



Universidade Federal de Pernambuco
Centro de Informática

Graduação em Engenharia da Computação

**Aprendizado de Máquina para Otimização do Consumo de
Energia em Redes *Ad Hoc ALOHA Puro***

Victor Ximenes Carneiro de Oliveira

Trabalho de Graduação

Recife, Pernambuco

Março de 2024

Universidade Federal de Pernambuco
Centro de Informática

Victor Ximenes Carneiro de Oliveira

**Aprendizado de Máquina para Otimização do Consumo de Energia
em Redes *Ad Hoc ALOHA Puro***

Trabalho apresentado ao Curso de Graduação em Engenharia da Computação do Centro de Informática da Universidade Federal de Pernambuco como requisito parcial para obtenção do grau de Bacharel em Engenharia da Computação.

Área de concentração: Redes de computadores

Orientador: Renato Mariz de Moraes

Co-orientador: Paulo Filipe Cândido Barbosa

Recife, Pernambuco

Março de 2024

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Oliveira, Victor Ximenes Carneiro de.

Aprendizado de Máquina para Otimização do Consumo de Energia em
Redes Ad Hoc ALOHA Puro / Victor Ximenes Carneiro de Oliveira. - Recife,
2024.

62 p. : il., tab.

Orientador(a): Renato Mariz de Moraes

Coorientador(a): Paulo Filipe Cândido Barbosa

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Informática, Engenharia da Computação - Bacharelado,
2024.

Inclui referências.

1. Aprendizado de máquina. 2. Redes Ad Hoc. 3. Protocolo Aloha. 4.
Consumo de energia. 5. Internet das coisas. I. Moraes, Renato Mariz de.
(Orientação). II. Barbosa, Paulo Filipe Cândido. (Coorientação). IV. Título.

000 CDD (22.ed.)

Victor Ximenes Carneiro de Oliveira

**Aprendizado de Máquina para Otimização do Consumo de Energia em Redes
Ad Hoc ALOHA Puro**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia da Computação do Centro de Informática da Universidade Federal de Pernambuco, como requisito parcial para obtenção do título de bacharel em Engenharia da Computação.

Aprovado em: 18/03/2024

BANCA EXAMINADORA

Prof. Dr. Renato Mariz de Moraes (Orientador)

Universidade Federal de Pernambuco

Prof. Dr. Paulo Filipe Cândido Barbosa (Co-orientador)

Universidade Federal de Pernambuco

Prof. Dr. Daniel Carvalho da Cunha (Examinador Interno)

Universidade Federal de Pernambuco

Dedico este trabalho a Deus e minha família.

Agradecimentos

Agradeço primeiramente a Deus por toda força, paciência e inteligência para suportar todas as adversidades para concluir essa etapa da minha vida. Destaco que a principal lição desses anos foi a importância da força de vontade para começar e terminar cada ciclo.

Agradeço a minha família, meu irmão Hugo Ximenes, minha mãe Mônica Ximenes e meu pai Alexon Melo, por me incentivar a estudar na UFPE e por serem de grande suporte durante todo esse período.

Agradeço aos meus amigos Arthur Feitoza, Gabriel Melo, Ian Ferreira, Leonardo Conte e Vitor Monte. Agradeço por todos os bons momentos durante esses anos, que sempre se fizeram presentes.

Agradeço ao meu amigo Danilo do Nascimento Santos por me acompanhar todo esse período da faculdade. Em primeiro lugar por ter embarcado na ideia de morar em Recife para estudar na UFPE, e por ter compartilhado todos esses anos, com muitos momentos espontâneos que ficaram marcantes.

Agradecimento especial a cada amigo do grupo Expendables: Daniel Perazzo, Fernando Macedo, José Carlos, Lucas Ambrósio, Matheus Andrade, Pedro Nogueira, Riei Joaquim, Victor Hugo, Victor Miguel, Zenio Angelo e Zilde Neto. Todos vocês foram de extrema importância nesse período da graduação e sinceramente, não conseguiria chegar até aqui sem todo o suporte mútuo desse grupo em sobreviver nas dificuldades da graduação. Dos momentos de companhia nos laboratórios de graduação, as viradas de noite no CIn fazendo projeto, até as ligações no Discord durante a pandemia, todas essas recordações eu guardo com carinho.

Agradeço à associação de tênis de mesa do Sport Club do Recife, sobretudo a Anderson Santos, por toda a jornada de treinamento que rendeu frutos, sendo o principal deles o orgulho de representar a UFPE como atleta de tênis de mesa nos Jogos Universitários Brasileiros, nas edições de 2022 e 2023.

Agradeço a toda experiência e aos envolvidos nos projetos de extensões e trabalhos, cada experiência foi fundamental para o momento atual. Desde as aulas de francês no CAC; a primeira monitoria; a equipe de robótica Maracatronics; a iniciação científica no convenio CIn/Motorola; ao estágio na Fabrica de Negócios; ao trabalho como engenheiro de dados na Neurotech e finalmente ao trabalho como engenheiro de software na PD Case. Cada experiência foi crucial para a formação como profissional.

Agradeço ao meu orientador Prof. Renato Mariz e meu co-orientador Dr. Paulo Barbosa por toda dedicação, orientação e acompanhamento durante o desenvolvimento deste trabalho.

Agradecimento final a você, caro leitor, por estar lendo este trabalho.

“O futuro tem muitos nomes.

Para os fracos é o inalcançável.

Para os temerosos, o desconhecido.

Para os valentes é a oportunidade.”

—VICTOR HUGO

Resumo

O controle de consumo de energia é essencial para o funcionamento de sistemas operados à bateria como os utilizados em redes IoT e de sensores. Os algoritmos normalmente empregados para esse fim envolvem funções de otimização com considerável complexidade e controle rigoroso do ambiente de teste. Por outro lado algoritmos de otimização energética implementados para o protocolo Aloha puro que é base para tecnologias de comunicações em redes IoT como LoRaWAN, tendem a ser mais simples e podem causar colisão de pacotes o que pode resultar em desperdício de energia.

Diante disto o presente trabalho descreve o desenvolvimento e implementação de um algoritmo de redução de consumo de energia baseado em aprendizado de máquina, para o protocolo Aloha puro, que otimize múltiplas variáveis de transmissão como número de bits por quadro, potência de transmissão, número de saltos do remetente ao destinatário na rede, e taxa de transmissão de dados. Os resultados mostram que o sistema proposto reduz o consumo energético durante cada transmissão nos dispositivos que formam a rede, com uma otimização do tempo de execução de 99,994%.

Palavras-chave: Aprendizado de máquina; Redes Ad Hoc ; Protocolo Aloha ; Consumo de energia; Internet das coisas ; Protocolos MAC;

Abstract

The control of energy consumption is essential for the operation of battery-operated systems, such as those used in *IoT* networks and sensors. The algorithms commonly employed for this purpose involve optimization functions with considerable complexity and rigorous control of the test environment. On the other hand, energy optimization algorithms implemented for the pure Aloha protocol, which serves as the basis for communication technologies in *IoT* networks such as *LoRaWAN*, tend to be simpler and may result in packet collisions, leading to energy waste.

In light of this, this proposal aims to implement an energy consumption reduction algorithm based on machine learning for the Aloha protocol. This algorithm will optimize multiple transmission variables, such as the number of bits per frame, transmission power, the number of hops from sender to receiver in the network, and data transmission rate. The expected outcome is to create a system that minimizes energy consumption during each transmission in the devices forming the network, with a runtime optimization of 99.994%.

Keywords: Machine Learning; Ad Hoc network ; Aloha protocol; Energy Consumption ; Internet of Things ; MAC layer.

Lista de Tabelas

3.1	Parâmetros PHY-MAC empregados na geração da base de dados ALOHA	31
3.2	Hiper-parâmetros da RNA para Aloha Puro	33
4.1	Avaliação das métricas da RNA	40
4.2	Intervalos de confiança das métricas com 95% de nível de confiança	41
4.3	Comparativo entre custo computacional da RNA com o MCE	43

Lista de Figuras

1.1 Fluxograma do passo a passo deste trabalho	3
2.1 Tentativas de transmissão e retransmissão devido a colisão de pacotes no protocolo <i>Slotted ALOHA</i> . Fonte: link	14
2.2 Diferença entre modelagem tradicional e aprendizado de máquina [1]	16
2.3 Comparação entre neurônio biológico e neurônio artificial. Fonte: [2]	17
2.4 Gráfico comparativo da convergência entre os método, SGD, Momentum, Adam, Adagrad, Adadelta e Rmsprop sob a função Griewank, coeficiente de aprendizado α variando entre 0,1 (100%) e 0,01 (10%) e número de iterações variando entre 10, 20 e 60 [3]	20
2.5 Gráficos comparativos entre redes neurais com diferentes treinamentos. Fonte: Link	22
3.1 Fluxograma das etapas da metodologia	26
3.2 Rede linear com N nós equidistantes [4]	28
3.3 Arquitetura da Rede Neural Artificial com 2 camadas escondidas	32
3.4 Comparativo entre a base de dados gerada para o protocolo <i>Aloha puro</i> e para o protocolo <i>Aloha Slotted</i>	34
3.5 Distribuição das amostras Treinamento X Teste	35
4.1 Evolução do <i>Mean Squared Error</i> (MSE) durante o treinamento	38
4.2 Comparativo entre o E_{ihop} encontrado pelo MCE e o E_{ihop} predito pela RNA	38
4.3 Comparativo entre o P_0 encontrado pelo MCE e o P_0 predito pela RNA	39
4.4 E_{ihop} em função da taxa de transmissão. Comparativo entre os resultados entre P_0 definido matematicamente e outra abordagem com variação do P_0	40
4.5 E_{ihop} previsto pela RNA e o valor real do MCE para cada quantidade de saltos.	42
4.6 P_0 previsto pela RNA e o valor real do MCE para cada quantidade de saltos.	42

Sumário

1	Introdução	1
1.1	Motivação	1
1.2	Objetivos	2
1.3	Nova Proposta do Consumo de Energia e Modelagem da Rede Neural	2
1.4	Contribuições	4
1.5	Estrutura do Documento	4
2	Revisão Teórica	6
2.1	Redes de Internet das coisas	6
2.1.1	Comunicação sem fio	7
2.1.2	Redes sem Fio	7
2.1.3	Redes de sensores sem fio	8
2.1.4	Protocolos em Internet das Coisas	8
2.1.5	Controle de Acesso ao Meio	9
2.1.6	Protocolos MAC	10
2.1.7	O protocolo ALOHA Puro	12
2.1.8	O protocolo <i>Slotted</i> ALOHA	13
2.2	Aprendizado de máquina	15
2.2.1	Visão geral	15
2.2.2	Aprendizado supervisionado	16
2.2.3	Redes neurais artificiais	17
2.2.4	Métricas de avaliação	22
2.2.5	MultiLayer Perceptron	23
2.3	Trabalhos relacionados	24
2.4	Resumo do capítulo	24

3 Nova Proposta do Consumo de Energia e Modelagem da Rede Neural	26
3.1 Modelo de Consumo de Energia (MCE)	27
3.2 Geração da base de dados para treinamento da RNA	30
3.3 Regressão e otimização da rede neural	32
3.4 Dados do experimentos	33
3.4.1 Comparação do E_{ihop} entre <i>Aloha puro</i> e <i>Aloha Slotted</i>	33
3.4.2 Divisão dos conjuntos de treinamento e teste	33
3.5 Resumo do capítulo	34
4 Resultados Obtidos	36
4.1 Avaliações do treinamento e das previsões da RNA	37
4.1.1 Evolução do MSE durante o treinamento da RNA	37
4.1.2 Comparativo entre o E_{ihop} encontrado pelo MCE e o E_{ihop} predito pela RNA	37
4.1.3 Avaliação dos resultados com $P0$ com variação e fixado pelo modelo	39
4.2 Resultados das métricas da etapa de teste	40
4.2.1 Intervalos de Confiança	41
4.3 Gráfico de E_{ihop} e $P0$ por quantidade de saltos	41
4.4 Comparativo entre custo computacional	41
4.5 Resumo do capítulo	43
5 Conclusão e trabalhos futuros	45
5.1 Conclusão	45
5.2 Trabalhos futuros	46
5.3 Outras contribuições	46
Referências Bibliográficas	47

Capítulo 1

Introdução

“O princípio mais forte de crescimento reside na escolha humana.”

– GEORGE ELIOT

Neste capítulo introdutório serão apresentados a motivação para o desenvolvimento deste trabalho, bem como, o objetivo e a estrutura deste documento.

1.1 Motivação

Com vista na necessidade humana de comunicação, meios foram desenvolvidos para transmitir informações, o que acelerou o desenvolvimento de conhecimento e tecnologias na história. Na atualidade, esse fenômeno se manifesta na crescente proliferação de dispositivos conectados à Internet das Coisas (IoT), em que devido a esses dispositivos serem alimentados muitas vezes por baterias ou fonte de energia limitadas [5], surge uma demanda maior pela eficiência energética. Nesse cenário, o protocolo *Aloha* demonstra sua utilidade nessa área de aplicação, por sua simplicidade em ambientes com restrições de recursos, sobretudo de *hardware*.

O protocolo Aloha desempenha um papel fundamental na infraestrutura do LoRaWAN (do inglês *Long Range Wide Area Network*), uma tecnologia hegemônica voltada para IoT [6]. A tecnologia LoRaWAN utiliza o protocolo Aloha para gerenciar o acesso ao meio, permitindo que dispositivos IoT transmitam dados de forma eficiente em longas distâncias [7]. A importância do Aloha no contexto do LoRaWAN reside na capacidade de coordenar as transmissões de dispositivos IoT, garantindo eficácia na comunicação sem fio.

Em decorrência de sua simplicidade e sua lógica de funcionamento, a taxa de transmissão do protocolo *Aloha* é consideravelmente baixa, devido a alta probabilidade de dois ou mais

nós transmitirem, o que ocasiona um evento de colisão de pacotes na rede e a necessidade de recorrentes retransmissões, sendo esse um relevante fator no aumento do consumo de energia.

Tendo em vista essa dificuldade, este trabalho tem como motivação central aprimorar a eficiência energética do protocolo Aloha Puro em contextos específicos de IoT. A otimização do custo energético torna-se crucial para estender a vida útil das baterias dos dispositivos, reduzir a necessidade de manutenção e, por consequência, melhorar a sustentabilidade das soluções IoT.

1.2 Objetivos

Este trabalho tem como objetivo geral otimizar o consumo energético do protocolo *ALOHA puro*, com base em uma análise quantitativa. Além disso, este trabalho intenciona fornecer uma documentação robusta para servir de referência para futuras pesquisas e contribuições na área de protocolos de comunicação relativa ao *ALOHA puro*.

São objetivos específicos deste trabalho:

1. Definir uma modelagem matemática do consumo de energia do *ALOHA puro* através da dedução das fórmulas físicas do comportamento do protocolo;
2. Gerar uma base de dados relevante da simulação do consumo de energia do protocolo *Aloha puro*;
3. Realizar o treinamento de uma rede neural para predição da potência e consumo de energia com base nos parâmetros gerados pelo conjunto de treino;
4. Avaliar os resultados obtidos para comprovar a otimização do consumo.

1.3 Nova Proposta do Consumo de Energia e Modelagem da Rede Neural

Com a finalidade de atingir os objetivos propostos neste trabalho, definiu-se o percurso metodológico ilustrado na Figura [1.1](#), no qual são exibidas, passo a passo, as atividades realizadas durante esse trabalho.

