



UNIVERSIDADE FEDERAL DE SANTA CATARINA (UFSC)
CENTRO TECNOLÓGICO (CTC)
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE AUTOMAÇÃO E
SISTEMAS

Miguel Lino Ferreira Neto

**Arquitetura Orientada a Dados para Reconfiguração
de Redes IEEE 802.15.4 com Priorização de
Mensagens de Regiões de Eventos Críticos**

Florianópolis
2026

Miguel Lino Ferreira Neto

**Arquitetura Orientada a Dados para Reconfiguração de Redes IEEE
802.15.4 com Priorização de Mensagens de Regiões de Eventos Críticos**

Tese submetida ao Programa de Pós-graduação
em Engenharia de Automação e Sistemas da
Universidade Federal de Santa Catarina para
obtenção do título de doutor em Engenharia de
Automação e Sistemas.

Supervisor: Prof. Dr. Carlos Barros Montez

Co-supervisor: Prof. Dr. Erico Meneses Leão

Florianópolis
2026

Ficha de identificação de obra elaborada pelo autor,
através do Programa de PósAutomação da Universidade Federal de Santa Catarina.

Lino, Miguel

Arquitetura Orientada a Dados para Reconfiguração de
Redes IEEE 802.15.4 com Priorização de Mensagens de Regiões
de Eventos Críticos. 2026.

139 p.

Tese (Doutorado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação
em Engenharia de Automação e Sistemas, Florianópolis, 2026.

Orientador: Prof. Dr. Carlos Barros Montez

Co-orientador: Prof. Dr. Erico Meneses Leão

Inclui referências.

1. Engenharia de Automação e Sistemas. 2. Rede de
Sensores Sem Fio. 3. Arquitetura de Reconfiguração de
Redes orientada a Dados. 4. Título.

Miguel Lino Ferreira Neto

**Arquitetura Orientada a Dados para Reconfiguração de Redes IEEE
802.15.4 com Priorização de Mensagens de Regiões de Eventos Críticos**

O presente trabalho de doutoramento foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Dr. Ivanovitch Medeiros Dantas da Silva
Universidade Federal do Rio Grande do Norte

Prof. Dr. Mário Jorge de Andrade Ferreira Alves
Instituto Politécnico do Porto ISEP – Porto - Portugal

Prof. Dr. Ricardo Alexandre Reinaldo de Moraes
Universidade Federal de Santa Catarina

Prof. Dr. Carlos Barros Montez
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de doutorado em Engenharia de Automação e Sistemas.



Documento assinado digitalmente
Julio Elias Normey Rico
Data: 30/01/2026 14:35:52-0300
CPF: ***.840.859-**
Verifique as assinaturas em <https://v.ufsc.br>

Coordenação do Programa de PósAutomação UFSC



Documento assinado digitalmente
Carlos Barros Montez
Data: 30/01/2026 15:44:32-0300
CPF: ***.035.027-**
Verifique as assinaturas em <https://v.ufsc.br>

Carlos Barros Montez
Orientador

Florianópolis
2026

Agradecimentos

Primeiramente, eu agradeço a Deus e às pessoas mais importantes da minha vida: minha mãe Cilene, meu irmão Aquiles e minha companheira Tamires, por suportarem minhas nuances psicológicas e ausências em momentos importantes enfrentados durante o período de doutoramento. Estas são as pessoas que dão sentido a minha vida e pelas quais eu dedico esforço todos os dias que acordo.

Agradeço também às instituições de apoio a pesquisa: CAPES por contribuir em parte deste doutoramento com a bolsa, e ao CNPq pelos projetos de pesquisa.

Em seguida, não só agradecer mas reverenciar, aos professores e à universidade pública brasileira. Universidade esta que na minha vida foi e é tão importante, proporcionando além de educação, estrutura e ambiente propício ao desenvolvimento das relações humanas, acadêmicas, desportivas, e de descobertas extraordinárias por vários campos do conhecimento. Destacando que este é um dos poucos lugares de transformação, capaz de fazer da vida do indivíduo mais desacreditado um mundo de realizações e conquistas. Permitindo que este também contribua para o crescimento econômico e social de gerações. Além de expandir as conexões com o mundo a fora e preservar a cultura. Em especial agradecer aos professores Prof. Dr. Carlos Montez e Prof. Dr. Erico Leão, respectivamente pela orientação e coorientação deste trabalho, que com muita paciência e excelência conduziram a minha caminhada ao longo destes anos. Lembrar também dos professores e colegas do DAS-UFSC, bem como dos professores, professoras e colegas do CCOMP-UFPI e DC-UFPI, que marcaram minha vida positivamente, e os quais lembrarei pro resto da vida. Dos professores extremamente dedicados que tive no Colégio São Francisco e Colégio Batista de Pedreiras-MA, cujos ensinamentos guardo até hoje. Professores e professoras que tive ao longo de toda vida, como minha mãe, sendo pai e mãe, e nossa parceira Genilza, que desde a minha infância se preocuparam com minha educação, cuidados e formação de caráter. E por que não, ao Prof. Clóvis de Barros Filho, que mesmo presente 99% das vezes virtualmente nos meus dias, serve de inspiração na busca pelo conhecimento, e por quem tenho enorme admiração e apreço.

