI: <https://doi.org/10.1109/ICC.2017.7996384>.
- [10] V. G. D. Oliveira e R. R. D. Sabino, “Desafios e soluções para desenvolver a mobilidade urbana e sustentável no Brasil,” 2022.
- [11] M. I. Hossain, “Comparison of LPWAN Technologies: Cost Structure and Scalability,” *Wireless Personal Communications*, v. 121, pp. 1–17, nov. de 2021. DOI: 10.1007/s11277-021-08664-0.

- [12] P. Daniłowski, “Battery Life of LoRa Devices,” Acessado em Nov 2024. Disponível em: <https://yosensi.io/posts/battery-life-of-lora-devices/>, rel. técn., Aug 2021.
- [13] A. Olejniczak, O. Blaszkiewicz, K. Cwalina, P. Rajchowski e J. Sadowski, “LOS and NLOS identification in real indoor environment using deep learning approach,” *Digital Communications and Networks*, mai. de 2023. DOI: 10.1016/j.dcan.2023.05.009.
- [14] R. E. Nkrow, B. Silva, D. Boshoff, G. Hancke, M. Gidlund e A. Abu-Mahfouz, “NLOS Identification and Mitigation for Time-based Indoor Localization Systems: Survey and Future Research Directions,” *ACM Comput. Surv.*, v. 56, n. 12, out. de 2024, ISSN: 0360-0300. DOI: 10.1145/3663473. endereço: <https://doi.org/10.1145/3663473>.
- [15] F. Carpi, M. Martalo, L. Davoli et al., “Experimental analysis of RSSI-based localization algorithms with NLOS pre-mitigation for IoT applications,” *Computer Networks*, v. 225, p. 109663, mar. de 2023. DOI: 10.1016/j.comnet.2023.109663.
- [16] J. Yang, K. Tsubouchi, S. Nakamae e N. Nishio, “Orientation Estimation using Differences in WiFi Signal Behavior in LOS and NLOS Cases,” mar. de 2024, pp. 493–498. DOI: 10.1109/PerComWorkshops59983.2024.10502827.
- [17] Z. Wei, B. Mao, H. Guo, Y. Xun, J. Liu e N. Kato, “An Intelligent Path Loss Prediction Approach Based on Integrated Sensing and Communications for Future Vehicular Networks,” *IEEE Open Journal of the Computer Society*, v. PP, pp. 1–11, jan. de 2024. DOI: 10.1109/OJCS.2024.3386733.
- [18] A. Bombino, S. Grimaldi, A. Mahmood e M. Gidlund, “Machine Learning-Aided Classification of LoS/NLoS Radio Links in Industrial IoT,” abr. de 2020. DOI: 10.1109/WFCS47810.2020.9114409.
- [19] L. Casals Ibáñez, B. Mir Masnou, R. Vidal Ferré e C. Gomez, “Modeling the Energy Performance of LoRaWAN,” *Sensors*, v. 17, p. 2364, out. de 2017. DOI: 10.3390/s17102364.
- [20] R. Macêdo, M. Miranda, J. Lima e A. de Medeiros, “Modelagem inteligente de perda de percurso utilizando transceptores LoRa,” jan. de 2019. DOI: 10.14209/sbrt.2019.1570557263.
- [21] K. Islam, D. Murray, D. Diepeveen, M. Jones e F. Sohel, “LoRa-based outdoor localization and tracking using unsupervised symbolization,” *Internet of Things*, v. 25, p. 101016, nov. de 2023. DOI: 10.1016/j.iot.2023.101016.
- [22] J. Finnegan, S. Brown e R. Farrell, “Modeling the Energy Consumption of LoRaWAN in ns-3 Based on Real World Measurements,” em *2018 Global Information Infrastructure and Networking Symposium (GIIS)*, 2018, pp. 1–4. DOI: 10.1109/GIIS.2018.8635786.
- [23] G. Macedo, V. Jr, A. de Medeiros, L. Costa e J. Silva, “LoRaWAN em Pecuária Inteligente: Análise de Desempenho de Algoritmos de ADR,” jan. de 2023. DOI: 10.14209/sbrt.2023.1570918971.