O percurso inicia com a revisão bibliográfica, com pesquisas e leituras de artigos e materiais científicos disponíveis nas plataformas IEEExplore, Google Scholar, arXiv e ResearchGate,

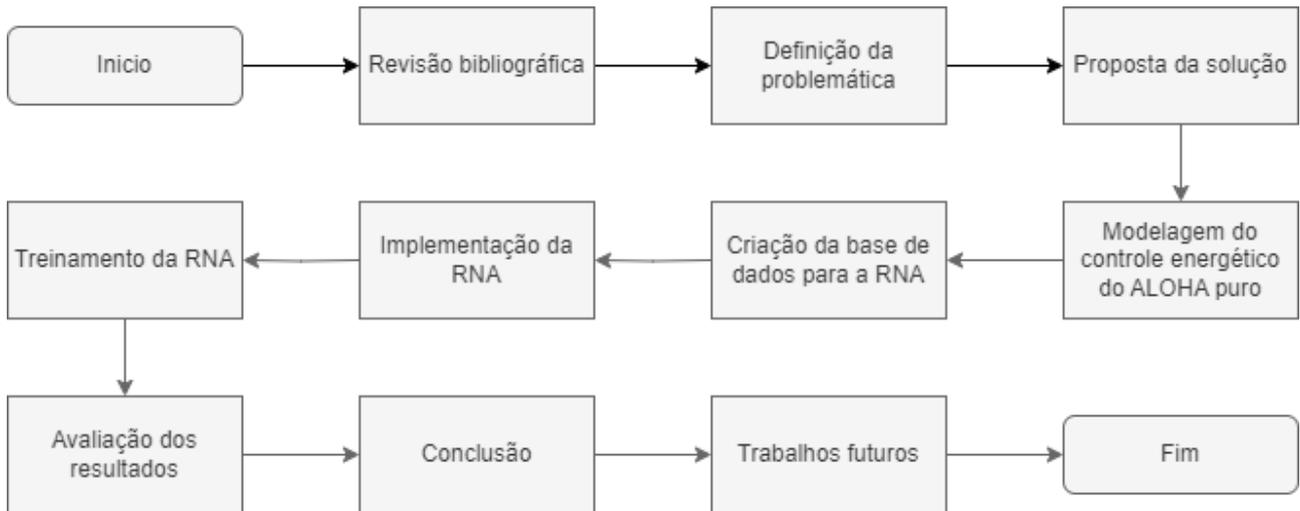


Figura 1.1: Fluxograma do passo a passo deste trabalho

com os descritores “*Pure aloha*”, “*Iot energy consumption*”, “*Iot network protocol*”, “*iot machine learning*” e “*iot machine learning control consumption for WSN*”. A partir disso, foi identificada a problemática do consumo energético que envolvem protocolos de comunicação em dispositivos IoT, sobretudo o *Aloha puro* devido a sua baixa eficiência. Com isso, foi proposta a solução da utilização de uma rede neural artificial, capaz de aprender as melhores configurações de variáveis nas camadas físicas e MAC, para otimizar o consumo de energia e potência de um dispositivo de Internet das Coisas que utiliza o protocolo *Aloha Puro*.

Com a proposta definida, utilizou-se o modelo energético do *Slotted Aloha* proposto em [8] como base para adaptação ao protocolo *Aloha Puro*. Com isso, foi realizado o desenvolvimento das fórmulas para a modelagem do consumo de energia e potência, para que, por meio de um algoritmo de busca exaustiva, fosse gerado uma base de dados robusta com as variáveis das camadas físicas e MAC como número de bits por quadro, taxa de transmissão, distância entre os nós, números de saltos ideais do remetente ao destino.

Com a base de dados gerada, foi iniciado o desenvolvimento da rede neural artificial, no qual foi escolhido a arquitetura *MultiLayer Perceptron* devido a seu baixo custo computacional, indicado para dispositivos Iot. A partir disso, foi realizado o treinamento da rede, ajustando os hiper-parâmetros e avaliando as métricas para otimizar a eficiência da rede.

Para validar os resultados da rede neural, foram utilizados métodos de métricas de regressão, para comparar o desempenho da rede neural em prever com precisão os valores reais da potência e do consumo de energia, para determinada configuração.

As conclusões deste trabalho são extraídas a partir dos resultados obtidos, assim como

sugestões de contribuições futuras a partir deste trabalho.

1.4 Contribuições

Como consequência do percurso metodológico realizado, este trabalho tem como contribuição:

1. Desenvolvimento do modelo matemático do consumo energético do Aloha puro.
2. A criação de uma rede neural artificial, que aprende o comportamento de operacionalização de múltiplas variáveis da camada física e MAC, que contribuem para uma maior eficiência energética em dispositivos que utilizam o protocolo *Aloha puro*.

1.5 Estrutura do Documento

O restante deste documento está organizado da seguinte forma:

Capítulo 2: Revisão Teórica

Este capítulo oferece uma análise aprofundada de tópicos e conceitos essenciais para a compreensão de protocolos de comunicação. Explora sua aplicação no contexto da Internet das Coisas (IoT), abordando as dificuldades e limitações inerentes a esses sistemas. Além disso, fornece uma explicação detalhada sobre aprendizado de máquina e Redes Neurais do tipo *Multilayer Perceptron* (MLP), destacando como esses elementos compõem a abordagem adotada para resolver a problemática em questão.

Capítulo 3: Nova Proposta do Consumo de Energia e Modelagem da Rede Neural

Neste capítulo, é descrita a metodologia e a nova proposta utilizada para abordar o problema específico do consumo de energia associado ao protocolo *ALOHA puro*. É apresentada a dedução das fórmulas relacionadas ao consumo energético e a modelagem matemática que guiará a simulação do protocolo. A partir disso, detalha o processo de gerar uma base de dados robusta para aprimorar o desempenho da rede neural, detalhando também a implementação e treinamento do modelo.

Capítulo 4: Resultados Obtidos

Este capítulo destaca e analisa os resultados obtidos por meio da simulação e do treinamento da rede neural. Explora as descobertas significativas e avalia como esses resultados contribuem

para a compreensão do problema e para o alcance dos objetivos propostos.

Capítulo 5: Conclusão e Trabalhos Futuros

No último capítulo, são apresentadas as conclusões derivadas do trabalho realizado. São discutidas as implicações dos resultados obtidos e sugestões para futuros desenvolvimentos e pesquisas na área.

Capítulo 2

Revisão Teórica

“É bom ter livros de citações. Gravadas na memória, elas inspiram-nos bons pensamentos.”

– WINSTON CHURCHILL

Neste capítulo são apresentados os conceitos fundamentais para entendimento do trabalho. A primeira seção é destinada a redes de internet das coisas, apresentando a contextualização da área de estudo e os conceitos relacionados a redes de computadores e protocolos de comunicação, no final da seção são destacados os protocolos ALOHA, referentes à proposta deste trabalho. A segunda seção é destinada ao aprendizado de máquina, apresentando os fundamentos para elaboração e implementação de uma rede neural artificial.

2.1 Redes de Internet das coisas

A Internet das Coisas, do termo em inglês *Internet of Things* (IoT) representa uma inovação tecnológica que conecta dispositivos físicos ao mundo digital, permitindo a troca de dados e informações de maneira inteligente e integrada. Essa interconexão possibilita a criação de sistemas inteligentes e automatizados, nos quais objetos do cotidiano, equipamentos industriais e até mesmo vestíveis estão habilitados para coletar, transmitir e receber dados. A aplicabilidade da IoT abrange uma ampla gama de setores, desde a automação residencial e cidades inteligentes até a indústria 4.0 e a saúde conectada [9, 10, 11]. A interligação da IoT com as redes de computadores desempenha um papel crucial, proporcionando a infraestrutura necessária para a coleta, transmissão e processamento de dados entre os dispositivos, culminando na criação de um ecossistema interconectado que impulsiona a inovação e a eficiência em diversos domínios.

2.1.1 Comunicação sem fio

Comunicação sem fio refere-se à transferência de pacotes de dados sem a necessidade de uma conexão física por meio de cabos. Embora existam diversas formas de propagar ondas eletromagnéticas nesse contexto, a maioria dos sistemas modernos utiliza a propagação por meio de radiofrequência (RF) ou sinais de micro-ondas [12]. Ao contrário das comunicações em meios com conexões físicas, as comunicações via rádio apresentam desafios distintos e não proporcionam uma análise tão direta [13].

2.1.2 Redes sem Fio

As redes sem fio podem ser classificadas com base na presença ou ausência de uma infraestrutura. Redes infraestruturadas contam com uma estação base ou ponto de acesso para gerenciar as transmissões e fornecer acesso à rede cabeada. Já as redes sem infraestrutura, também conhecidas como as redes *ad hoc*, não dependem de uma infraestrutura central, permitindo que os dispositivos se autoconfigurem dinamicamente. Nesta seção as duas arquiteturas mais frequentes em redes sem fio serão abordadas.

Redes Infraestruturadas

Redes sem fio infraestruturadas são caracterizadas pela presença de uma estação base (BS, do inglês *Base Station*), ou como são mais conhecidas em redes WLAN, pontos de acesso (AP, do inglês *Access Point*). As estações bases têm a função de prover, via conexão sem fio, acesso à rede cabeada aos dispositivos móveis associados à rede sem fio [14]. Estes dispositivos devem encaminhar dados para essa estação, resultando em comunicação de único salto. Isso proporciona maior taxa de transmissão e menor atraso, mas pode ser custoso e impraticável em certos cenários, como monitoramento florestal ou situações militares. Exemplos de redes infra-estruturadas incluem o sistema de telefonia celular, redes Wi-Fi e Bluetooth.

Redes sem Infraestrutura

Em contraste às redes infraestruturadas, as redes *ad hoc* não necessitam da assistência de uma infraestrutura, ou seja, estas redes são compostas de dispositivos capazes de se autoconfigurar, dinamicamente, formando uma rede de múltiplos saltos. Em razão da inexistência de uma infraestrutura, os nós da rede devem exercer papéis de controle e demais tarefas essenciais

para a rede [14]. Nestas redes os nós podem se comunicar diretamente entre si, contanto que estejam no alcance de comunicação. Uma vez que um dispositivo não possua acesso direto ao destinatário, o nó depende da retransmissão por meio dos demais elementos da rede para se comunicar com o nó destino. Devido às capacidades de autoconfiguração e auto-organização, as redes *ad hoc* apresentam a vantagem de serem altamente flexíveis sendo, então, interessantes para situações emergenciais. Além do mais, a ausência de uma infraestrutura resulta em uma rede de custos mais baixos. Verifica-se, também, que a falta de um ponto de falha central (como é no casos das redes infraestruturadas) torna tais redes altamente robustas e, portanto, ideais para situações pós-desastres e aplicações militares [14].

Por outro lado, as redes *ad hoc* detêm taxas de transmissão mais baixas em relação às redes com infraestrutura, devido a falta de uma unidade central de controle, o que acentua a taxa de colisão de pacotes. A depender do protocolo empregado, ocorre também um aumento de sobre-escuta do canal e/ou sobrecarga nos pacotes de dados, além das retransmissões entre os nós implicarem em maiores atrasos fim-a-fim e ainda maior consumo energético. [15]

2.1.3 Redes de sensores sem fio

As redes de sensores sem fio (*WSN*, do inglês *Wireless Sensor Networks*) são redes *ad hoc*, formada por várias unidades, essas redes operam em ambientes hostis e são, geralmente, projetadas para durar o máximo de tempo sem a necessidade de intervenção humana, pois, em muitos casos é inviável realizar esta intervenção sendo, portanto, fundamental que os dispositivos sejam energeticamente eficientes. Fruto do investimento, da DARPA em redes *ad hoc* para fins táticos militares, as redes de sensores atualmente suportam uma ampla gama de aplicações como rastreamento de alvos, monitoramento ambiental e de saúde, sistemas autômatos de controle e exploração de ambientes hostis [16, 17].

2.1.4 Protocolos em Internet das Coisas

Protocolos, em redes de computadores, são definidos como regras, diretrizes e convenções com o objetivo de garantir a comunicação entre dispositivos em rede. Como existem diferentes modelos de protocolos e dispositivos, a maioria dos protocolos seguem uma arquitetura padrão, de forma a tornar viável uma comunicação entre diferentes dispositivos. Essa arquitetura segue a estrutura de camadas, na qual existem a camada de física, a camada de enlace, a camada de rede e a camada de aplicação [18].

- **Camada física:** Camada responsável por transportar informações entre duas máquinas, convertendo os bits de informações em sinais físicos, que podem ser transmitidos através de cabos, fibras ópticas ou ondas eletromagnéticas, sendo este último utilizado em comunicações sem fio. Em WSN, essa camada é responsável por captar os dados de fontes materiais, através de dispositivos físicos ou sensores como temperatura, umidade, GPS, entre outros [19].
- **Camada de enlace e controle de acesso ao meio:** Camada responsável pelo gerenciamento de como os dispositivos compartilham o canal de comunicação, por meio da criação de endereços físicos para identificação na rede. Em WSN, a camada de enlace e a camada física compõem a camada de percepção, responsável pelo controle de dispositivos, coleta de dados e transporte seguro das informações, direcionando para a camada de rede [19].
- **Camada de rede:** Camada responsável em tratar os dados coletados pela camada MAC e endereça-los à camada de aplicação. Essa camada utiliza diversas técnicas de roteamento para adaptar-se de acordo com a tecnologia empregada, como smartphones, Bluetooth, ZigBee, entre outras. Nesse contexto, um dispositivo de gateway na camada de rede recebe as informações coletadas pelos dispositivos sensores. Em seguida, ele encaminha esses dados para uma rede Ethernet ou a Internet, possibilitando o armazenamento das informações em um banco de dados do sistema de destino ou na nuvem [20].
- **Camada de aplicação:** Camada responsável por fornecer os diferentes tipos de serviços requeridos pelas camadas anteriores. Esta camada oferece também a estrutura para desenvolvimento de várias aplicações, o que tornou dispositivos IoTs úteis e versáteis em diferentes áreas como residencial, agricultura, médica, indústria, entre outros [10].

2.1.5 Controle de Acesso ao Meio

Em ambientes de redes sem fio, um dos focos primordiais reside na exploração da camada de Controle de Acesso ao Meio (MAC, do inglês *Medium access control*). Esta camada desempenha um papel crucial ao garantir o funcionamento eficiente em redes onde o meio de transmissão é compartilhado [21]. Os protocolos desenvolvidos para essa camada desempenham uma função vital ao assegurar uma distribuição equitativa e eficaz da largura de banda disponível. Considerando que os dispositivos em redes sem fio frequentemente operam com recursos de energia

limitados, a consciência do consumo energético torna-se fundamental para os protocolos MAC. Assim, uma das principais responsabilidades desses protocolos é mitigar colisões e interferências entre transmissões de dados, pois tais eventos implicam em retransmissões e, conseqüentemente, em um aumento no consumo energético dos dispositivos [15].

2.1.6 Protocolos MAC

Um protocolo MAC é definido como um conjunto de diretrizes e regras que regulam o acesso dos dispositivos ao meio compartilhado, o que permite a comunicação de forma ordenada e eficiente entre os elementos da rede [22].

Elaborar um protocolo MAC para redes sem fio envolve balancear diferentes propriedades para atingir o comportamento esperado, sendo assim, não é possível aprimorar uma métrica sem que outra seja prejudicada, conhecido como *trade-off*, em que é necessário definir quais métricas são mais importantes no contexto inserido. Em [22], são apresentadas as principais métricas comparativas em protocolo sem fio, entre elas, são destacadas:

- **Vazão**, do inglês *throughput*: É a fração da capacidade do canal utilizada para transferência de dados. A vazão indica a taxa de transmissão ou seja, a quantidade de pacotes de dados que o protocolo consegue transmitir em relação ao tempo. Dessa forma, maximizar a vazão de dados é o principal objetivo dos protocolos MAC.
- **Justiça**: Os protocolos devem realizar uma divisão justa da banda de modo que nenhum nó da rede seja priorizado. Essa propriedade pode ser re-definida para protocolos com suporte a multimídia em que a justiça envolve a divisão proporcional da banda.
- **Atraso**, do inglês *delay*: O atraso é definido como o tempo médio que um pacote permanece na fila do protocolo MAC, ou seja, o tempo entre a requisição de uma transferência e a efetivação da transferência dos dados. Como esta métrica varia não somente de acordo com o protocolo empregado, mas também com as características do tráfego é essencial que ao compará-la os protocolos utilizem as mesmas condições.
- **Estabilidade**: Como em redes cabeadas, os protocolos MAC sem fio também devem ser capaz de resistir a picos de cargas maiores que a capacidade máxima de transmissão mesmo que a longo prazo as aplicações requeiram um volume de comunicação bem menor que esta capacidade.

- Robustez contra desvanecimento: Como abordado no início do capítulo os desvanecimentos em meio são aleatórios, além disso, esse meio é bastante propenso a erros. Esses fatores podem tornar instável a comunicação entre dois nós da rede. Dessa forma, os protocolos MAC devem ser resistentes a tais falhas evitando instabilidades em seu comportamento.
- Eficiência Energética: Como a maioria dos dispositivos sem fio são equipados com baterias, é importante que os protocolos tenham consciência de seus consumos energéticos e poupem energia. Esta propriedade é bem acentuada em redes de sensores sem fio na qual em muitas é difícil ou impossível de realizar a troca de baterias dos sensores. [5]
- Suporte a Multimídia: Com a crescente demanda das aplicações por transmissões de áudio e vídeo em adição aos dados [23], é necessário que os protocolos MAC ofereçam suporte as diferentes aplicações multimídia se empenhando, também, em tratar as diferentes restrições de atrasos destas.