Aproveito para expressar minha gratidão a todos deixando um trecho que julgo como uma grande obra da cultura brasileira:

*“Graças a Deus, tive casa e colégio, aqui no Brasil isso é privilégio.
Pra classe média do play desse prédio, pensar coletivo não é o remédio.
Tupi tava aqui antes da caravela. Zumbi nunca vi de camisa amarela.
A escravidão ainda deixa sequela, quem vive a mazela da cela é a favela.
Moldado em barro eu vim, pra varrer poeira e pra descer ladeira inteira.”*

— MOLDADO EM BARRO, banda **BRAZA**.

*“A minha vida toda um ato de desapego,
do corpo, do casamento, do parente, do emprego.
Fé é confiança, no que quer que se invista.
Tem fé o ateu, tem fé o cientista.
Me curvo humildemente ante aquilo que não sei.
Acredito no amor, ganho o jogo no fair play.”*

— OXALÁ, banda BRAZA.

“Conhecer é descobrir a própria ignorância em expansão.”

— RICHARD FEYNMAN

*“Vivemos em uma ilha cercada por um mar de ignorância.
À medida que nossa ilha de conhecimento cresce,
também cresce a margem da nossa ignorância.”*

— JOHN A. WHEELER

Resumo

Redes de Sensores Sem Fio (RSSF) constituem a tecnologia de última milha para arquiteturas de Internet das Coisas (IoT) e são amplamente empregadas em aplicações de monitoramento e controle. Entre essas redes, aquelas baseadas no padrão IEEE 802.15.4 e organizadas em topologia *cluster-tree* destacam-se pela capacidade de balanceamento de carga e pela eficiência energética obtida por estruturas hierárquicas e esquemas adaptativos de escalonamento. Entretanto, à medida que o número de nodos cresce e os fluxos de dados variam entre as regiões monitoradas, os desafios associados ao gerenciamento da rede tornam-se mais complexos. Esse cenário se agrava na presença de regiões de atenção ou *hotspots*, onde a incidência de eventos é significativamente maior. Neste contexto, e visando garantir níveis adequados de Qualidade de Serviço (QoS), esta tese propõe uma arquitetura de reconfiguração de RSSFs baseada em formação topológica adaptativa, bem como um mecanismo de reescalonamento de *beacons* para redes IoT com regiões de atenção. Ambas as estratégias buscam otimizar o desempenho da rede nas regiões de atenção, aumentando a taxa de entrega de pacotes de seus nodos e reduzindo os atrasos de comunicação. A reconfiguração topológica e o reescalonamento podem ser acionados dinamicamente a partir da detecção de novas áreas de atenção com base nos próprios dados monitorados, caracterizando uma abordagem orientada a dados. A proposta foi avaliada por meio de simulações extensivas em diversos cenários reais de monitoramento e comparada a métodos recentes da literatura. Os resultados demonstram que a arquitetura desenvolvida produz uma topologia de rede mais homogênea, reduz perdas de pacotes e atrasos fim a fim — especialmente nas regiões de atenção — e aumenta significativamente as taxas de entrega de dados para a estação base.

Palavras-chave: cluster-tree; RSSF; PSO; escalonamento de beacons.

Abstract

Wireless Sensor Networks (WSNs) are the last mile technology for Internet of Things (IoT) architectures and have been widely used in monitoring and control applications. Networks compliant with the IEEE 802.15.4 standard operating in cluster tree topology are suitable for these applications because they allow for better load balancing and efficient use of energy through hierarchical structures and adaptive scheduling schemes. However, as the number of nodes increases and data flows vary across the monitored region, the challenges associated with these applications become more complex. This problem is exacerbated in environments with hotspots — regions where there is a higher incidence of events. In this context, to ensure the desired levels of quality of service (QoS), this thesis proposes a data-driven WSN architecture for IoT networks with hotspot regions, featuring an adaptive topological formation and a beacon rescheduling mechanism. These components aim to optimize network performance in hotspots by improving data delivery rates and reducing communication delays. The network architecture can be reconfigured, and beacon rescheduling can be dynamically triggered as soon as new hotspots are detected, based on the network's own monitored data — thus characterizing a data-driven approach. The proposal was validated through extensive simulations in various real monitoring scenarios, and compared to recent approaches in the literature. The results demonstrate that the proposed architecture creates a more homogeneous network topological structure, reduces packet losses and end-to-end delays — especially in the hotspots — and increases data delivery rates to the base station.