- [24] L. Filho, A. Medeiros, J. Silva, V. A. D. S. JUNIOR e N. Bezerra, “Spreading Factor Assignment Strategy for Coverage and Capacity Flexible Tradeoff,” *Journal of Communication and Information Systems*, v. 37, n. 1, pp. 47–51, fev. de 2022. DOI: 10.14209/jcis.2022.5. endereço: <https://jcis.sbrt.org.br/jcis/article/view/801>.
- [25] K. Mikhaylov, J. Petäjäjärvi e T. Hänninen, “Analysis of the Capacity and Scalability of the LoRa Wide Area Network Technology,” mai. de 2016.
- [26] S. Aggarwal e A. Nasipuri, “Improving Scalability of LoRaWAN Networks by Spreading Factor Distribution,” *SoutheastCon 2021*, pp. 1–7, 2021. endereço: <https://api.semanticscholar.org/CorpusID:233332681>.
- [27] A. Farhad, D.-H. Kim e J.-Y. Pyun, “Resource allocation to massive internet of things in LoRaWANs,” *Sensors*, v. 20, n. 9, p. 2645, 2020.
- [28] M. Hammache, R. Kacimi e A.-L. Beylot, “L3sfa: Load shifting strategy for spreading factor allocation in LoRaWAN systems,” em *2020 IEEE 45th Conference on Local Computer Networks (LCN)*, IEEE, 2020, pp. 216–224.
- [29] M. R. Rao e S. Sundar, “Enhanced LoRaWAN performance through advanced spread factor allocation empowered by machine learning,” *Engineering Research Express*, v. 6, n. 4, p. 045354, 2024.
- [30] M. R. Rao e S. Sundar, “Enhanced LoRaWAN performance through advanced spread factor allocation empowered by machine learning,” *Engineering Research Express*, v. 6, n. 4, p. 045354, 2024.
- [31] A. Farhad e J.-Y. Pyun, “LoRaWAN meets ML: A survey on enhancing performance with machine learning,” *Sensors*, v. 23, n. 15, p. 6851, 2023.
- [32] M. Chen, L. Mokdad, J. Ben-Othman e J.-M. Fourneau, “Dynamic parameter allocation with reinforcement learning for LoRaWAN,” *IEEE Internet of Things Journal*, v. 10, n. 12, pp. 10250–10265, 2023.
- [33] A. Valkanis, G. A. Beletsioti, K. F. Kantelis, P. Nicopolitidis e G. I. Papadimitriou, “Ensuring Reliability for LoRa Networks Using a Reinforcement-Learning-Assisted Time Division Duplex Protocol,” *IEEE Internet of Things Journal*, v. 11, n. 3, pp. 4179–4190, 2023.
- [34] N. Aihara, K. Adachi, O. Takyu, M. Ohta e T. Fujii, “Q-learning aided resource allocation and environment recognition in LoRaWAN with CSMA/CA,” *IEEE Access*, v. 7, pp. 152126–152137, 2019.
- [35] A. Ivoghlian, Z. Salcić e K. I.-K. Wang, “Federated Reinforcement Learning for Automated LoRaWAN Management in Industrial IoT,” em *International Conference on Mobile and Ubiquitous Systems: Computing, Networking, and Services*, Springer, 2023, pp. 136–155.

- [36] J. Moraes, H. Oliveira, E. Cerqueira, C. Both, S. Zeadally e D. Rosário, “Evaluation of an Adaptive Resource Allocation for LoRaWAN,” *J. Signal Process. Syst.*, v. 94, n. 1, pp. 65–79, jan. de 2022, ISSN: 1939-8018. DOI: 10.1007/s11265-021-01678-8. endereço: <https://doi.org/10.1007/s11265-021-01678-8>.
- [37] S. Chen, H. Zhao, Z. Zhang, Y. Gong, R. Li e L. Wang, “Improved ADR and Initial SF Allocation in LoRaWAN Network and their Simulation on NS3,” nov. de 2023, pp. 1–5. DOI: 10.1109/ICSPCC59353.2023.10400320.
- [38] K. Q. Abdelfadeel, V. Cionca e D. Pesch, “Fair adaptive data rate allocation and power control in LoRaWAN,” em *2018 IEEE 19th International Symposium on “A World of Wireless, Mobile and Multimedia Networks” (WoWMoM)*, IEEE, 2018, pp. 14–15.
- [39] A. Fonseca, L. Oliveira, A. de Medeiros, M. Caballero e J. Martinez, “Perda de Percurso para Redes LoRaWAN em Ambientes Compostos,” jan. de 2024. DOI: 10.14209/sbrt.2024.1571036506.