Em contrapartida alguns trabalhos, como em [21, 24], apontam fatores que deterioram as métricas listadas anteriormente, entre eles :

- Colisões: Colisões ocorre quando um ou mais nós transmitem simultaneamente interferindo entre si. Colisões enquadram como um dos principais fatores no consumo energético de um protocolo devido a necessidade de retransmissão.
- Sobrecarga, do inglês *overhead*: Geralmente, protocolos MAC reservam uma fração de pacote, ou mesmo, pacotes inteiros para realizar o controle do acesso ao meio. A sobrecarga é então definida como todo conteúdo sem dados de aplicação que é transmitido e/ou recebido em um protocolo [24]. O uso demasiado desse controle pode representar a perda de capacidade, aumento de latência e piora na eficiência energética.
- Sobre-escuta, do inglês *overhearing*: A sobre-escuta se dá quando um nó recebe e processa pacotes não destinados a ele, mesmo que esta atividade seja realizada de forma parcial. A sobre-escuta representa principalmente um gasto energético, visto que o dispositivo poderia polpar energia ao não receber o pacote que não lhe é destinado [24].
- Escuta Ociosa, do inglês *idle listening*: Em diversos protocolos, os nós devem sensorar o canal para receber dados endereçados a si. Quando não há tráfego no canal, é definido que o nó está em modo de escuta ociosa. Este fator pode representar de 50% a 100% do

consumo energético de um protocolo, devido a consumo de manter o sensor operante mas sem transmitir ou receber pacote de dados [21].

2.1.7 O protocolo ALOHA Puro

O protocolo *Aloha* é uma abordagem *Ad Hoc* na arquitetura de redes de comunicação sem fio, sendo de fundamental importância na história do desenvolvimento de redes de comunicação sem fio. Foi concebido por Norman Abramson e os pesquisadores do Laboratório de Pesquisa de Sistemas de Comunicação da Universidade do Havaí no início da década de 1970 [25], no qual visavam uma solução eficiente para a transmissão de pacotes de dados em uma rede de rádio. Diferente de sistemas convencionais, que funcionam com agendamento de tempo ou divisão da frequência para transmissão, o *Aloha* apresentou um conceito inovador para sua época, que consistia no acesso ao canal permitido a qualquer momento, sem a necessidade de uma estrutura de tempo predefinida.

Em sua versão pura, que consiste em tempo contínuo, a probabilidade de sucesso de transmissão de um nó está na junção das probabilidade de um nó transmitir e nenhum outro mais transmitir durante o momento, como demonstrado nas equações abaixo.

$$P_{\text{Sucesso de transmissão de um nó}} = P_{\text{Nó transmite}} \cdot P_{\text{Nenhum nó transmite em } [t_{0-1}, t_0]} \cdot P_{\text{Nenhum nó transmite em } [t_0, t_{0+1}]} \quad (2.1)$$

$$P_{\text{Sucesso}} = N \cdot p \cdot (1 - p)^{N-1} \cdot (1 - p)^{N-1} \quad (2.2)$$

A probabilidade de sucesso é dada por

$$P(\text{Sucesso}) = N \cdot p \cdot (1 - p)^{2N-2}. \quad (2.3)$$

A partir disso, calcula-se a derivada de $P(\text{Sucesso})$ em relação a p para obter o p' ideal que maximize a taxa de *Throughput*

$$\frac{d}{dp} P(\text{Sucesso}) = N \cdot (1 - p)^{2N-2} - N \cdot p \cdot (2N - 2) \cdot (1 - p)^{2N-3}. \quad (2.4)$$

Ao igualar a derivada a zero e isolando $N(1-p)^{2N-3}$, se obtém,

$$N(1-p)^{2N-3} [(1-p) - p(2N-2)] = 0. \quad (2.5)$$

Como $0 < p < 1$, $(1-p) \neq 0$. Logo, é possível reduzir a expressão,

$$1-p = p(2N-2), \quad (2.6)$$

em que resolvendo a equação, a solução para p' ideal é

$$p' = \frac{1}{2N-1}. \quad (2.7)$$

Para encontrar a taxa de transmissão (*Throughput*), calcula-se o limite de N tendendo ao infinito em $P(\text{Sucesso})$ com p' ideal:

$$\lim_{N \rightarrow \infty} P(\text{Sucesso}) = N \cdot p' \cdot (1-p')^{2N-2} = \left(\frac{N}{2N-1} \right) \cdot \left[1 - \frac{1}{2N-1} \right]^{2N-2} \quad (2.8)$$

Pelo limite notável $\lim_{x \rightarrow \infty} \left(1 - \frac{1}{x}\right)^x = \frac{1}{e}$, se obtém o calculo final da taxa de transmissão:

$$P(\text{Sucesso}) = \frac{1}{2} \cdot \frac{1}{e} = \frac{1}{2e} \approx 0,1839 \quad (2.9)$$

2.1.8 O protocolo *Slotted ALOHA*

Em sua versão *slotted*, que consiste na divisão do tempo em *slots* para a transmissão, conforme é ilustrado na Figura [2.1](#).

A probabilidade de sucesso de transmissão de um nó está na junção das probabilidade de um nó transmitir e nenhum outro mais transmitir em determinado *slot*, como demonstrado nas equações

$$P_{\text{Sucesso de transmissão de um nó}} = P_{\text{Nó transmite}} \cdot \quad (2.10)$$

$$P_{\text{Nenhum nó transmite em determinado slot}}$$

$$P_{\text{Sucesso}} = N \cdot p \cdot (1-p)^{N-1}. \quad (2.11)$$

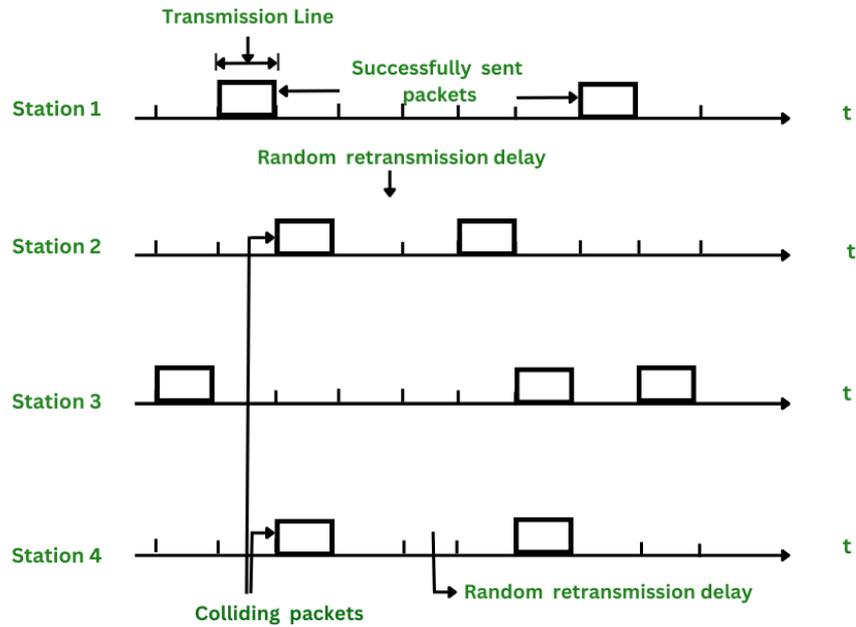


Figura 2.1: Tentativas de transmissão e retransmissão devido a colisão de pacotes no protocolo *Slotted ALOHA*. Fonte: [link](#)

A probabilidade de sucesso é dada por

$$P(\text{Sucesso}) = N \cdot p \cdot (1 - p)^{N-1}. \quad (2.12)$$

A partir disso, calcula-se a derivada de $P(\text{Sucesso})$ em relação a p para obter o p' ideal que maximize a taxa de *Throughput*,

$$\frac{d}{dp} P(\text{Sucesso}) = N \cdot (1 - p)^{N-1} - N \cdot p \cdot (N - 1) \cdot (1 - p)^{N-2}. \quad (2.13)$$

Ao igualar a derivada a zero e isolando $N(1 - p)^{N-1}$, se obtém

$$N(1 - p)^{N-1} [(1 - p) - p(N - 1)] = 0. \quad (2.14)$$

Como $0 < p < 1$, $(1 - p) \neq 0$. Logo, é possível reduzir a expressão

$$1 - p = p(N - 1). \quad (2.15)$$

Resolvendo a equação, a solução para p' ideal é

$$p' = \frac{1}{N}. \quad (2.16)$$

Para encontrar a taxa de transmissão (*Throughput*), calcula-se o limite de N tendendo ao infinito em $P(\text{Sucesso})$ com p' ideal,

$$\lim_{N \rightarrow \infty} P(\text{Sucesso}) = N \cdot p' \cdot (1 - p')^{N-1} = \left(1 - \frac{1}{N}\right)^{N-1}. \quad (2.17)$$

Pelo limite notável $\lim_{x \rightarrow \infty} \left(1 - \frac{1}{x}\right)^x = \frac{1}{e}$, se obtém o calculo final da taxa de transmissão:

$$P(\text{Sucesso}) = \frac{1}{e} \approx 0,3678 \quad (2.18)$$

2.2 Aprendizado de máquina

2.2.1 Visão geral

O aprendizado de máquina é um campo da inteligência artificial que revoluciona a forma como os sistemas computacionais podem adquirir conhecimento e melhorar seu desempenho ao longo do tempo. Em seu contexto mais amplo, visa desenvolver algoritmos que capacitam as máquinas a aprender a partir de dados e experiências, sem depender de uma programação explícita para cada tarefa. Essa abordagem contrasta com métodos tradicionais de programação, onde as instruções são fornecidas explicitamente para a execução de tarefas específicas.

A Figura [2.2](#) ilustra a diferença na abordagem da solução de um problema entre modelagem tradicional e uso de aprendizado de máquina.

A criação de modelos de aprendizado de máquina envolve a exposição desses modelos a conjuntos de dados relevantes, permitindo que eles identifiquem padrões, façam previsões ou tomem decisões com base nas informações disponíveis. A capacidade de generalizar a partir desses dados é uma característica crucial do aprendizado de máquina, permitindo que os modelos se apliquem efetivamente a novos cenários.

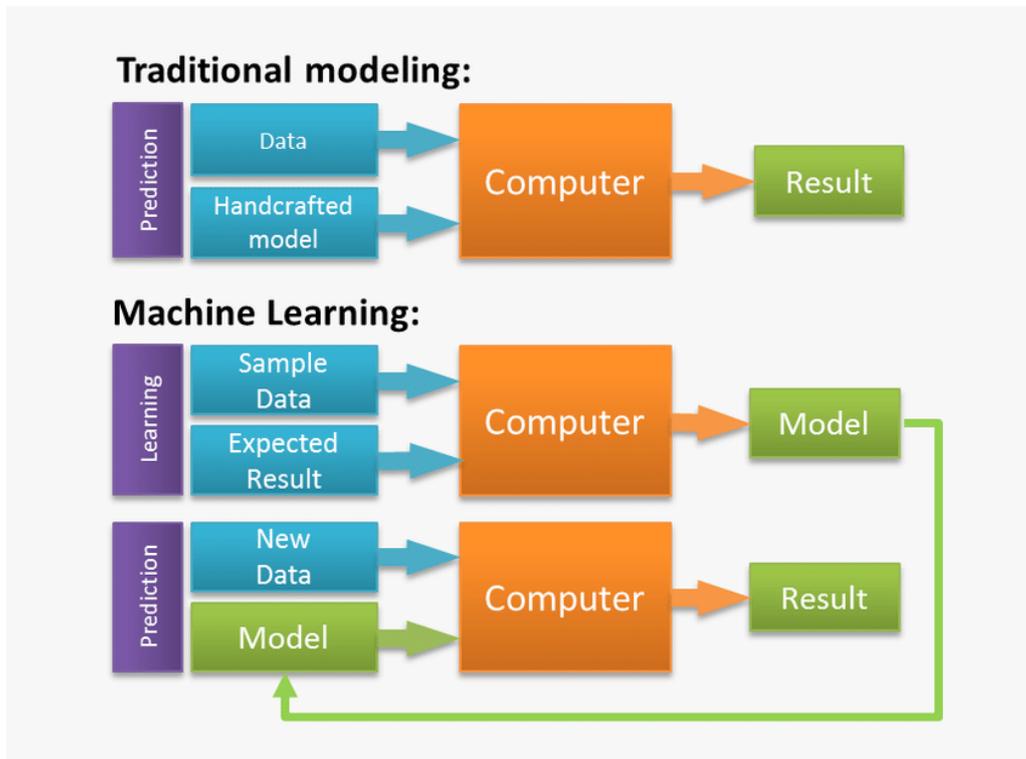


Figura 2.2: Diferença entre modelagem tradicional e aprendizado de máquina [1]

A relevância do aprendizado de máquina está intrinsecamente ligada à sua capacidade de lidar com problemas complexos e variáveis em várias disciplinas, oferecendo soluções poderosas na análise de dados, reconhecimento de padrões, processamento de linguagem natural ou tomada de decisões autônomas. Sua aplicação se estende a setores como saúde, finanças, logística, ciência de dados e muito mais, capacitando sistemas a realizar tarefas sofisticadas e extrair informações significativas de grandes conjuntos de dados. Como resultado, o aprendizado de máquina tornou-se uma ferramenta central na transformação digital e na busca por inovações em diversas áreas [26].

2.2.2 Aprendizado supervisionado

O aprendizado supervisionado é uma vertente do aprendizado de máquina no qual utiliza um conjunto de dados previamente rotulados, ou seja, dentro do conjunto de dados existe a resposta definida [27]. Dessa forma, o modelo é treinado com os dados de entrada e saída para que aprenda, com base nos dados recebidos na entrada, como atingir a saída esperada. Essa abordagem tem sido amplamente aplicada em problemas de classificação, regressão e detecção de padrões, tornando-se uma ferramenta essencial em uma variedade de domínios.

2.2.3 Redes neurais artificiais

Nessa sessão são apresentados os conceitos fundamentais para o desenvolvimento de uma rede neural artificial.

Neurônio

O neurônio é a unidade básica em uma rede neural artificial. Inspirado no neurônio biológico, ele recebe entradas ponderadas, aplica uma função de ativação e produz uma saída, como ilustrado na Figura 2.3. Os pesos associados às entradas são ajustados durante o treinamento, permitindo que o neurônio aprenda a representar padrões complexos nos dados.

O processo de sinapse ocorre na ligação entre neurônio, no qual a saída de um neurônio de uma camada anterior é utilizada como entrada para o neurônio posterior.

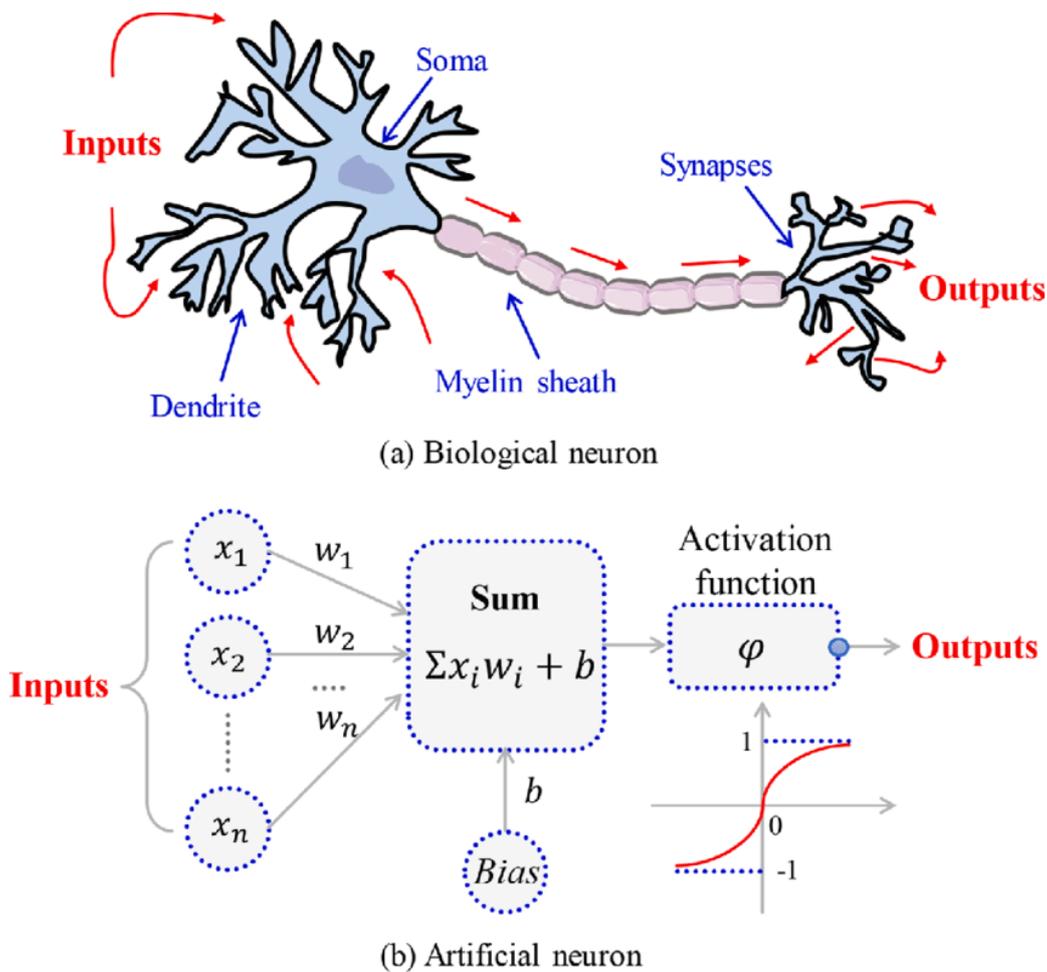


Figura 2.3: Comparação entre neurônio biológico e neurônio artificial. Fonte: [2]

Gradiente descendente

O Gradiente descendente é uma ferramenta otimizadora fundamental em aprendizado de máquina, cuja função é ajustar os pesos da rede de maneira a minimizar a função de custo. O gradiente descendente utilizado em redes neurais utiliza o fundamento de mínimo local e global de cálculo, na derivação da função em direção ao mínimo.