Keywords: cluster-tree; WSNs; PSO; beacon scheduling.

Sumário

1	Introdução	19
1.1	Motivação e Justificativa	20
1.2	Definição do Problema de Pesquisa	21
1.3	Objetivo	22
1.4	Escopo do Trabalho	23
1.5	Contribuições da Pesquisa	23
1.6	Organização do Documento	24
2	Fundamentação Teórica	26
2.1	Redes de Sensores sem Fio: Conceitos	26
2.1.1	Topologias de Rede de Sensores sem Fio (RSSF)	28
2.1.2	Redes <i>cluster-tree</i>	29
2.1.3	Escalonamento de sono em uma RSSF	31
2.2	O Padrão IEEE 802.15.4	33
2.2.1	Subcamada MAC do IEEE 802.15.4	35
2.2.2	Modos de comunicação estendidos do IEEE 802.15.4	36
2.3	Técnicas de Inteligência Artificial aplicadas em RSSFs	38
2.3.1	Inteligência Artificial: conceitos	38
2.3.2	Aprendizagem de Máquina	39
2.3.3	Técnicas de clusterização e classificação	41
2.3.4	Algoritmos meta-heurísticos	44
2.3.5	Considerações referentes às abordagens baseadas em IA	46
3	Trabalhos Relacionados	50
3.1	Trabalhos com Foco na Eficiência Energética	50
3.2	Trabalhos com Foco na Formação Topológica	52
3.2.1	Formações topológicas orientadas a dados	52
3.2.2	Formações voltadas para aplicações IoT	54
3.2.3	Comparação entre propostas de formação topológica	55
3.3	Trabalhos com Formação Baseadas em Inteligência Artificial	55
3.3.1	Estratégias usando IA para formação topológica	56
3.3.2	Comparação entre as propostas baseadas em IA	61
3.4	Trabalhos com Algoritmos de Otimização	61
3.4.1	Configuração da topologia de RSSF	64
3.4.2	Comparação entre abordagens de otimização	65
3.5	Abordagens Relacionadas com <i>hotspots</i>	67
3.5.1	Comparação entre abordagens relacionadas a <i>hotspots</i>	69
4	Arquitetura do Sistema	72
4.1	Modelo do Sistema	72
4.2	Componentes da Arquitetura do Sistema	74
4.3	CALiPSO: Mecanismo de Reconfiguração Baseada em BPSO	81
4.3.1	Exemplo ilustrativo	81

4.3.2	Representação de Partícula, Exploração e Exploração no CALiPSO	82
4.3.3	Fluxograma do mecanismo CALiPSO	83
4.4	Exemplo de aplicação do mecanismo CALiPSO	85
4.5	BRAZA: Reescalonamento de Nós em Regiões de Atenção	87
4.6	Exemplo de aplicação do mecanismo BRAZA	89
4.7	Considerações sobre a Arquitetura	92
5	Resultados do CALiPSO e do BRAZA na Arquitetura Orientada a Dados	94
5.1	Cenários Usados para a Avaliação por Simulação	94
5.2	Avaliação de Técnicas de Clusterização de Dados	95
5.3	Mecanismos de Formação Direcional: BUF-pan e BUF-red	96
5.4	Resultados do Mecanismo de Formação Topológica CALiPSO	100
5.4.1	Análise de desempenho dos algoritmos de formação topológica	102
5.4.2	Análise qualitativa das topologias formadas pelo CALiPSO	104
5.4.3	Avaliação de QoS das topologias formadas pelo CALiPSO	105
5.4.4	Análise de complexidade do CALiPSO	107
5.4.5	Algoritmo do CALiPSO	110
5.4.6	Avaliação experimental do CALiPSO	111
5.4.7	Considerações sobre o CALiPSO	113
5.5	Resultados do Mecanismo de Reescalonamento Prioritário BRAZA	113
5.5.1	Resultados do BRAZA sobre toda a rede	115
5.5.2	Resultados do BRAZA sobre as regiões de atenção	117
6	Conclusão	122
6.1	Visão Geral do Trabalho	122
6.2	Revisão das Motivações do Trabalho	123
6.3	Contribuições e Escopos da Pesquisa	126
6.4	Trabalhos Futuros	127