- [40] L. Oliveira, A. de Medeiros, E. Silva e L. Oliveira, “Identificação Inteligente de Linha de Visada em Redes LoRaWAN,” jan. de 2024. DOI: 10.14209/sbrt.2024.1571036507.
- [41] L. L. De Oliveira, L. A. De Oliveira, E. F. Silva, V. A. De Sousa e Á. A. M. De Medeiros, “Smart Line-of-Sight Identification in LoRaWAN Networks,” em *2024 Symposium on Internet of Things (SIoT)*, vol. 1, 2024, pp. 1–5. DOI: 10.1109/SIoT63830.2024.10780656.
- [42] L. L. de Oliveira, A. A. M. de Medeiros, V. Â. de Sousa Junior e G. Macedo, “Alocação do fator de espalhamento e consumo de bateria em redes LoRaWAN,” *Anais da Conferência Nacional em Comunicações, Redes e Segurança da Informação (ENCOM) Natal(RN)*, Disponível em: <https://www.even3.com.br/anais/encom2024/881919-ALOCACAO-DO-FATOR-DE-ESPALHAMENTO-E-CONSUMO-DE-BATERIA-EM-REDES-LORAWAN.>, 2024.
- [43] A. Wirsbinna, “LoRaWAN AS PART OF A SMART CITY STRATEGY,” *International Journal of Innovative Technologies in Economy*, ago. de 2022. DOI: 10.31435/rsglobal_ijite/30092022/7841.
- [44] D. Lopes e J. Kniess, “Monitoramento de Resíduos Poluentes com Tecnologia de Comunicação LPWAN,” em *Anais da XXIV Escola Regional de Alto Desempenho da Região Sul*, Florianópolis/SC: SBC, 2024, pp. 81–84. DOI: 10.5753/eradr.2024.238732. endereço: <https://sol.sbc.org.br/index.php/eradr/article/view/28008>.
- [45] F. V. den Abeele, J. Haxhibeqiri, I. Moerman e J. Hoebeke, “Scalability Analysis of Large-Scale LoRaWAN Networks in ns-3,” *IEEE Internet of Things Journal*, vol. 4, no. 6, pp. 2186–2198, 2017.

- [46] D. Magrin, *Network level performances of a LoRa system*, 2016. DOI: <http://tesicab.unipd.it/53740/1/dissertation.pdf>.
- [47] L. Alliance, “LoRaWAN® Specification v1.1,” Acessado em Nov 2024. Disponível em: <https://resources.lora-alliance.org/technical-specifications/lorawan-specification-v1-1>, rel. técn., Nov 2024.
- [48] Semtech, “LoRaWAN – Simple Rate Adaptation Recommended Algorithm,” Acessado em Nov 2024. Disponível em: <https://www.thethingsnetwork.org/forum/uploads/default/original/2X/7/7480e044aa93a54a910dab8ef0adfb5f515d14a1.pdf>, rel. técn., Oct 2016.
- [49] J. C. d. Silva, D. d. L. Flor, V. A. d. S. Junior, N. S. Bezerra e A. A. M. d. Medeiros, “A Survey of LoRaWAN Simulation Tools in ns-3,” *Journal of Communication and Information Systems*, v. 36, n. 1, pp. 17–30, fev. de 2021. DOI: 10.14209/jcis.2021.2. endereço: <https://jcis.sbirt.org.br/jcis/article/view/741>.
- [50] Semtech, “AN1200.22 LoRa™ Modulation Basics,” [Online] Available: www.semtech.com/uploads/documents/an1200.22.pdf, 2015.
- [51] Semtech, *SX1272/73 - 860 MHz to 1020 MHz Low Power Long Range Transceiver*, 2024.
- [52] Nsnam, *Network simulator-3*, Available <https://www.nsnam.org/>, 2025.
- [53] B. Reynders, Q. Wang e Pollin, “A LoRaWAN module for ns-3: implementation and evaluation,” *WNS3 '18: Proceedings of the 10th Workshop on ns-3*, jun. de 2018. DOI: 10.1145/3199902.3199913.
- [54] V. Bonilla, B. Campoverde e S. G. Yoo, “A Systematic Literature Review of LoRaWAN: Sensors and Applications,” *Sensors*, v. 23, n. 20, 2023, ISSN: 1424-8220. DOI: 10.3390/s23208440. endereço: <https://www.mdpi.com/1424-8220/23/20/8440>.