O gradiente descendente estocástico (*Stochastic Gradient Descent (SGD)*) é um tipo de abordagem na qual a atualização do gradiente na função de custo é executada a cada amostra de treinamento. Por conta disso, essa abordagem é mais rápida, porém com a desvantagem de poder atingir o mínimo local mais cedo [28]. Na literatura, recomenda-se o uso de algoritmos iterativos de otimização, entre eles, os mais destacados e difundidos são:

- **Momentum:** O método *Momentum* é uma técnica popular de otimização em aprendizado de máquina, especialmente em problemas de SGD. Proposto originalmente por Boris T. Polyak em 1964 [29], como forma de acelerar a convergência do algoritmo de otimização, especialmente em cenários nos quais o gradiente pode variar consideravelmente ou conter ruídos.

A proposta fundamental do *Momentum* é introduzir uma inércia no processo de atualização dos pesos do modelo. Isso é alcançado ao adicionar uma fração do vetor de atualização anterior ao vetor de atualização atual, dessa forma, ao atualizar os parâmetros históricos, o método leva em consideração não somente o gradiente atual mas também os anteriores, assumindo valores probabilísticos entre 0 e 1 para determinar a relevância dos gradientes anteriores. De modo geral, é considerado um valor em torno de 0,9 [28].

- **Adagrad:** Introduzida em [30] como uma abordagem adaptativa para otimização estocástica, o método *Adagrad* utiliza um coeficiente de aprendizado dinâmico, que é atualizado a cada etapa, como forma de eliminar o problema consequente do coeficiente de aprendizado constante utilizado no método gradiente descendente. A função principal do *Adagrad* é otimizar a convergência do modelo ajustando as taxas de aprendizado de acordo com a frequência das atualizações anteriores de cada parâmetro. Isso significa que parâmetros que recebem atualizações mais frequentes têm suas taxas de aprendizado reduzidas, enquanto parâmetros menos frequentemente atualizados têm taxas de aprendizado aumentadas.

Entretanto, esse método possui limitações notáveis com relação a acumulação contínua

dos quadrados dos gradientes ao longo do treinamento, o que pode resultar em taxas de aprendizado extremamente pequenas, dessa forma, gerando uma convergência prematura ou até mesmo uma estagnação do treinamento. Além disso, é necessário definir um valor inicial para o coeficiente de aprendizado.

- **Adadelta:** Proposto originalmente em [31] como uma extensão do *Adagrad*, com o objetivo de corrigir as limitações relacionadas ao coeficiente de aprendizado. O método *Adadelta* elimina as duas principais desvantagens do *Adagrad*, relacionadas a necessidade de inicializar com algum valor aleatório o coeficiente de aprendizado e deste se aproximar a zero com o tempo, devido ao crescimento da matriz de gradientes resultando na diminuição do valor do coeficiente de aprendizado. Para solucionar essas limitações, o método *Adadelta* define a soma dos quadrados do gradiente em uma certa proporção e define como uma constante, assim como no método *Momentum*.
- **RMSProp:** Sendo uma variação do método *Adadelta*, o *RMSProp* foi proposto por Geoff Hinton em suas notas de aula, em que utiliza o parâmetro do coeficiente de aprendizado considerando o valor do parâmetro como 0,9 e o valor do coeficiente de aprendizado como 0,001 para obtenção de melhores resultados [32].
- **Adam:** O método *Adaptive Moment Estimation* (Adam), proposto em [33], combina as vantagens dos métodos *Adadelta* e *RMSProp* de atualização do coeficiente de aprendizado por iteração, ao levar em consideração os quadrados dos gradientes anteriores, assim como os gradientes não quadrados, como *Momentum*. Isso permite ao algoritmo se adaptar dinamicamente a diferentes características dos dados e dos parâmetros do modelo, ajustando a taxa de aprendizado de forma individual para cada parâmetro. Essa característica é particularmente útil em cenários onde diferentes parâmetros possuem escalas ou comportamentos distintos.

Em resumo, o Adam se destaca como um método de otimização versátil, amplamente empregado em treinamento de redes neurais, proporcionando uma convergência eficiente e adaptativa em uma variedade de tarefas de aprendizado de máquina.

A Figura 2.4 expressa o comportamento dos gradientes apresentados nesta seção na obtenção do ótimo global para a função de *benchmark* Griewank [3], no qual é possível observar um melhor desempenho do método ReLU.

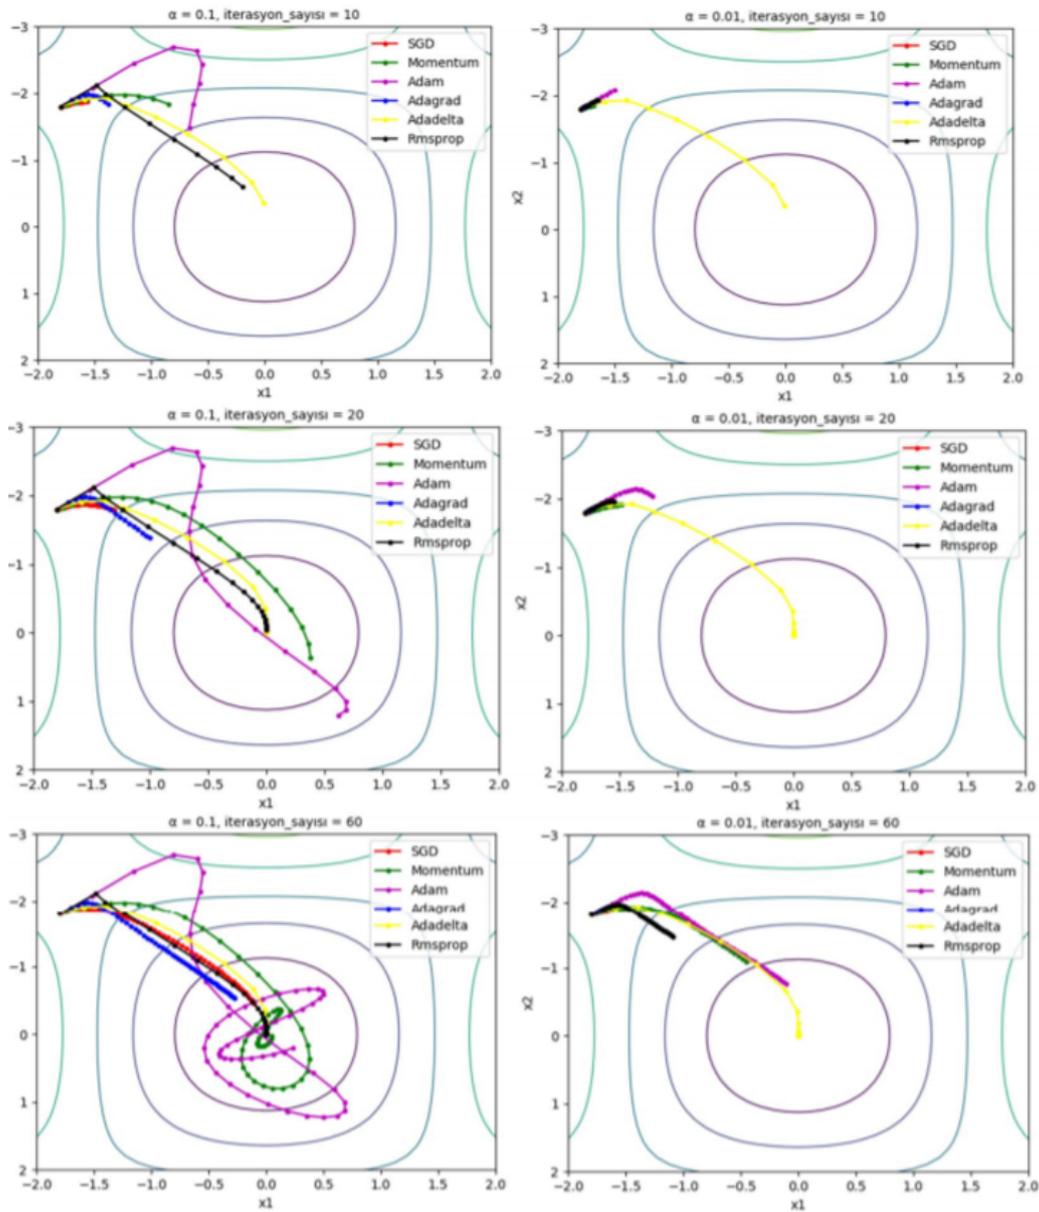


Figura 2.4: Gráfico comparativo da convergência entre os métodos, SGD, Momentum, Adam, Adagrad, Adadelta e Rmsprop sob a função Griewank, coeficiente de aprendizado α variando entre 0,1 (100%) e 0,01 (10%) e número de iterações variando entre 10, 20 e 60 [3].

Função de ativação

A Função de Ativação determina a saída de um neurônio, introduzindo não linearidades na rede. Diferentes funções de ativação, como a sigmoide e a ReLU, têm impactos significativos no desempenho da rede. Essas funções analisam os dados apresentados pelo gradiente descendente, ao classificar o grau de relevância da informação para a rede neural e definir se essa informação irá ativar ou não o neurônio relativo.

- **Função sigmoide:** Sigmoide é uma função de ativação real, não-linear, diferenciável

limitada, utilizada em redes neural *feed-forward*, em que recebe como entrada valores reais e é definida pela equação

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2.19)$$

- **ReLU:** Função de Unidade Linear Retificada (ReLU) foi proposta originalmente em [34], sendo a função de ativação mais utilizada em aplicações de aprendizado, por apresentar os melhores resultados, representada pela equação

$$f(x) = \max(0, x) = \begin{cases} 0, & \text{se } x < 0 \\ x, & \text{se } x \geq 0, \end{cases} \quad (2.20)$$

no que representa uma função quase linear, dessa forma, preservando as propriedades de modelos lineares. Essa característica oferece vantagem no uso da *ReLU* por não realizar cálculos exponenciais, o que facilita a otimização do gradiente descendente [35].

Taxa de aprendizado

A Taxa de Aprendizado influencia a rapidez com que os pesos da rede são ajustados durante o treinamento. Escolher uma taxa de aprendizado apropriada é uma consideração crítica, pois uma taxa muito alta pode resultar em convergência instável, enquanto uma taxa muito baixa pode levar a um treinamento lento ou estagnado [28].

Épocas de treinamento

Épocas de Treinamento indicam o número de vezes que todo o conjunto de treinamento é apresentado à rede neural durante o processo de treinamento.

Essa quantidade de épocas (ou tempo) de treinamento deve ter um valor ótimo para ajustar eficientemente a rede, pois, poucas épocas não serão capazes de treinar a rede por completo, gerando uma rede sob-ajustada (*underfit*). Entretanto, treinar uma rede por muitas épocas também pode ocasionar da rede estar sobre-ajustada (*overfit*), em que a rede começa a "decorar" os resultados dos dados de treinamento e perde a capacidade de generalizar, resultando em um baixo aproveitamento em dados em que não estejam na base de treinamento. A Figura 2.5 apresenta um comparativo entre previsões geradas por um rede *underfit*, uma *overfit* e uma com uma quantidade ótima de épocas de treinamento.

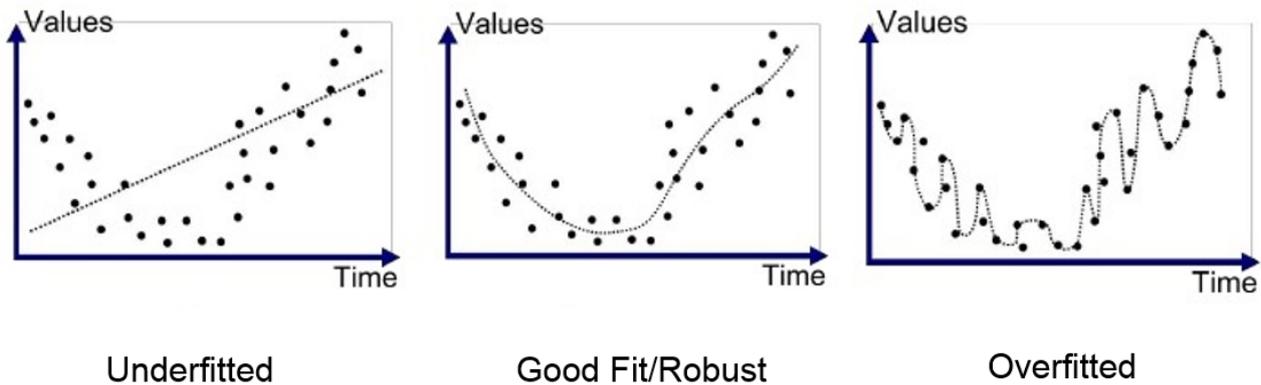


Figura 2.5: Gráficos comparativos entre redes neurais com diferentes treinamentos. Fonte: [Link](#)

2.2.4 Métricas de avaliação

Para avaliação dos modelos de rede neural artificial, são utilizados diferentes métodos de métricas para comparar o resultado obtido com o esperado, e dessa forma, julgar a eficiência do modelo. Para modelos de regressão, isto é, modelos que tem como saída números contínuos, são necessárias métricas estatísticas de regressão, entre elas, as mais destacadas são: [\[36\]](#)

- **Mean Squared Error (MSE):** O MSE calcula a média dos quadrados das diferenças entre as previsões do modelo e os valores reais. Portanto quanto menor o MSE, mais indica que o modelo está em ajustar-se aos dados. No entanto, como a métrica é sensível a *outliers*, pode ser influenciada por valores extremos.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.21)$$

- **Mean Absolute Error (MAE):** Ao contrário do MSE, o MAE calcula a média das diferenças absolutas entre as previsões e os valores reais. Isso implica que o MAE é menos sensível a *outliers*, fornecendo uma visão mais robusta da precisão do modelo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.22)$$

- **R-squared:** (R^2) O Coeficiente de Determinação (R^2) é uma medida que varia entre 0 e 1, indicando a porcentagem da variabilidade nos dados que é explicada pelo modelo. Um resultado mais próximo de 1 indica que o modelo se ajusta bem aos dados, enquanto valores mais baixos indicam menor adequação.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.23)$$

- **Evaluate Variance Score: (EVS)** Semelhante ao R^2 , o EVS varia de 0 a 1, representando a fração da variação total nos dados que é explicada pelo modelo. No entanto, ao contrário do R^2 , o EVS pode assumir valores negativos, indicando uma performance inferior à simples média dos dados.

$$EVS = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.24)$$

Em todas métricas, y_i indica o valor real, \hat{y}_i indica o valor previsto pelo modelo e \bar{y} indica a media de todos os valores reais.

Essas métricas fornecem uma visão abrangente da qualidade do modelo, avaliando diferentes aspectos, como a magnitude dos erros, a capacidade de explicação e a variação explicada nos dados. Importante destacar a utilização de mais de uma métrica para avaliar a robustez do modelo.

2.2.5 MultiLayer Perceptron

O Perceptron de Múltiplas Camadas (MLP) é uma arquitetura de rede neural composta por camadas de neurônios, incluindo uma camada de entrada, uma ou mais camadas ocultas, do inglês *Hidden Layer*, e uma camada de saída. Por ser uma rede multicamada, a ligação entre neurônios consegue tornar um MLP capaz de realizar projeções ou classificações de inferência, reduzindo a ordem de complexidade assintótica de técnicas mais complexas [37], e consequentemente economizando memória e energia, o que a torna atrativa para aplicações com limitações de *hardware* como o caso de IoT [4].

O desempenho de uma rede neural está relacionado diretamente com os valores estabelecidos de seus parâmetros e hiper-parâmetros. Os parâmetros consistem nos dados de entrada, o que pode ser influenciado pelo tratamento destes. Os hiper-parâmetros constituem ajustes que influenciam a etapa de treinamento, como: O número de camadas de neurônios, o algoritmo gradiente descendente, a função de ativação dos neurônios, a taxa de aprendizado, o número de épocas de treinamento, entre outros [37].