Lista de Figuras

1	Exemplo de nó-sensor de uma RSSF e sua composição básica.	26
2	Tipos de topologias de RSSFs	29
3	Topologia <i>cluster-tree</i>	30
4	Exemplo de ciclos de serviços dos nodos e modos de escalonamento. . . .	32
5	Pilha de protocolos IEEE 802.15.4/ZigBee e demais tecnologias baseadas no padrão 802.15.4.	34
6	Estrutura do <i>superframe</i>	35
7	Técnicas de clusterização e classificação de dados.	42
8	Algoritmos meta-heurísticos (adaptada de [52]).	44
9	Diagrama de blocos da arquitetura do sistema proposto.	74
10	Algoritmo de descoberta de profundidade e criação da tabela de vizinhança.	77
11	Identificação de grupos prioritários a partir da clusterização de dados. . .	78
12	Exemplo de verificação de escalonabilidade pela técnica <i>Load-SDA</i>	80
13	Um exemplo de uma parte da RSSF com uma região de atenção.	81
14	Evolução da partícula que troca o CH do nodo 20 para o nodo 15.	82
15	Evolução de partículas e sub-partículas do algoritmo CALiPSO.	84
16	Partículas viáveis e possíveis caminhos resultantes de suas rotações. . . .	86
17	Ordem de escalonamento proposto.	88
18	Reescalonamento para atender configurações com casos pares e ímpares. .	89
19	Reescalonamento dos <i>duty-cycles</i> para atender os nodos não prioritários.	90
20	Reescalonamento dos <i>duty-cycles</i> de cada grupo de nodos.	91
21	Cenários de simulação.	95
22	Métricas de Qualidade de Serviço – <i>Quality of Service</i> (QoS) avaliadas sob a implementação de DCTs.	95
23	Taxa de recebimento de pacotes ao longo de 10 rodadas.	96
24	Máquina de estados dos mecanismos BUF.	97
25	Resultados referentes aos atrasos de comunicação e perda de pacotes das abordagens <i>bottom-up</i> e <i>top-down</i>	99
26	Resultados referentes à estrutura formada por cada abordagem direcional.	100
27	Resultados referentes às métricas da rede de cada abordagem direcional. .	100
28	Número de <i>clusters</i> gerados por profundidade em cada abordagem. . . .	101
29	Topologia resultante de cada abordagem no cenário IEEE-test-feeder. . .	103
30	Topologia resultante de cada abordagem no cenário IEEE-test-feeder. . .	104
31	Topologia resultante do CALiPSO no cenário IEEE-test-feeder.	104
32	Atraso fim a fim e perdas de pacotes nos dois cenários avaliados.	105
33	Pacotes recebidos pela <i>Base Station</i> (BS) no cenário Intel Lab.	106
34	Pacotes recebidos pela BS no cenário IEEE-test-feeder.	106
35	Energia consumida no cenário Intel Lab.	107
36	Energia consumida no cenário IEEE-test-feeder.	107
37	Atraso dos nodos prioritários no cenário IEEE-test-feeder.	107
38	Tempos de execução do CALiPSO nos cenários Intel Lab e IEEE-test-feeder.	113
39	Atrasos fim a fim de todos os nodos da rede.	115
40	Taxa média de pacotes de todos os nodos da rede.	116

41	Energia consumida de todos os nodos da rede.	116
42	Atraso (em segundos) dos nodos no SPRF* e NovelSuperf.	117
43	Atraso (em segundos) dos nodos no CALiPSO e no BRAZA.	118
44	Perdas de pacotes (em percentuais) de nodos no CALiPSO e no BRAZA.	119
45	Energia consumida (em Joules) pelo SDA+TDCS e pelo BRAZA.	120
46	Atrasos e perdas de pacotes no BRAZA e em outras abordagens da literatura.	120

Lista de Tabelas

1	Versões do padrão IEEE 802.15.4.	37
2	Trabalhos relevantes à formação topológica de RSSFs.	55
3	Propostas de formação de RSSFs com otimização e Aprendizado de Máquina.	61
4	Comparação de trabalhos relacionados a meta-heurísticas.	66
5	Propostas para reconfiguração de RSSFs com foco em hotspots.	70
6	Parâmetros de simulação da avaliação de abordagens de formação direcional.	98
7	Detalhes de simulação para os mecanismos de formação com e sem <i>Particle Swarm Optimization</i> (PSO).	102
8	Comparação de complexidade algorítmica.	111
9	Parâmetros adicionais do cenário IEEE-test-feeder para avaliação do BRAZA.	114
10	Resultados de atrasos e perdas de pacote para nodos em <i>hotspots</i> e demais nodos.	118
11	Energia consumida pelo SDA+TDCS e pelo BRAZA.	119