- [55] A. Lavric e P. Valentin, “Internet of Things and LoRa™ Low-Power Wide-Area Networks: A survey,” pp. 1–5, jul. de 2017. DOI: 10.1109/ISSCS.2017.8034915.
- [56] Semtech, “LoRaWAN® Device Classes,” Acessado em Nov 2024. Disponível em: <https://www.semtech.com/uploads/technology/LoRa/lorawan-device-classes.pdf>, rel. técn., March 2024.
- [57] V. R. Monaretto, “Projeto e Análise de Controle de um carregador de baterias de íons de Lítio,” mai. de 2021.
- [58] T. S. RAPAPPORT, *Comunicações sem fio - principios e praticas*, 2ª. New Jersey: Prentice hall PTR, 1996.
- [59] L. Oliveira, “RSSignal: um Arcabouço para Evolução de Técnicas de Geração de Chaves Baseadas em RSSI,” pp. 111–124, 2022, ISSN: 0000-0000. DOI: 10.5753/sbseg.2022.225333. endereço: <https://sol.sbc.org.br/index.php/sbseg/article/view/21662>.
- [60] T. T. Network, “The Things Network,” 2025.

- [61] Multitech, “MTAC-LoRa Cards,” Disponível: <https://www.multitech.net/developer/products/multiconnect-conduit-platform/accessory-cards/mtac-lora/>,” 2024.
- [62] Multitech, “Multitech Developer Resources - mDot,” Disponível: <https://www.multitech.net/developer/products/multiconnect-dot-series/multiconnect-mdot/>,” 2024.
- [63] C. M. Bishop, *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Berlin, Heidelberg: Springer-Verlag, 2006, ISBN: 0387310738.
- [64] K. P. Murphy, “Machine learning - a probabilistic perspective,” em *Adaptive computation and machine learning series*, 2012. endereço: <https://api.semanticscholar.org/CorpusID:17793133>.
- [65] L. Zahedi, F. Ghareh Mohammadi, S. Rezapour, M. Ohland e M. H. Amini, “Search Algorithms for Automated Hyper-Parameter Tuning,” jul. de 2021.
- [66] N. Isaac, Nyarko-Boateng, Owusu e J. Aning, “Performance of Machine Learning Algorithms with Different K Values in K-fold Cross-Validation,” *International Journal of Information Technology and Computer Science*, v. 6, pp. 61–71, dez. de 2021. DOI: 10.5815/ijitcs.2021.06.05.
- [67] L. L. de Oliveira, “Identificação Inteligente LOS/NLOS LoRaWAN UFJF,” em Disponível: <https://github.com/lucas-lima99>, 2024.
- [68] C. A. BALANIS, *Antenna theory: Analysis and design*, 3°. JOHN WILEY & SONS, INC, 2012.
- [69] S. K. Mitra, *Digital Signal Processing: A Computer Based Approach*, 1st. USA: McGraw-Hill, Inc., 1997, ISBN: 0070429537.
- [70] A. F. MOLISCH, *Wireless Communications*, 2ª. University of southern California: IEEE, 2011.
- [71] M. Jouhari, N. Saeed, M.-S. Alouini e E. M. Amhoud, “A Survey on Scalable LoRaWAN for Massive IoT: Recent Advances, Potentials, and Challenges,” *IEEE Communications Surveys & Tutorials*, v. 25, n. 3, pp. 1841–1876, 2023. DOI: 10.1109/COMST.2023.3274934.
- [72] R. S. Sutton e A. G. Barto, *Reinforcement Learning: An Introduction*. Cambridge, MA, USA: A Bradford Book, 2020, ISBN: 0262039249.
- [73] M. Sangalli, *Reinforcement Learning - The multi-armed bandit problem*, set. de 2022.
- [74] M. Bor, U. Roedig, T. Voigt e J. Alonso, “Do LoRa Low-Power Wide-Area Networks Scale?,” nov. de 2016. DOI: 10.1145/2988287.2989163.
- [75] W. Teixeira Pires Junior, D. da Silva, R. Silva et al., “QoS-aware Optimal Deployment of LoRa Gateways in UAV-enabled LoRaWANs,” ago. de 2024. DOI: 10.5753/sbric.2024.1443.