2.3 Trabalhos relacionados

Este trabalho teve como trabalhos relacionados a dissertação de mestrado [8] e a tese de doutorado [4].

A dissertação de mestrado propôs um modelo de consumo de energia em função de parâmetros das camadas física e de enlace, que modela o consumo energético dos dispositivos que operam nessas redes, no qual foram utilizados os protocolos MAC *Slotted Aloha* e *CSMA/CA* para a modelagem da comunicação entre os nós.

A tese de doutorado propôs a criação de um método baseado em aprendizado de máquina que combina as informações operacionais de dois algoritmos de controle de consumo de energia para os protocolos *CSMA/CA*, *Slotted Aloha*, protocolos de referência usados na camada de enlace nas importantes tecnologias Wi-Fi e ZigBee. O método aprende o comportamento de operacionalização de múltiplas variáveis de camada física (PHY) e de enlace (MAC) para diferentes dispositivos e protocolos, contribuindo para uma maior eficiência energética durante as transmissões. Outra contribuição foi uma Rede Neural Artificial codificadas dentro do sensor agregando inteligência ao processo de transmissão de dados e tornando-o capaz de entender dinamicamente o estado atual da rede e manipular de forma autônoma variáveis das camadas PHY e MAC na busca de minimizar o custo de energia durante cada transmissão.

2.4 Resumo do capítulo

Neste capítulo foi realizado a revisão de literatura sobre as áreas de redes IoT e aprendizado de máquina, necessárias para a contextualização e referência para o próximo capítulo. Na primeira seção, focada em redes de computadores, foi introduzido o contexto de Internet das Coisas e suas aplicações em áreas como saúde e indústria. A partir disso, foram detalhados os conceitos fundamentais de redes sem fio, como a forma de propagação e as categorias de redes infraestruturadas e não-estruturadas (ou *Ad Hoc*).

Com ênfase em redes Ad Hoc para Internet das Coisas, este capítulo apresenta a visão geral de redes de sensores em fio, assim como a estrutura das camadas física, percepção, rede e aplicação. Esse embasamento é importante para entendimento das limitações e desafios existentes no processo de otimização dos protocolos em redes IoT.

Ao final desta seção, foram apresentados os protocolos de comunicação *Aloha puro* e *Aloha Slotted*. A versão pura é o principal objeto de estudo deste trabalho, no qual foi detalhado,

através de cálculos matemáticos, o problema da baixa taxa de transmissão, devido a sua probabilidade de acesso, ponto que será importante para o desenvolvimento da proposta no próximo capítulo.

Na segunda seção, focada em aprendizado de máquina, foi introduzido a contextualização sobre a área e suas aplicações, sobretudo em problemas que envolvem previsões, que é o caso deste trabalho. Para isso, foi detalhado o processo do aprendizado supervisionado, que envolve o conhecimento prévio das variáveis de entrada e de saída, para que a rede possa aprender o padrão.

Este estudo apresentou os componentes básicos para a construção de uma rede neural artificial, como a estrutura de um neurônio e a forma como realiza o cálculo com utilização de entradas, pesos e vieses. Sobre gradiente descendente, foram apresentados 5 algoritmos de otimização do gradiente, avaliando as vantagens e desvantagens de cada um. Foram apresentadas as funções de ativação, foram destacadas as funções sigmoide e ReLU, assim como os hiperparâmetros de taxa de aprendizado e épocas de treinamento, relevantes para a eficiência do treinamento, para evitar os problemas de *underfit* e *overfit*.

Este capítulo também apresentou as principais métricas de avaliação de regressão de rede neural, que serão utilizadas em capítulos futuros, devido a sua importância em avaliar a eficiência e precisão do modelo. Por último, foi apresentada a arquitetura MultiLayer Perceptron e como sua economia de memória e energia a torna indicada para aplicações em dispositivos IoT.

Por fim, foram apresentados os principais trabalhos relacionados, no qual este trabalho teve como ponto de partida e base para desenvolver a proposta de solução.

Capítulo 3

Nova Proposta do Consumo de Energia e Modelagem da Rede Neural

“Você deve aproveitar os pequenos desvios. Ao máximo. Porque é onde você encontrará coisas mais importantes do que aquilo que você realmente deseja.”

– YOSHIHIRO TOGASHI

Este capítulo descreve a metodologia empregada para a otimização do custo energético do protocolo *Aloha puro*. Inicialmente foi necessário desenvolver a modelagem matemática do custo energético de um nó da rede, através das fórmulas físicas presentes nos trabalhos relacionados e propor a modelagem para o consumo de energia de um ou mais saltos. Seguidamente, a partir da modelagem desenvolvida na etapa anterior, serão geradas amostras para o conjunto de treinamento para a rede neural, conforme descrito na Figura 3.1.

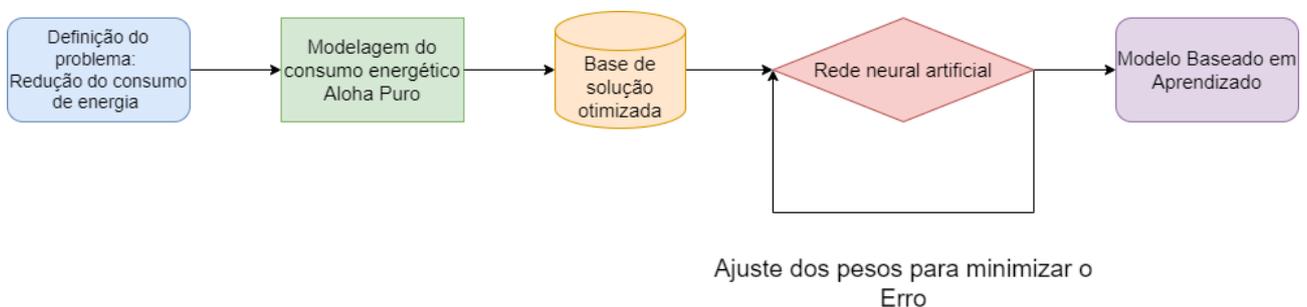


Figura 3.1: Fluxograma das etapas da metodologia

3.1 Modelo de Consumo de Energia (MCE)

Essa etapa consiste em desenvolver uma modelagem matemática a partir das fórmulas da energia consumida para realização de um salto com retransmissão apresentada em [38].

Inicialmente, a partir dos estudos propostos por [38], o consumo de energia (E_p) para o envio de um pacote é a soma entre a energia utilizada na transmissão E_{Tx} e a energia utilizada para recepção E_{Rx} , assim

$$E_p = E_{tx} + E_{rx}. \quad (3.1)$$

Em que E_{Tx} e E_{Rx} são formuladas ,respectivamente, em [39] por

$$E_{Tx} = T_{start} \cdot P_{start} + \frac{N_b}{R} \cdot (P_{txElec} + P_{amp}), \quad (3.2)$$

$$E_{Rx} = T_{start} \cdot P_{start} + \frac{N_b}{R} \cdot P_{rxElec}. \quad (3.3)$$

Em que N_b é o numero de bits por pacote medido em *bits*, R é a taxa de transmissão de dados em *bits/segundo*, P_{txElec} é a potência para alimentação do circuito de transmissão em *mW*, P_{rxElec} é a potência para alimentação do circuito de recepção em *mW*, T_{start} é o tempo de inicialização do circuito em μs e P_{start} é a potência necessária para inicialização em *mW*. P_{amp} é definida como a potência para amplificação do sinal na transmissão em *mW*, dada por

$$P_{amp} = \alpha_{amp} + \beta_{amp} \cdot P_t, \quad (3.4)$$

em que α_{amp} é o nível constante de potência em *mW* e β_{amp} é uma constante de proporcionalidade da potência de transmissão P_t .

Para obter o consumo médio de energia por bit para uma transmissão para um salto com sucesso, é necessário dividir o consumo de energia para transmissão de um pacote pelo número de bits (N_b) deste pacote. Dessa forma, define-se E_b o consumo de energia por bit (*J/bit*) como sendo

$$E_b = \frac{E_p}{N_b} = E_c + K_1 \cdot P_t, \quad (3.5)$$

em que E_c e K_1 são, respectivamente,

$$E_c = \frac{2T_{\text{start}} \cdot P_{\text{start}}}{N_b} + \frac{P_{\text{tx_elec}} + P_{\text{rx_elec}} + \alpha_{\text{amp}}}{R}, \quad (3.6)$$

$$K_1 = \frac{\beta_{\text{amp}}}{R}. \quad (3.7)$$

A partir das equações 3.1 a 3.7, deu-se início ao estudo da modelagem para o protocolo *Aloha puro*, com base nos trabalhos propostos em [8]

Com a modelagem proposta por [38] para um canal com perdas, a probabilidade de sucesso de transmissão de um pacote com N_b bits é $p_l(\gamma) = (1 - \text{BER}(\gamma))^{N_b}$, em que $\text{BER}(\gamma)$ é a taxa de erro de bits em função da relação sinal-ruído (γ), como descrito em [40]. A partir daqui, nessa probabilidade será também multiplicada pela probabilidade de acesso ao meio bem-sucedido de um nó no protocolo *Aloha puro*, que é dada por

$$\delta(n) = p(1-p)^{n-2}(1-p)^{n-2}, \quad (3.8)$$

em que p é a probabilidade de um nó transmitir e n o número de nós na rede.

Como demonstrado no Capítulo 2, a probabilidade de transmissão ideal p' para *aloha puro* é $1/(2n-1)$, segundo Eq. [2.7], logo alterando a Eq. [3.8], obtém-se

$$\delta(n) = \frac{1}{2n-1} \left(1 - \frac{1}{2n-1}\right)^{n-2} \left(1 - \frac{1}{2n-1}\right)^{n-2} = \frac{1}{2n-1} \left(1 - \frac{1}{2n-1}\right)^{2n-4}. \quad (3.9)$$

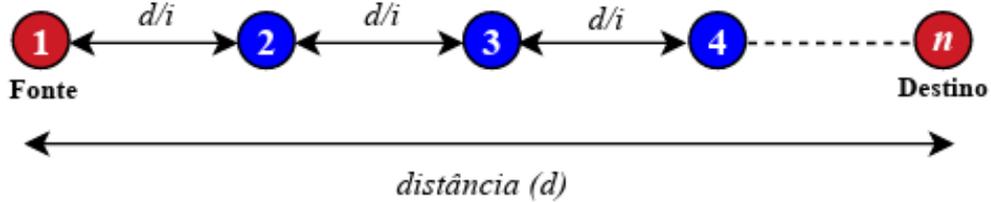


Figura 3.2: Rede linear com N nós equidistantes [4]

Conforme a Figura [3.2], d indica a distância total entre o nó *fonte* e o nó *destino*, e i indica o número de saltos, onde a quantidade de nós é igual à quantidade de saltos acrescida de um. Assim, define-se que $\frac{d}{i}$ é a distância por salto entre nós. Substituindo n na Eq. [3.10] por $(i+1)$ para obter a probabilidade de acesso ao meio com sucesso de um nó em função de i , obtém-se

$$\delta = \frac{1}{2(i+1)-1} \left(1 - \frac{1}{2(i+1)-1}\right)^{2(i+1)-4} = \frac{1}{2i+1} \left(1 - \frac{1}{2i+1}\right)^{2i-2} = \frac{\left(\frac{2i}{2i+1}\right)^{2i-1}}{2i}. \quad (3.10)$$

Assim, a probabilidade de transmissão com sucesso de um pacote no protocolo *Aloha puro* é dada por

$$P_{r_s}(\gamma) = pr_s(\gamma)\delta = \frac{(1 - \text{BER}(\gamma))^{N_b} \left(\frac{2i}{2i+1}\right)^{2i-1}}{2i}. \quad (3.11)$$

A relação sinal-ruído é definida como sendo

$$\gamma = C_2 P_t \left(\frac{d}{i}\right)^{-\alpha} R^{-1}. \quad (3.12)$$

Como se trata de uma transmissão por múltiplos saltos em uma rede linear com nós equidistantes, primeiro define-se o consumo médio de energia por bit para realizar um único salto, em unidades de Joules/bit, da seguinte forma

$$\bar{E}_{1hop} = E_b(P_t) \sum_{k=1}^{\infty} k P_{r_s} (1 - P_{r_s})^{k-1} = \frac{E_b(P_t)}{P_{r_s}}. \quad (3.13)$$

Desta maneira, a quantidade média de energia consumida para a transmissão bem-sucedida de um único bit ao longo de vários saltos, sem levar em conta o período de *back-off* do dispositivo, é $\bar{E}_{1hop} \cdot i$. Portanto, com base nas Eqs. (3.5), (3.11) e (3.13), resulta em

$$\bar{E}_{ihop} = \bar{E}_{1hop} \cdot i = \frac{(E_c + K_1 \cdot P_t)i}{\frac{(1 - \text{BER}(\gamma))^{N_b} \left(\frac{2i}{2i+1}\right)^{2i-1}}{2i}} = \frac{(E_c + K_1 \cdot P_t)2i^2}{(1 - \text{BER}(\gamma))^{N_b} \left(\frac{2i}{2i+1}\right)^{2i-1}}, \quad (3.14)$$

ou seja,

$$\bar{E}_{ihop} = \frac{(E_c + K_1 \cdot P_t)}{\left(1 - \frac{\alpha_m}{2\beta_m C_2 P_t \left(\frac{d}{i}\right)^{-\alpha} R^{-1}}\right)^{N_b}} \cdot \frac{2i^2}{\left(\frac{2i}{2i+1}\right)^{2i-1}}. \quad (3.15)$$

A potência de transmissão ótima (P_0) é obtida através da derivação da energia

$$\left. \frac{\partial \bar{E}_{ihop}}{\partial P_t} \right|_{P_t=P_0} = 0, \quad (3.16)$$

em que P_0 está em função da taxa de transmissão de dados (R) e do tamanho do pacote de

dados (N_b). Dessa forma, a partir da Eq. (3.16), obtém-se a formulação

$$P_0(R, N_b) = \frac{\left(\frac{d}{i}\right)^{-\alpha} \alpha_m (1 + N_b)}{4C_2\beta_m R^{-1}} + \frac{\sqrt{\left(\frac{d}{i}\right)^{-\alpha} \beta_{amp}\alpha_m \left[\left(\frac{d}{i}\right)^{-\alpha} \beta_{amp}\alpha_m (1 + N_b)^2 + 8\beta_m C_2 R^{-1} (C_3 R + C_4 N_b)\right]}}{4C_2\beta_{amp}\beta_m R^{-1}}. \quad (3.17)$$

C_3 e C_4 são derivados da Eq. (3.6), onde

$$C_3 = 2T_{start}P_{start}, \quad (3.18)$$

$$C_4 = P_{txElec} + P_{rxElec} + \alpha_{amp}. \quad (3.19)$$

Portanto, a partir das Eqs. (3.15) e (3.17), O \bar{E}_{ihop} é a energia média consumida por bit de dados transmitido com sucesso do nó fonte ao nó destino em função de R e N_b , para i saltos e considerando a potência ótima de transmissão $P_0(R, N_b)$ para o protocolo *Aloha puro* e dado por

$$\bar{E}_{ihop} = \frac{(C_3 R + (C_4 + \beta_{amp} P_0(R, N_b)) N_b)}{RN_b \left(1 - \frac{\alpha_m}{2\beta_m C_2 \left(\frac{d}{i}\right)^{-\alpha} R^{-1} P_0(R, N_b)}\right)^{N_b}} \cdot \frac{2i^2}{\left(\frac{2i}{2i+1}\right)^{2i-1}}. \quad (3.20)$$

Os parâmetros das camadas física (PHY) e enlace (MAC), como exemplo de dispositivos IoT, seguindo o μ -AMPS-1 [39], são apresentados na Tabela 3.1

3.2 Geração da base de dados para treinamento da RNA

O objetivo desta etapa é gerar um banco de dados robusto de treinamento, combinando todas as variáveis envolvidas na Equação e os parâmetros da Tabela 3.1 para o protocolo *Aloha Puro*.

Essa estratégia consiste em criar diferentes cenários e respectivas soluções de transmissões de forma que uma rede neural artificial possa ser treinada e capacitada a encontrar soluções eficientes em cenários onde não é possível controlar essas variáveis, sobretudo distância pela possibilidade de dispositivos *IoT* de serem móveis.