Lista de Acrônimos

ACO	<i>Ant Colony Optimization</i>
AG	<i>Algoritmos Genéticos</i>
AM	<i>Aprendizagem de Máquina</i>
AMCA	<i>Asynchronous Multi-Channel Adaptation</i>
AODV	<i>Ad-hoc On Demand Distance Vector</i>
APP	<i>Application Layer</i>
AR	<i>Aprendizagem por Reforço</i>
ASN	<i>Absolute Slot Numbers</i>
BI	<i>Beacon Interval</i>
BO	<i>Beacon Order</i>
BPSK	<i>Binary Phase-Shift Keying</i>
BPSO	<i>Binary Particle Swarm Optimization</i>
BS	<i>Base Station</i>
CAP	<i>Contention Access Period</i>
CFP	<i>Contention Free Period</i>
CH	<i>Cluster-Head</i>
COTS	<i>Commercial Off-The-Shelf</i>
CPSO	<i>Combinatorial Particle Swarm Optimization</i>
CSMA-CA	<i>Carrier Sense Multiple Access with Collision Avoidance</i>
CSS	<i>Chirp Spread Spectrum</i>
DSME	<i>Deterministic and Synchronous Multi-channel Extension</i>
DSR	<i>Dynamic Source Routing</i>
DSSS	<i>Direct Sequence Spread Spectrum</i>
ED	<i>Energy Detection</i>
GA	<i>Genetic Algorithm</i>
GTS	<i>Guaranteed Time Slots</i>
IA	<i>Inteligência Artificial</i>
IC	<i>Inteligência Computacional</i>
ICA	<i>Independent Component Analysis</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
IoT	<i>Internet of Things</i>
IP	<i>Internet Protocol</i>

ISM	<i>Industrial, Scientific, and Medical</i>
LEACH	<i>Low-Energy Adaptive Clustering Hierarchy</i>
LLDN	<i>Low-Latency Deterministic Networks</i>
LP-WAN	<i>Low-Power Wide Area Networks</i>
LQI	<i>Link Quality Indicator</i>
LR-WPAN	<i>Low-Rate Wireless Personal Area Networks</i>
MAC	<i>Media Access Control</i>
MDP	<i>Markov Decision Process</i>
ML	<i>Machine Learning</i>
MO	<i>macMulti-superframeOrder</i>
NET	<i>Network Layer</i>
OSI	<i>Open Systems Interconnection</i>
PAN	<i>Personal Area Network</i>
PCA	<i>Principle Component Analysis</i>
PHY	<i>Physical Layer</i>
PLN	<i>Processamento de Linguagem Natural</i>
PSO	<i>Particle Swarm Optimization</i>
QoS	<i>Qualidade de Serviço – Quality of Service</i>
QPSK	<i>Quadrature Phase-Shift Key</i>
RF	<i>Rádio Frequência</i>
RFID	<i>Radio Frequency IDentification</i>
RNA	<i>Redes Neurais Artificiais</i>
RSSF	<i>Rede de Sensores sem Fio</i>
RSSI	<i>Received Signal Strength Indicator</i>
SA	<i>Simulated Annealing</i>
SD	<i>Superframe Duration</i>
SDV	<i>Singular Value Decomposition</i>
SO	<i>Superframe Order</i>
SUN	<i>Smart Utility Network</i>
TSCH	<i>Time Slotted Channel Hopping</i>
UWB	<i>Ultra-Wide Band</i>
WLAN	<i>Wireless Local Area Networks</i>
WPAN	<i>Wireless Personal Area Network</i>
WSN	<i>Wireless Sensor Network</i>
ZBR	<i>ZigBee Routing</i>

1 Introdução

O conceito de Internet das Coisas (**IoT** – *Internet of Things*) consolidou-se a partir dos anos 2000, com a ideia de interconectar objetos (ou “coisas”) do mundo real com o mundo virtual, por meio de sensores e dispositivos que possibilitam a troca de informações e o acesso à Internet. Nos últimos anos, esse conceito tem estado cada vez mais presente em sistemas voltados para ambientes de larga escala que abrangem aplicações de monitoramento ambiental, cidades inteligentes e plantas *onshore* de petróleo e gás.

As **RSSFs** ou, em inglês, *Wireless Sensor Networks* (**WSNs**), constituem-se em um dos principais pilares de suporte à *Internet of Things* (**IoT**), fornecendo ampla cobertura e conectividade a um grande número de nodos, que podem atuar de forma inteligente, independentemente da intervenção humana. Comumente, as **RSSFs** representam a tecnologia de última milha nas aplicações de **IoT**, formando uma camada composta por sensores e, eventualmente, atuadores interligados por uma rede de comunicação sem fio. Essas redes caracterizam-se, em geral, pela implantação aleatória dos nodos nos mais diversos ambientes — frequentemente hostis — com o objetivo de realizar o sensoriamento e a atuação de maneira cooperativa. Esses nodos, também denominados nós-sensores, operam sob restrições de energia, capacidade limitada de armazenamento e processamento, além das limitações inerentes à comunicação sem fio.

Nesse contexto, a implementação de protocolos específicos voltados para redes de baixo consumo e baixo custo, ou *Low-Rate Wireless Personal Area Networks* (**LR-WPAN**), busca atender a tais restrições e suportar diversos tipos de topologias (estruturas de conexão lógica e física entre dispositivos). Esses protocolos tornaram-se fundamentais para operações de monitoramento de áreas aquáticas [87], agricultura de precisão, *smart cities* [39], prevenção de desastres [63], automação industrial [70], entre outras aplicações [93, 1]. Contudo, a eficiência dessas redes ainda esbarra em limitações de processamento dos dispositivos. Embora algoritmos de IA e de “aprendizado de máquina” sejam amplamente propostos para otimizar a formação e reconfiguração da rede, a maioria das soluções atuais depende de recursos de *cloud computing*, sendo uma estratégia indesejada em aplicações como as tratadas aqui, focadas estritamente em *edge computing*.

No monitoramento de grandes áreas, a formação de topologias em **RSSFs** é um elemento-chave e desafiador, amplamente estudado nos últimos anos, pois impacta diretamente o desempenho da rede em termos de métricas de **QoS**, como atraso fim a fim, taxa de perda de pacotes e consumo energético. Como os nodos frequentemente operam em cenários adversos, a topologia pode se alterar dinamicamente, e eventos inesperados podem surgir em alguma região da área monitorada, demandando detecção e tratamento adequados. Portanto, torna-se necessário desenvolver esquemas integrados capazes de combinar diferentes mecanismos para lidar com esses desafios de maneira adaptativa e eficiente.

Este trabalho propõe a construção de uma arquitetura de formação topológica autoadaptável para **RSSFs** orientadas a dados (*data-driven*) monitorados pelos próprios

Neste documento, ferramentas de IA (como as LLMs – Large Language Models) foram utilizadas exclusivamente para a revisão textual e plotagem de gráficos 3D, não tendo sido empregadas para a geração de código, resultados ou conteúdo científico.

nodos, com o objetivo de prover comunicação eficiente, alta escalabilidade e priorização de diferentes tipos de tráfego, especialmente em cenários sujeitos a falhas de nodos e eventos dinâmicos no ambiente.

1.1 Motivação e Justificativa

Grande parte das [RSSFs](#) é empregada em aplicações de monitoramento e controle de ambientes de larga escala¹. Para esse tipo de aplicação, a padronização promovida por entidades como o *Institute of Electrical and Electronics Engineers* ([IEEE](#)) deu origem a protocolos baseados na norma IEEE 802.15.4 [40], a qual se consolidou como o padrão *de facto* para comunicação em redes de sensores sem fio. Essa norma possibilita operação com baixa latência e consumo reduzido de energia, além de viabilizar a interoperabilidade entre dispositivos. Adicionalmente, ela oferece suporte a redes complexas, como a topologia *cluster-tree*, que favorece a escalabilidade, a eficiência na troca de dados e o monitoramento da rede.

No contexto de [RSSFs](#) aplicadas ao monitoramento, à medida que a região monitorada se expande e o número de dispositivos, bem como o volume de dados trocados entre eles, aumenta, torna-se comum a ocorrência de eventos. Esses eventos, geralmente decorrentes de alterações físicas no ambiente, precisam ser detectados, identificados e tratados com agilidade. As regiões onde tais eventos ocorrem podem demandar prioridade no tráfego de comunicação, o que pode exigir reconfigurações frequentes na estrutura da rede.

As regiões com maior probabilidade de ocorrência de eventos podem ser denominadas *hotspots*. Neste documento, essas regiões também serão referidas como regiões de atenção. Para que suas informações alcancem a estação base com maior frequência, confiabilidade e a menor latência possível, torna-se essencial um mecanismo orientado pelos dados da aplicação, capaz de identificar dinamicamente tais regiões e interagir com outros mecanismos de reconfiguração da rede, de modo a assegurar requisitos de QoS — especialmente em relação à confiabilidade e aos atrasos das mensagens —, promovendo assim um monitoramento mais eficiente nessas regiões de atenção.