Para realizar todas as combinações dos intervalos (Δ) definidos na Tabela 3.1 para as variáveis de entrada R , N_b , α , d e i , foi necessária a implementação de um algoritmo de busca exaustiva [41] para enumerar todas as possíveis soluções do problema para que assim a RNA

Parâmetro	Descrição	Valor
P_{rxElec}	Potência do circuito de recepção	279mW
P_{start}	Potência para inicialização	58,7mW
T_{start}	Tempo de inicialização	446 μ s
P_{txElec}	Potência do circuito de transmissão	151mW
α_{amp}	Nível de potência	174mW
β_{amp}	Constante de proporcionalidade	5
N_0	Densidade espectral de ruído	-154dBm/Hz
f_c	Frequência da portadora	2,4GHz
c	Velocidade da luz no vácuo	3×10^8 m/s
G_T	Ganho da antena de transmissão	1
G_R	Ganho da antena de recepção	1
ΔR	Taxa de transmissão	50 a 10^7 bps
ΔN_b	Número de bits por quadro	1 a 8×10^6 bits
$\Delta \alpha$	Coefficiente de atenuação	2 e 4
Δd	Distância entre fonte e destino	10 a 250m
Δi	Número de saltos até o destino	1, 2, 4, 8

Tabela 3.1: Parâmetros PHY-MAC empregados na geração da base de dados ALOHA
Fonte: [4]

possa encontrar a solução global ótima para as saídas \bar{E}_{ihop} e P_0 , demonstrado no pseudocódigo [1].

Algorithm 1: Busca exaustiva das melhores configurações

Data: Entrada do Algoritmo
Result: NNTrainingSet

```

1  $k = 0$ ;
2 for  $\alpha \in \Delta_\alpha$  do
3   for  $d \in \Delta_d$  do
4     for  $i \in \Delta_i$  do
5        $j = 0$ ;
6        $\bar{E}_{ihop} = \text{MAX}_{\text{value}}$ ;
7       for  $R \in \Delta_R$  do
8          $\bar{E}_{ihop} = \text{MAX}_{\text{value}}$ ;
9         for  $N_b \in \Delta_{N_b}$  do
10           $\text{Temp}\bar{E}_{ihop} = \text{Calculate}_{E_{ihop}}(MCE)$ ;
11          if  $\bar{E}_{ihop} > \text{Temp}\bar{E}_{ihop}$  then
12             $\bar{E}_{ihop} = \text{Temp}\bar{E}_{ihop}$ ;
13            NNTrainingSet[ $k, j$ ]  $\leftarrow \bar{E}_{ihop}, R, N_b, \alpha, d, i$ ;
14           $j = j + 1$ ;
15         $k = k + 1$ ;

```

3.3 Regressão e otimização da rede neural

Com a base de treinamento gerada na etapa anterior, considerando a limitação de hardware de dispositivos de *IoT*, é mais adequado a implementação de uma rede neural mais simples, nesse caso um MultiLayer Perceptron (MLP) se encaixa na problemática. A partir da base de dados geradas, foram selecionadas as colunas [BEnh, P0] como valores de saída, conforme ilustrado na Figura 3.3 ou seja, com base nos valores das outras colunas providas na base de dados, a RNA estará capacitada de prever os valores de [BEnh, P0], respectivamente prever o custo energético e a potencia ideal.

O algoritmo de treinamento empregado na MLP baseia-se no aprendizado supervisionado, utilizando a técnica de correção de erros. Esta abordagem visa ajustar os pesos dos neurônios (Θ) a cada interação, ou época, por meio da retro-propagação do erro calculado entre a saída predita ($Y_{Predict}$) e a saída desejada (Y_{True}). Desse modo, os pesos de cada neurônio na rede são atualizados durante cada ciclo iterativo.

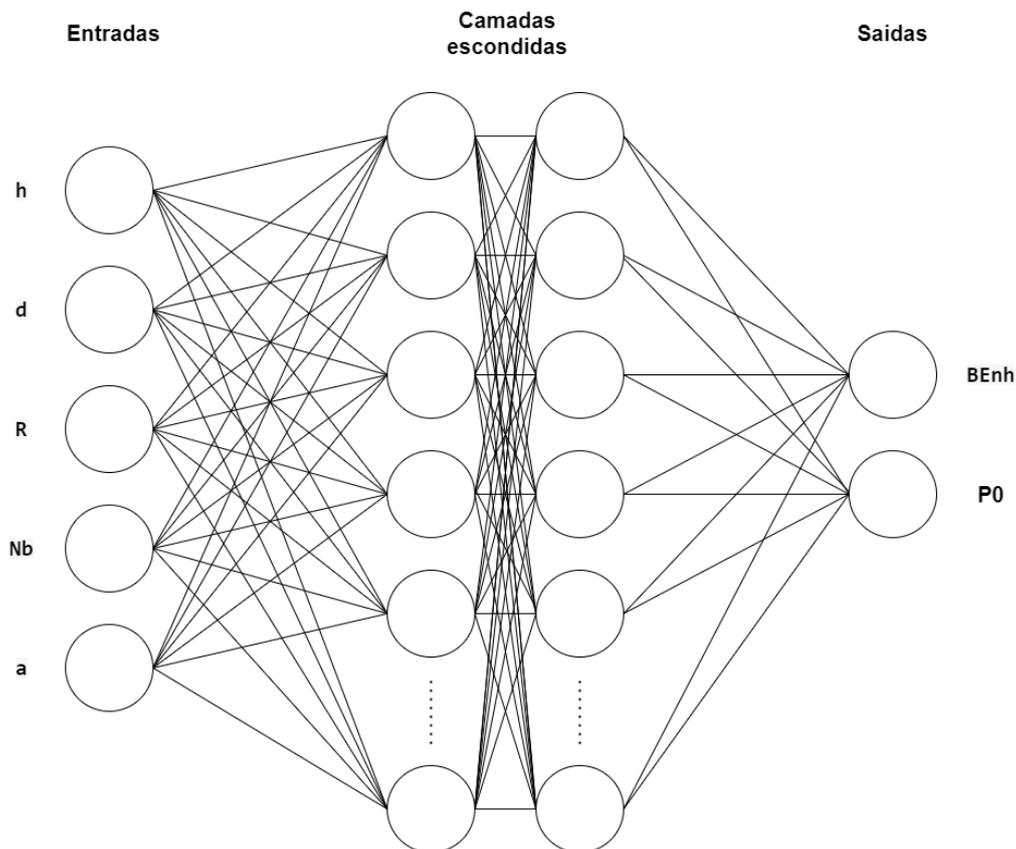


Figura 3.3: Arquitetura da Rede Neural Artificial com 2 camadas escondidas

Para a implementação, foram selecionados os *frameworks* Keras e TensorFlow Lite na linguagem Python, por serem ferramentas voltadas para desenvolvimento em *hardware* limitado,

visando a otimização de custo e tamanho [42].

Para avaliação do treinamento do modelo, foi utilizado o erro quadrático médio (*Mean Squared Error - MSE*), em que a cada iteração, calculava o MSE entre $Y_{Predict}$ e Y_{True} , e ajustava os pesos com o objetivo de minimizar o erro.

A Tabela 3.2 informa os valores utilizados nos hiper-parâmetros da RNA, no qual foram realizados testes empíricos para que pudesse encontrar os valores que geravam os melhores resultados.

Descrição	Valor
Quantidade de camadas escondidas	2
Quantidade de neurônios em cada camada escondida	100
Número máximo de épocas para treinamento	50
Taxa de aprendizado	0,001
Fator de erro mínimo	0,18
Algoritmo de otimização do gradiente estocástico	<i>Adam</i>
Função de ativação de neurônios	<i>ReLU</i>
Quantidade de amostras de treinamento	13824

Tabela 3.2: Hiper-parâmetros da RNA para Aloha Puro

3.4 Dados do experimentos

3.4.1 Comparação do E_{ihop} entre *Aloha puro* e *Aloha Slotted*

A hipótese a priori com relação aos dados gerados, é que o protocolo *Aloha puro* apresente um desempenho inferior ao *Aloha Slotted* devido às características de ambos protocolos, como descrito na Seção 2.1.8. Para validar essa hipótese, foi realizada uma comparação entre os dados provenientes entre a modelagem do *Aloha puro* e a modelagem do *Aloha Slotted* apresentada por [8], ambas modelagens utilizando os parâmetros PHY-MAC da Tabela 3.1. Como ilustrado na Figura 3.4, é possível inferir a posteriori, que os dados apresentam o comportamento coerente com o esperado, isto é, o desempenho do protocolo *Aloha puro* é inferior ao do *Slotted Aloha*.

3.4.2 Divisão dos conjuntos de treinamento e teste

A base de dados foi dividida em dois conjuntos, o de treinamento e o de testes, para avaliar a precisão da RNA em casos que não estão no treinamento. Para isso, foi necessário realizar uma divisão aleatória dos conjuntos, por meio da função `train_test_split()` importada da

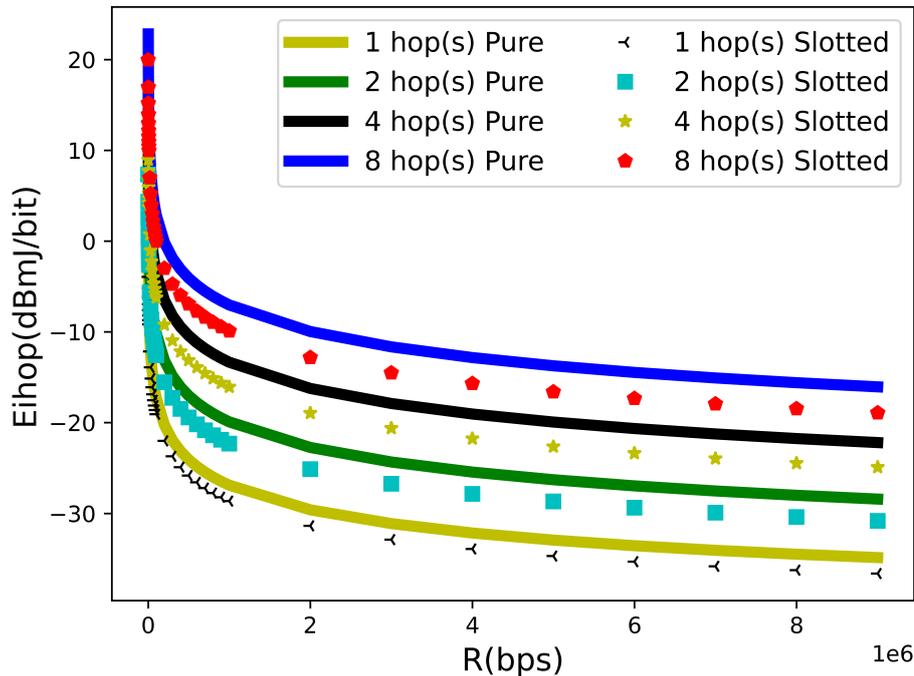


Figura 3.4: Comparativo entre a base de dados gerada para o protocolo *Aloha puro* e para o protocolo *Aloha Slotted*

biblioteca *sklearn*, que garante uma divisão justa da base de dados. A divisão da base de dados segue a proporção de 80/20, ou seja, 80% para o conjunto de treinamento e 20% para o conjunto de teste.

A Figura 3.5 ilustra a coerência entre as amostras utilizadas na etapa de treinamento e na etapa de teste.

O treinamento da rede neural foi realizado no [Google Colab](#) implementado em *Python* em *Jupyter Notebook* para aproveitar o processamento GPU (unidade de processamento gráfico) oferecido no serviço para executar de forma mais eficaz.

3.5 Resumo do capítulo

Neste capítulo foi detalhada a metodologia empregada para a construção da proposta de abordagem baseada em aprendizado de máquina em protocolo *Aloha puro*, para gerenciar recursos no dispositivo, com o objetivo de reduzir o custo computacional e energético. o modelo considera variáveis das camadas físicas e MAC para determinar uma configuração de hardware que otimize o consumo energético. Para isso, a metodologia foi dividida em 3 etapas.

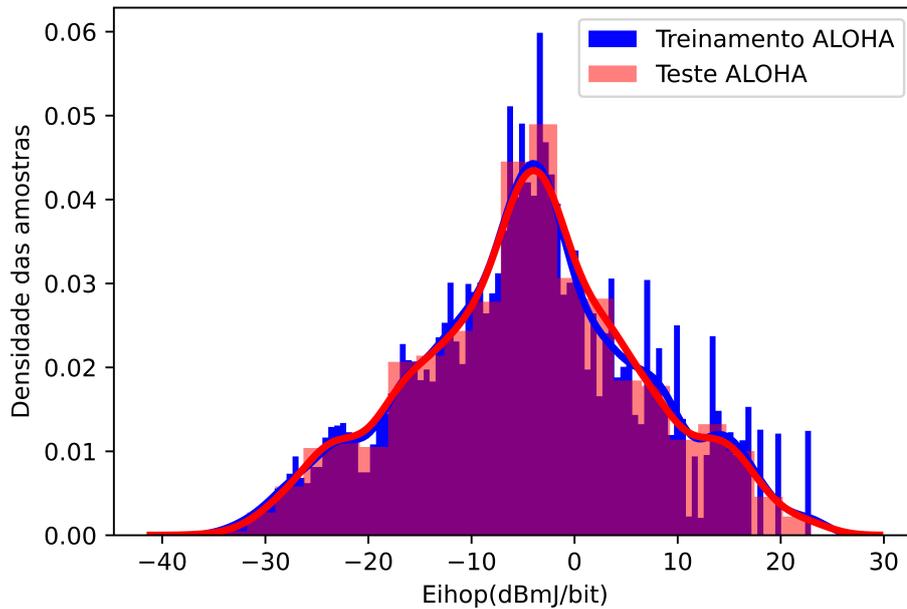


Figura 3.5: Distribuição das amostras Treinamento X Teste

A primeira etapa descreve a modelagem matemática do consumo energético e potência ótima do protocolo *Aloha puro*. Teve como base o modelo de consumo de energia proposta por [8], no qual houve uma alteração para se adequar ao comportamento do protocolo *Aloha puro*.

A segunda etapa descreve o algoritmo exaustivo utilizado para criação da base de dados para treinamento da RNA. A modelagem desenvolvida na etapa anterior foi utilizada no algoritmo exaustivo para gerar os valores das configurações de otimização global, de forma a encontrar a melhor configuração que resulte no menor consumo de energia em diferentes cenários de transmissão. Esse banco de dados gerados foi fundamental para o treinamento na RNA na etapa seguinte.

A terceira etapa descreve a arquitetura da RNA utilizada, assim como parâmetros e hiperparâmetros definidos para o treinamento do modelo. A RNA é uma MLP de regressão, com 3 camadas escondidas, que foi treinada com o banco de dados gerado na etapa anterior, para que pudesse ser capaz de determinar as condições ótimas de consumo energético com base em parâmetros que for apresentado. A escolha da arquitetura de uma MLP se deve a capacidade de aprender problemas não-lineares e possuir baixo custo computacional, requisito importante para dispositivos IoT.

Capítulo 4

Resultados Obtidos

“Toda falha é um passo rumo ao sucesso.”

– WILLIAM WHEWELL

A validação da proposta de solução é um passo crucial no desenvolvimento de uma técnica, sobretudo em algoritmos de aprendizado de máquina, que requerem uma etapa de validação do modelo. Neste contexto, foram destacados seis objetivos fundamentais para avaliar a eficácia da Rede Neural Artificial (RNA) proposta:

1. **Acompanhar a evolução de treinamento da RNA:** É essencial monitorar de perto o processo de treinamento da RNA, observando sua capacidade de aprendizado e adaptação. Isso proporciona informações valiosas sobre como a rede neural se ajusta às nuances dos dados e como sua aproximação às soluções evolui ao longo do tempo.
2. **Analisar a qualidade de predição da RNA:** A validação não se limita ao treinamento. É necessário avaliar a capacidade preditiva da RNA em conjuntos de testes ainda não explorados pela técnica. Essa análise proporciona uma visão abrangente da generalização da RNA para dados não vistos durante o treinamento.
3. **Comparar resultados com técnicas exatas:** Uma comparação direta com resultados obtidos por algoritmos exatos é importante para avaliar a eficiência da abordagem baseada em aprendizado de máquina. A confrontação com soluções provenientes de técnicas de busca de ótimos globais destaca a capacidade da técnica heurística, baseada em aprendizado de máquina, em alcançar resultados tão eficientes quanto abordagens mais tradicionais.

4. **Avaliar a rede neural com métricas de regressão:** Como a RNA é do tipo de regressão, de prever valores contínuos, é importante utilizar métricas referentes, como MSE, MAE, R2 e EVS, para avaliação da eficiência da RNA. Assim como, determinar o intervalo de confiança para conferir se os resultados obtidos estão coerente com relação à margem de incerteza.
5. **Comparar o custo computacional entre o modelo de consumo de energia (MCE) e a rede neural artificial (RNA):** Para validar a otimização em relação a custo computacional e energético proposto no método da RNA, é necessário comparar o tempo de execução e o consumo da unidade central de processamento (CPU) entre a RNA e o MCE.

Esses seis pontos formam uma base robusta para a validação da proposta de solução, fornecendo uma análise abrangente da performance da RNA em diferentes aspectos do seu funcionamento.