Contudo, ao se adotar a norma IEEE 802.15.4 para o monitoramento de grandes áreas, a definição de mecanismos integrados de detecção de eventos e de reconfiguração da rede em uma estrutura *cluster-tree*, dentro de uma arquitetura coerente, requer um estudo aprofundado sobre a configuração dos *beacons* e da duração dos *superframes*, os esquemas de formação topológica, e a distribuição adequada dos períodos de atividade (*duty cycles*) dentro dos *superframes*. Todos esses aspectos constituem elementos-chave para a construção de redes de comunicação hierárquicas, escaláveis, confiáveis e energeticamente eficientes no monitoramento de ambientes de larga escala.

Dessa forma, este trabalho visa definir uma arquitetura computacional que integre um mecanismo de monitoramento e detecção de regiões de atenção, um mecanismo de formação topológica auto-adaptável para [RSSFs](#) com topologia *cluster-tree*, e um mecanismo de escalonamento de mensagens capaz de atender às métricas de [QoS](#) da rede, priorizando a comunicação dos nodos localizados nas regiões de atenção.

¹Neste trabalho, adota-se o termo larga escala no contexto de redes industriais, o qual é usualmente definido na literatura [5] como uma rede composta por dezenas a centenas de nodos.

1.2 Definição do Problema de Pesquisa

A proposta deste estudo é desenvolver uma arquitetura computacional auto-adaptável voltada à formação eficiente de **RSSF**s em conformidade com a norma IEEE 802.15.4, adotando topologias do tipo *cluster-tree*. Essa arquitetura deve considerar os dados monitorados pelos nós-sensores e detectar, de forma dinâmica, eventos em regiões de atenção. Tais eventos devem acionar mecanismos de reconfiguração da topologia e de escalonamento da comunicação, priorizando as mensagens oriundas dos nodos localizados nessas regiões. Portanto, este trabalho requer o estudo de abordagens de formação de redes que envolvam a tomada de decisão baseada em dados, a priorização de tráfego e o uso de técnicas de otimização de roteamento e definição dos caminhos de comunicação entre os nodos.

Os mecanismos propostos neste estudo devem atender aos seguintes requisitos:

- R-1 construir uma topologia de comunicação do tipo *cluster-tree* que assegure a cobertura e a conectividade da rede;
- R-2 selecionar adequadamente os nodos que comporão os *clusters* e aqueles que atuarão como *cluster-heads*;
- R-3 ajustar o escalonamento das mensagens da rede de acordo com a periodicidade dos nodos, configurando adequadamente as durações dos *superframes* do padrão *IEEE 802.15.4*, preservando a conformidade integral com essa norma;
- R-4 apresentar baixa complexidade algorítmica, possibilitando sua execução em nodos *Commercial Off-The-Shelf* (**COTS**) compatíveis com o padrão *IEEE 802.15.4*.

A partir desses requisitos, este trabalho tem o foco na seguinte **pergunta de pesquisa**:

No contexto de monitoramento de RSSF de larga escala compatíveis com a norma IEEE 802.15.4, como construir mecanismos de formação topológica e de escalonamento que priorizem nodos em regiões de atenção de forma dinâmica, mantendo baixa complexidade algorítmica e atendendo aos requisitos de QoS relacionados a atrasos, perdas de pacotes e consumo energético?

Em busca de respostas para tal questionamento, e considerando as premissas e os desafios anteriormente mencionados, outras questões de pesquisa são propostas e deverão ser investigadas ao longo deste trabalho, tais como:

- I) Como identificar, a partir da análise espaço-temporal dos dados coletados em uma **RSSF**, as regiões de atenção (*hotspots*)?
- II) A partir das técnicas e abordagens de formação topológica descritas na literatura, como propor um modelo de formação *cluster-tree* mais adequado ao contexto descrito?

- III) Dentre as técnicas e abordagens de escalonamento de *beacons* em [RSSFs](#) compatíveis com o padrão IEEE 802.15.4, apresentadas na literatura, como propor um modelo de escalonamento coerente com a formação topológica adotada?
- IV) Como projetar uma arquitetura orientada a dados que integre os mecanismos propostos nos itens I), II) e III), permitindo identificar regiões de atenção, reconfigurar dinamicamente a topologia da rede e ajustar o escalonamento de *beacons* de forma coordenada?

1.3 Objetivo

Pretende-se desenvolver uma arquitetura orientada a dados (*data-driven*) que integre um mecanismo de detecção de regiões de atenção (*hotspots*), um mecanismo de formação topológica para [RSSFs](#) com topologia *cluster-tree*, e um mecanismo de escalonamento de *beacons*, capaz de adaptar-se dinamicamente às características do ambiente, de forma a priorizar as regiões de atenção.