4.1 Avaliações do treinamento e das previsões da RNA

4.1.1 Evolução do MSE durante o treinamento da RNA

A Figura 4.1 apresenta a evolução do MSE durante o processo de treinamento da RNA, demonstrando uma queda acentuada logo nas primeiras iterações, e em seguida, realizando sutis otimizações na convergência. Em todos os testes realizados, observou-se que a a RNA apresentava uma convergência com 30 épocas de treinamento.

4.1.2 Comparativo entre o E_{ihop} encontrado pelo MCE e o E_{ihop} predito pela RNA

As Figuras 4.2 e 4.3 apresentam um comparativo ordenado entre os valores E_{ihop} e $P0$, respectivamente, obtidos pelo MCE, e as previsões dos valores de E_{ihop} e $P0$, respectivamente, encontrados pela RNA.

O detalhe das duas linhas estarem sobrepostas indica que a RNA foi capaz de aprender e prever valores muito próximos aos originais. A capacidade do modelo em reproduzir fielmente os resultados reais demonstra sua habilidade em capturar padrões complexos e não-lineares nos dados de treinamento e generalizar eficazmente para novos conjuntos de teste.

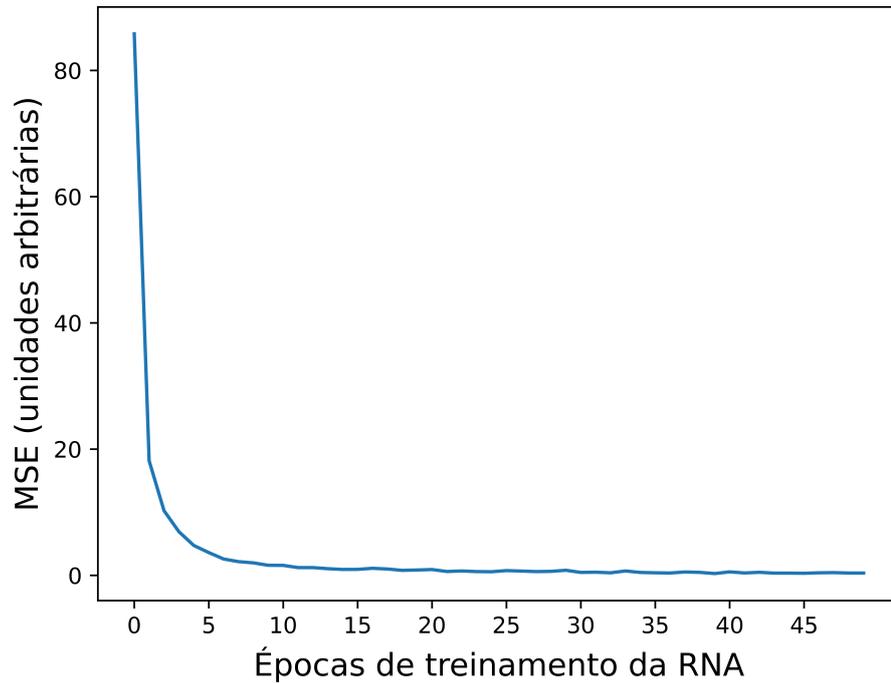


Figura 4.1: Evolução do *Mean Squared Error* (MSE) durante o treinamento

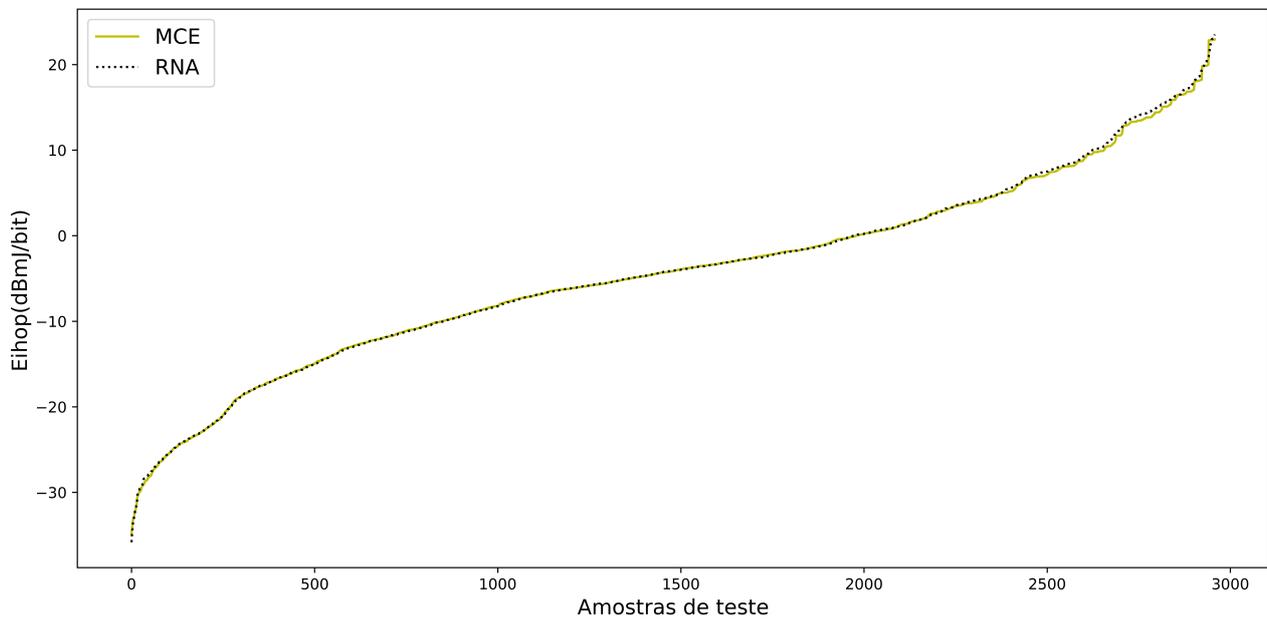


Figura 4.2: Comparativo entre o E_{ihop} encontrado pelo MCE e o E_{ihop} predito pela RNA

Este resultado reforça a confiança na capacidade preditiva da RNA e sugere que a abordagem adotada para o treinamento foi bem-sucedida. A sobreposição das linhas valida a precisão e robustez da RNA ao enfrentar desafios de previsão, proporcionando resultados que se alinham de maneira notável com a realidade.

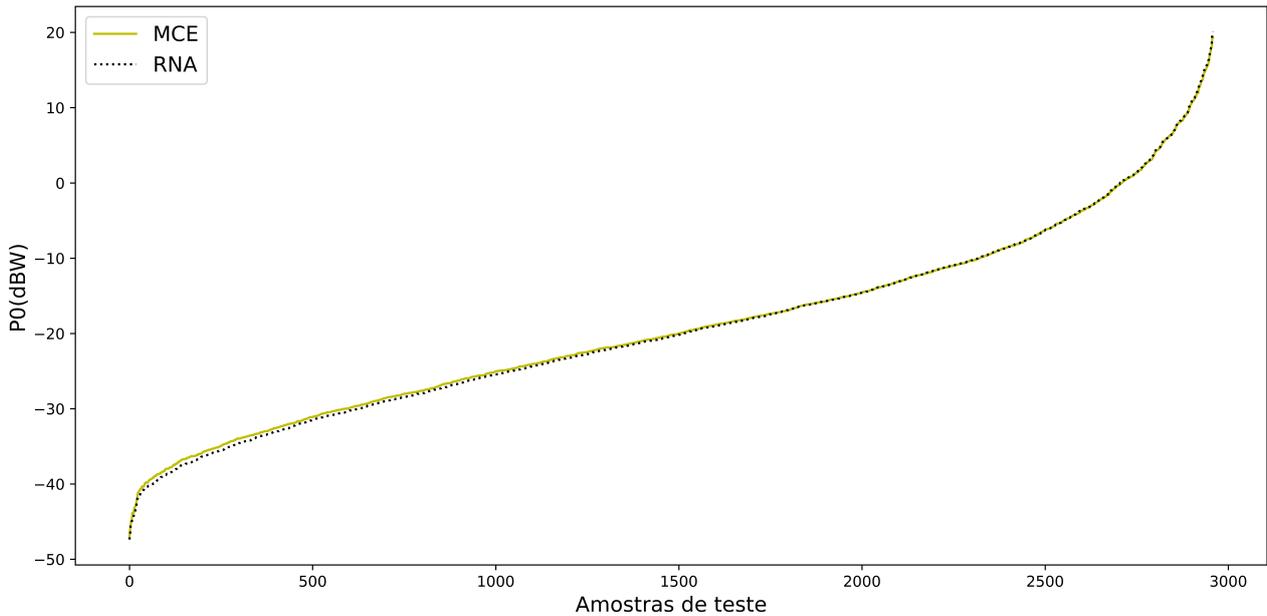


Figura 4.3: Comparativo entre o P_0 encontrado pelo MCE e o P_0 predito pela RNA

4.1.3 Avaliação dos resultados com P_0 com variação e fixado pelo modelo

O modelo proposto por [8] otimiza matematicamente o parâmetro P_0 , entretanto, visto que a modelagem utiliza outros parâmetros, foi realizado uma abordagem para gerar os dados variando o P_0 para observar se encontra valores de consumo de energia mais reduzido em relação ao modelo anterior. Foram denominados como "fechado" para o P_0 provido diretamente pela otimização matemática e "aberto" para a abordagem com variação no P_0 com uma porcentagem do valor original. Esta segunda abordagem foi utilizada na RNA.

As Figuras 4.4a e 4.4b ilustram o comportamento das duas abordagens, respectivamente para cenários com ambientes pouco atenuados ($\alpha=2$) e para cenários com ambientes muito atenuados ($\alpha=4$). A distância total entre o transmissor e receptor foi $d = 80$ metros, com número de saltos i variando entre 1, 2, 4 e 8. Os parâmetros de taxa de transmissão R e o número de bits por quadro N_b seguiram a variação padrão do Δ como demonstrado na Tabela 3.1

A partir dos resultados, foi observado que ambas abordagens obtiveram o mesmo comportamento, no qual, ambas as abordagens atingiram o mesmo mínimo consumo de energia.

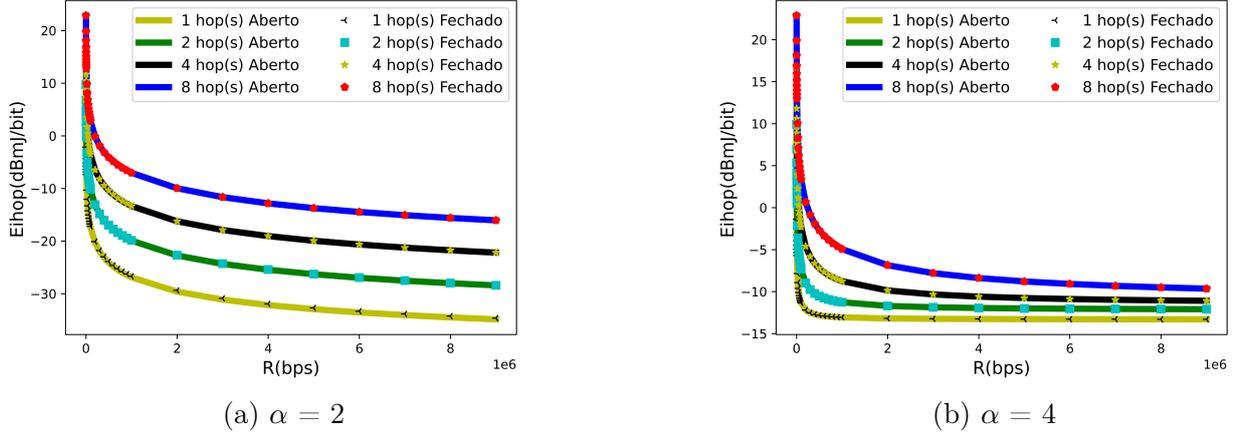


Figura 4.4: E_{ihop} em função da taxa de transmissão. Comparativo entre os resultados entre P_0 definido matematicamente e outra abordagem com variação do P_0

4.2 Resultados das métricas da etapa de teste

Na etapa de teste da RNA, foram utilizados as métricas de regressão: *Mean Squared error* (MSE) , *Mean Absolute Error* (MAE) , *R-Squared* (R2) e *Explained Variance Score* (EVS) entre os valores previstos pelo RNA e os valores reais do MCE [36]. A explicação do calculo estatístico dessas métricas se encontra na Seção 2.2.4 e a unidade dessas métrica esta em unidades arbitrárias devido ao calculo conjunto de E_{ihop} ($dBmJ/bit$) e P_0 (dBW). Os resultados estão apresentados na Tabela 4.1

	MSE	MAE	R2	EVS
RNA	0,1750	0,2936	0,9987	0,9988

Tabela 4.1: Avaliação das métricas da RNA

Conforme indicado pela tabela, a RNA demonstra um bom ajuste devido aos valores do MSE e MAE próximo a 0, o que indica que a RNA possui uma boa média de acerto e não foi afetada por *outliers*. A RNA também demonstra estar com baixa variação entre os resultados preditos devido aos valores do R2 e EVS, o que indicam que a rede explica em torno de 99.88% da variância dos dados, ou seja, a rede consegue prever as variações dos resultados com base nas informações de entrada .

4.2.1 Intervalos de Confiança

Os intervalos de confiança para as métricas de avaliação são apresentados na Tabela 4.2 em unidades arbitrárias devido ao cálculo conjunto de E_{ihop} ($dBmJ/bit$) e $P0$ (dBW):

Métrica	Intervalo de confiança
MSE	[0,17118, 0,17550]
MAE	[0,29096, 0,29345]
R2	[0,99871, 0,99873]
EVS	[0,99885, 0,99888]

Tabela 4.2: Intervalos de confiança das métricas com 95% de nível de confiança

Esses valores representam os limites inferior e superior do intervalo de confiança para cada métrica. O intervalo foi calculado com 30 resultados da RNA em diferentes datasets de teste, gerados por diferentes sementes, com nível de confiança de 95% [43]. Com base nos resultados das métricas da Tabela 4.1, é possível inferir que os resultados estão dentro do intervalo de confiança.

4.3 Gráfico de E_{ihop} e $P0$ por quantidade de saltos

As Figuras 4.5 e 4.6 ilustram com mais detalhes o E_{ihop} e $P0$, respectivamente, previsto pela RNA e pela modelagem MCE, que utilizou os parâmetros da Tabela 3.1, para diferentes valores de saltos (hop) no dataset de teste. A partir disso, torna-se notável novamente a sobreposição das linhas, o que evidencia a convergência da RNA, em prever os valores bastante próximos, para diferentes quantidades de saltos.

Um fator diretamente influenciado pela quantidade de saltos é a distancia entre nós, visto que a distância total entre nó origem e destino é dividida pela quantidade de saltos entre os nós, o que também requer mais transmissões. Dessa forma, observou-se que a RNA conseguiu prever com precisão em todos os casos com diferentes saltos.

4.4 Comparativo entre custo computacional

A Tabela 4.3 mostra o uso médio da CPU (unidade central de processamento) e o tempo total para obtenção das melhores soluções. Para os resultados obtidos pela RNA, a predição

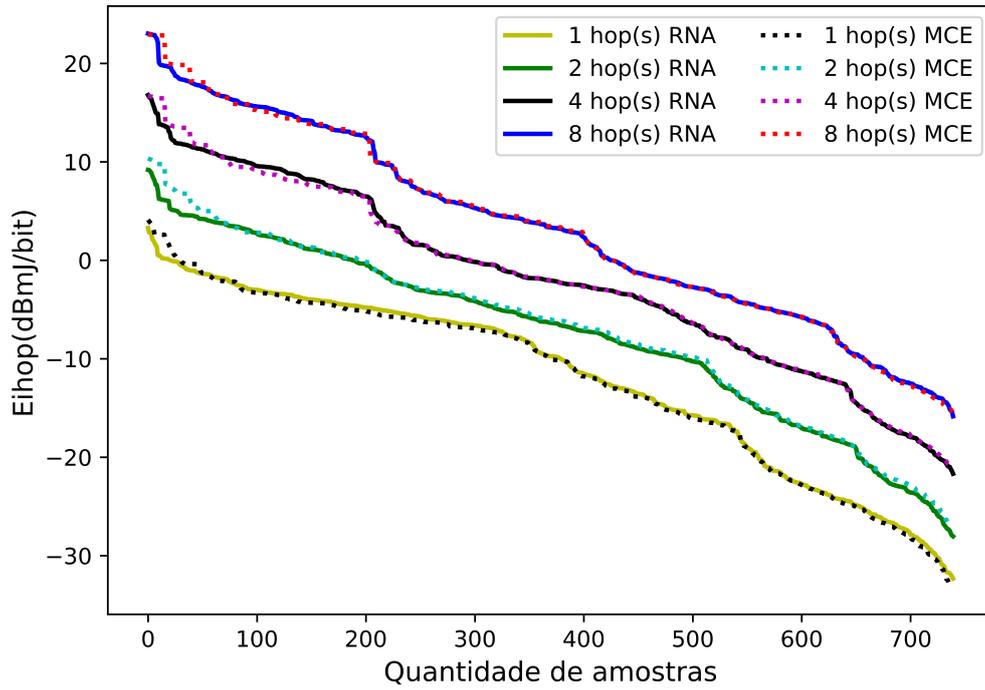


Figura 4.5: E_{ihop} previsto pela RNA e o valor real do MCE para cada quantidade de saltos.

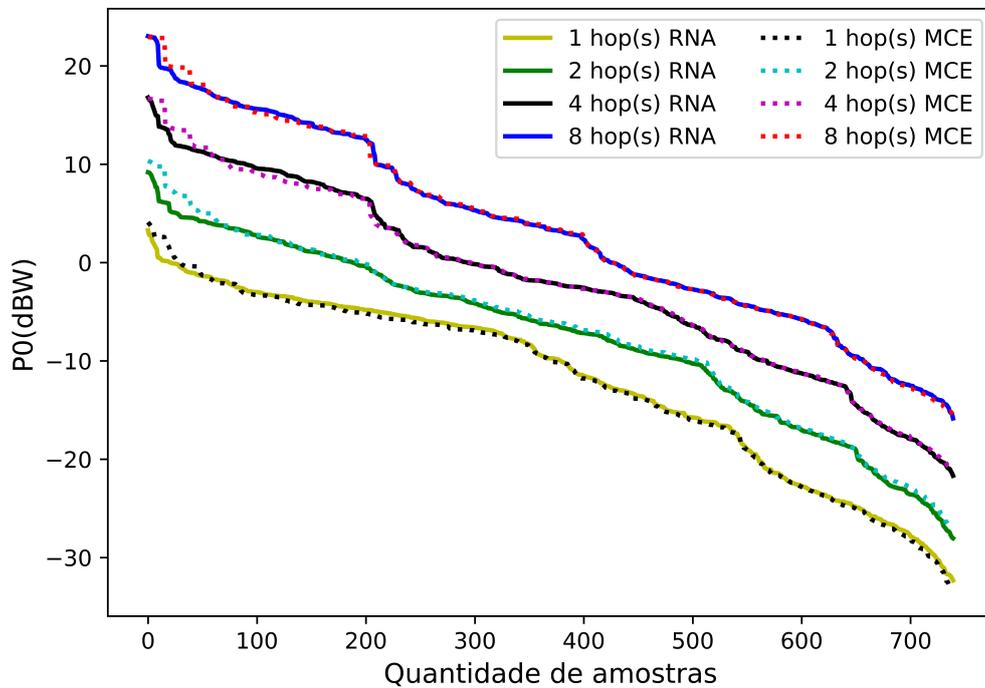


Figura 4.6: P_0 previsto pela RNA e o valor real do MCE para cada quantidade de saltos.

foi executada 30 vezes e calculado a média do consumo da CPU e do tempo total. Importante destacar que esse tempo de execução é apenas da predição, não sendo levado em consideração

o tempo de treinamento da rede neural. Enquanto o custo do uso da CPU sofreu um aumento, o principal ponto de otimização está no tempo total para alcançar os valores ótimos, visto que o MCE utiliza um processo exaustivo que consome horas. Ao mesmo tempo em que a RNA consegue os mesmos resultados com uma margem mínima de erro em uma fração de segundo. Dessa forma a otimização do tempo foi de 99,994% em relação ao tempo anterior.

Técnica	Uso médio CPU	Tempo total
RNA	12,47%	0,809s
MCE	24,3%	3,98h

Tabela 4.3: Comparativo entre custo computacional da RNA com o MCE

Essa queda no tempo de execução de encontrar os valores ótimos faz com que os dispositivos IoT possam recalculer em tempo real, caso hajam mudanças do ambiente e da configuração das variáveis.

4.5 Resumo do capítulo

O capítulo de resultados abrange a validação da proposta de solução, centrada em uma rede neural artificial (RNA) para otimizar o consumo energético em redes IoT que utilizam o protocolo *Aloha puro*. Foram delineados seis objetivos fundamentais para avaliar a eficácia da RNA. Estes incluem monitorar a evolução do treinamento da RNA, analisar a qualidade de predição, comparar resultados com técnicas exatas, avaliar a RNA com métricas de regressão, comparar dados gerados por diferentes modelagens de protocolos, e comparar o custo computacional com o modelo exaustivo.

Os resultados apresentados incluem a evolução do Mean Squared Error (MSE) durante o treinamento da RNA; comparativos entre os valores de E_{ihop} e $P0$ preditos, respectivamente, pela RNA treinada e os obtidos pelo modelo de consumo energético (MCE) que utiliza busca exaustiva para encontrar os ótimos globais; utilização de métricas de regressão para a avaliação da RNA durante a etapa de teste; definição dos intervalos de confiança para essas métricas; comparação dos dados gerados pela modelagem *Aloha puro* e *Aloha Slotted*; e um comparativo de custo computacional entre a RNA e o MCE.

Os resultados indicam uma convergência eficaz da RNA durante o treinamento, excelente capacidade preditiva em relação ao modelo exaustivo, métricas de avaliação destacando boa

precisão e baixa variação, além de uma otimização significativa em termos de custo computacional.

Esses resultados fortalecem a confiança na proposta de solução baseada em RNA, destacando sua eficácia em lidar com desafios complexos e não-lineares de otimização em redes IoT. A precisão, a generalização robusta e a eficiência computacional da RNA sugerem sua aplicabilidade prática e promissora para otimizar o consumo energético em ambientes IoT dinâmicos, que utilizem o protocolo *Aloha puro*.

Capítulo 5

Conclusão e trabalhos futuros

“A melhor maneira de ser feliz é contribuir para a felicidade dos outros.”

– CONFUCIO

5.1 Conclusão

Este trabalho teve como objetivo geral otimizar o consumo energético do protocolo *ALOHA puro* através de uma rede neural artificial, que prediz os valores ótimos de energia e potência para determinada configuração do ambiente e sistema. A metodologia da proposta foi dividida em 3 etapas: A primeira etapa utilizou o modelo de consumo de energia proposto por [8] como ponto de partida para a modelagem do consumo de energia do protocolo *Aloha puro*, em função das variáveis das camadas físicas e MAC como número de bits por quadro, taxa de transmissão, distância entre os nós, números de saltos ideais do remetente ao destino.

A segunda etapa criou um banco de dados robusto a partir da combinação das variáveis do MCE. Para isso, foi utilizado um algoritmo de busca exaustiva para encontrar as configurações de otimização global que encontrasse de forma exata a melhor representação que resulta no menor consumo de energia durante diferentes cenários de transmissão. A base de dados completa se encontra em [44].

A terceira etapa realizou a implementação e o treinamento da rede neural artificial, utilizando a arquitetura de MultiLayer Perceptron de regressão para aprender as relações de entrada e saída entre as variáveis das camadas físicas e MAC. A partir disso, a RNA se demonstrou eficiente em prever os valores ótimos de potência e consumo energético para dada configuração. Sendo realizado experimentos e métricas para avaliar o desempenho da RNA.

Um ponto importante a destacar é que apesar do treinamento da rede neural ser custoso, após treinado, o modelo realiza as predições com baixo consumo computacional e de tempo, principalmente ao comparar com a abordagem anterior da modelagem do consumo para obter os valores ótimos.

Por fim, a otimização de protocolos *Ad Hoc* para redes IoT é expandir o desenvolvimento e aumentar a longevidade desses dispositivos nessa tecnologia emergente. A importância do *Aloha puro* está, além do seu uso direto nos dispositivos, na sua utilização pela tecnologia hegemônica LoRaWAN para acesso ao meio, ou seja, otimizar o *Aloha puro* é também otimizar a principal tecnologia de comunicação de dispositivos de Internet da Coisas.

5.2 Trabalhos futuros

Com base neste trabalho, é possível determinar futuras contribuições:

- **Implementação da RNA em um sensor IoT simulado:** Como os testes e resultados foram realizados no terminal de um computador, o próximo passo é utilizar um simulador de rede IoT que simule o comportamento do protocolo *Aloha puro* para analisar a análise o impacto da implementação da RNA nessa simulação e avaliar a possível otimização.
- **Implementação da RNA em um sensor IoT físico:** Após testar e avaliar a aplicação da RNA no simulador, o passo seguinte é embarcar a RNA em dispositivos físicos e avaliar a possível otimização.

5.3 Outras contribuições

- Base de dados completa: Oliveira, Victor; Barbosa, Paulo ; de Moraes, Renato *ENERGY CONSUMPTION PURE ALOHA(M-AMPS)*. IEEE Dataport, 2024. Disponível em: <https://dx.doi.org/10.21227/v0cq-pj60>

Referências Bibliográficas

- [1] S. Mehra and M. Hasanuzzaman, *Detection of Offensive Language in Social Media Posts*. PhD thesis, 05 2020.
- [2] X. Wang, Y. Liu, and H. Xin, “Bond strength prediction of concrete-encased steel structures using hybrid machine learning method,” *Structures*, vol. 32, pp. 2279–2292, 09 2021.
- [3] E. YAZAN and M. F. Talu, “Comparison of the stochastic gradient descent based optimization techniques,” in *2017 International Artificial Intelligence and Data Processing Symposium (IDAP)*, pp. 1–5, 2017.
- [4] P. F. C. BARBOSA, “Um método de otimização de energia multi-protocolo mac e adaptável por meio de aprendizado de máquina para redes iot e de sensores,” 2023.
- [5] P. K. Reddy Maddikunta, G. Srivastava, T. Reddy Gadekallu, N. Deepa, and P. Boopathy, “Predictive model for battery life in iot networks,” *IET Intelligent Transport Systems*, vol. 14, no. 11, pp. 1388–1395, 2020.
- [6] M. Jouhari, N. Saeed, M.-S. Alouini, and E. M. Amhoud, “A survey on scalable lorawan for massive iot: Recent advances, potentials, and challenges,” *IEEE Communications Surveys Tutorials*, vol. PP, pp. 1–1, 01 2023.
- [7] J. Haxhibeqiri, E. De Poorter, I. Moerman, and J. Hoebeke, “A survey of lorawan for iot: From technology to application,” *Sensors*, vol. 18, p. 3995, 11 2018.
- [8] B. Silva and R. Moraes, “Optimized energy consumption for slotted aloha and csma/ca multihop ad hoc networks,” vol. 35, pp. 189–197, 07 2020.
- [9] K. Gupta, A. Kar, and M. Gupta, “Internet of things and sustainability: A literature review,” pp. 35–45, 01 2024.

- [10] P. Asghari, A. M. Rahmani, and H. H. S. Javadi, "Internet of things applications: A systematic review," *Computer Networks*, vol. 148, pp. 241–261, 2019.
- [11] L. Farhan, S. Shukur, A. E. Alissa, M. Alrweg, U. Raza, and R. Kharel, "A survey on the challenges and opportunities of the internet of things (iot)," pp. 1–5, 12 2017.
- [12] D. M. Pozar, *Microwave engineering*. John Wiley & Sons, 2009.
- [13] Z. Rong and T. S. Rappaport, *Wireless communications: principles and practice*. Prentice Hall, 1996.
- [14] A. Goldsmith, *Wireless communications*. Cambridge University Press, 2005.
- [15] S. F. Solehria and S. Jadoon, "Medium access control protocol for wireless sensor network—a survey," *International Journal of Video & Image Processing and Network Security IJVIPNS-IJENS*, vol. 11, no. 03, pp. 14–18, 2011.
- [16] R. Souza and P. Minet, "Multichannel assignment protocols in wireless sensor networks: A comprehensive survey," *Pervasive and Mobile Computing*, vol. 16, pp. 2–21, 2015.
- [17] I. F. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, "Wireless sensor networks: a survey," *Computer Networks*, vol. 38, no. 4, pp. 393–422, 2002.
- [18] S. N N, S. Kumar, and R. Banu, "Internet of things for neophytes: A survey," pp. 234–242, 12 2017.
- [19] Y. Tukur and Y. Ali, "Demonstrating the effect of insider attacks on perception layer of internet of things (iot) systems," pp. 1–6, 12 2019.
- [20] Y. Owada, G. Sato, K. Temma, T. Kuri, M. Inoue, and T. Nagano, "An implementation of layer 2 overlay mesh network and edge computing platform for iot," pp. 1–6, 11 2019.
- [21] W. Ye, J. Heidemann, and D. Estrin, "Medium access control with coordinated adaptive sleeping for wireless sensor networks," *IEEE/ACM Transactions on Networking (ToN)*, vol. 12, no. 3, pp. 493–506, 2004.
- [22] A. C. V. Gummalla and J. O. Limb, "Wireless medium access control protocols," *IEEE Communications Surveys & Tutorials*, vol. 3, no. 2, pp. 2–15, 2000.

- [23] A. Nauman, Y. A. Qadri, M. Amjad, Y. B. Zikria, M. K. Afzal, and S. W. Kim, “Multimedia internet of things: A comprehensive survey,” *IEEE Access*, vol. 8, pp. 8202–8250, 2020.
- [24] G. P. Halkes, T. Van Dam, and K. Langendoen, “Comparing energy-saving mac protocols for wireless sensor networks,” *Mobile Networks and Applications*, vol. 10, no. 5, pp. 783–791, 2005.
- [25] N. Abramson, “The aloha system: another alternative for computer communications,” in *AFIPS (Fall) Proceedings of the November 17-19, Fall Joint Computer Conference*, pp. 281–285, ACM, 1970.
- [26] P. P. Shinde and S. Shah, “A review of machine learning and deep learning applications,” in *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, pp. 1–6, 2018.
- [27] V. Nasteski, “An overview of the supervised machine learning methods,” *Horizons. b*, vol. 4, pp. 51–62, 2017.
- [28] I. J. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. <http://www.deeplearningbook.org>.
- [29] B. Polyak, “Some methods of speeding up the convergence of iteration methods,” *Ussr Computational Mathematics and Mathematical Physics*, vol. 4, pp. 1–17, 12 1964.
- [30] J. Duchi, E. Hazan, and Y. Singer, “Adaptive subgradient methods for online learning and stochastic optimization,” *Journal of Machine Learning Research*, vol. 12, pp. 2121–2159, 07 2011.
- [31] M. D. Zeiler, “Adadelata: an adaptive learning rate method,” *arXiv preprint arXiv:1212.5701*, 2012.
- [32] T. Tieleman and G. Hinton, “Lecture 6.5-rmsprop, coursera: Neural networks for machine learning,” *University of Toronto, Technical Report*, vol. 6, 2012.
- [33] D. Kingma and J. Ba, “Adam: A method for stochastic optimization,” *International Conference on Learning Representations*, 12 2014.
- [34] V. Nair and G. Hinton, “Rectified linear units improve restricted boltzmann machines vinod nair,” vol. 27, pp. 807–814, 06 2010.

- [35] J. Tang, D. Sun, S. Liu, and J.-L. Gaudiot, “Enabling deep learning on iot devices,” *Computer*, vol. 50, no. 10, pp. 92–96, 2017.
- [36] A. Majumder, M. Rahman, A. A. Biswas, M. Zulfiker, and S. Basak, *Stock Market Prediction: A Time Series Analysis*, pp. 389–401. 01 2022.
- [37] Y. Huan, Y. Qin, Y. You, L. Zheng, and Z. Zou, “A multiplication reduction technique with near-zero approximation for embedded learning in iot devices,” pp. 102–107, 09 2016.
- [38] Z. Ruifeng and J.-M. Gorce, “Optimal transmission range for minimum energy consumption in wireless sensor networks,” pp. 757–762, 03 2008.
- [39] H. Karl and A. Willig, *Protocols and architectures for wireless sensor networks*. John Wiley & Sons, 2007.
- [40] J.-M. Gorce, R. Zhang, and H. Parvery, “Impact of radio link unreliability on the connectivity of wireless sensor networks,” *EURASIP Journal on Wireless Communications and Networking*, vol. 2007, pp. 1–16, 2007.
- [41] P. Liashchynskiy and P. Liashchynskiy, “Grid search, random search, genetic algorithm: A big comparison for NAS,” *CoRR*, vol. abs/1912.06059, 2019.
- [42] L. Shuangfeng, “Tensorflow lite: On-device machine learning framework,” *Journal of Computer Research and Development*, vol. 57, no. 9, pp. 1839–1853, 2020.
- [43] *Simulation: Methodology and Statistics*, ch. 18, pp. 407–437. John Wiley Sons, Ltd.
- [44] V. Oliveira, P. Barbosa, and R. de Moraes, “Energy consumption pure aloha(m-amps).” IEEE Dataport, 2024. Disponível em: <https://dx.doi.org/10.21227/v0cq-pj60>.