O processo de formação da rede, que envolve a seleção de nodos na constituição dos *clusters* e a definição das rotas de comunicação, deve ser orientado pelos dados monitorados pelos próprios nodos, conduzindo a tomadas de decisão que priorizem os tráfegos provenientes das regiões de atenção e assegurem requisitos adequados de [QoS](#) para essas mensagens.

Objetivos Específicos

A partir do objetivo geral deste trabalho, algumas questões precisam ser respondidas a fim de orientar a criação dos mecanismos de formação de uma [RSSF](#). A seguir, são apresentados os objetivos específicos:

- Definir e avaliar mecanismos de agrupamento de dados (*data clustering*) que sejam mais adequados à detecção de regiões de atenção na área monitorada;
- Desenvolver métodos para a formação de topologias *cluster-tree*, envolvendo a determinação do número de *clusters* e de nodos por *cluster*, bem como a seleção dos nodos mais adequados para atuarem como coordenadores locais (*cluster-heads*);
- Implementar um modelo de formação topológica orientado por dados, capaz de priorizar o tráfego *upstream* proveniente dos nodos localizados nas regiões de atenção;
- Propor uma configuração de escalonamento para a rede *cluster-tree*, em conformidade com a norma IEEE 802.15.4 (*beacon scheduling*), capaz de priorizar o tráfego de mensagens provenientes de nodos localizados em regiões de atenção;
- Integrar os mecanismos de detecção de regiões de atenção, de formação topológica e de escalonamento em uma arquitetura orientada a dados, adaptativa e capaz de responder dinamicamente às condições da rede;
- Modelar os mecanismos propostos em um ambiente de simulação e analisar os resultados dos mecanismos propostos na arquitetura.

1.4 Escopo do Trabalho

Atualmente, tem surgido diversas tecnologias e padrões de redes de comunicação que permitem o monitoramento de grandes áreas por meio de enlaces de único salto. Entre essas tecnologias, destacam-se as redes LoRaWAN, IEEE 802.11ah (Wi-Fi HaLow), redes 5G privadas e o IEEE 802.15.4g, que estende o padrão original para operação em faixas sub-GHz. Contudo, neste estudo, adota-se o padrão IEEE 802.15.4 na faixa de 2,4 GHz, amplamente empregado em nodos comerciais (COTS), servindo como base para o desenvolvimento da arquitetura proposta.

Assume-se que a rede IEEE 802.15.4 opera no modo *beacon-enabled* e adota uma topologia do tipo *cluster-tree*. Embora seja possível configurar topologias em malha, este trabalho considera a configuração em árvore por apresentar maior eficiência energética e menor complexidade de coordenação entre os nodos.

O presente estudo concentra-se no tráfego *upstream* (*convergecast*), correspondente ao envio de dados dos nós-sensores à estação base. Embora o tráfego *downstream* também possa se beneficiar da topologia *cluster-tree*, seu tratamento, de uma forma completa, exigiria ajustes específicos no escalonamento de *beacons* e na duração dos *superframes* definidos pela norma IEEE 802.15.4, o que extrapola o escopo deste trabalho. Dessa forma, o foco na comunicação *upstream* permite configurar a rede e seu escalonamento de modo a priorizar a detecção de regiões de atenção e o tratamento preferencial das mensagens oriundas dessas regiões.

A abordagem orientada a dados adotada neste estudo envolve técnicas de detecção de eventos. Diversos métodos têm sido propostos na literatura com esse propósito. Nesta tese, foram analisadas diferentes técnicas de *data clustering*; contudo, optou-se pela utilização do *k-means*, em virtude de sua simplicidade e eficiência computacional, ainda que apresente algumas limitações conhecidas. A arquitetura proposta, entretanto, foi concebida de forma flexível, permitindo uma futura integração ou substituição dessa técnica por outros métodos de clusterização, conforme as necessidades da aplicação.

Por fim, os mecanismos propostos foram avaliados exclusivamente por meio de simulação, o que possibilitou testar diversos cenários quanto à abrangência da área monitorada, à disposição dos nodos e às diferentes combinações de mecanismos, de forma controlada e reproduzível; essas condições seriam difíceis de se atingir em experimentos com nodos reais.

1.5 Contribuições da Pesquisa

As principais contribuições deste estudo consistem no desenvolvimento de mecanismos para a reconstrução da *cluster-tree*, capazes de estabelecer caminhos exclusivos e prioritários para mensagens de origem específica, bem como na proposição de um mecanismo de escalonamento de mensagens no contexto de redes IEEE 802.15.4 operando no modo *beacon-enabled*. Ademais, propõe-se uma arquitetura modular e flexível, que integra esses mecanismos em um esquema orientado a dados, de natureza adaptativa e dinâmica.

1.6 Organização do Documento

Este documento está organizado da seguinte forma. O Capítulo 2 apresenta os conceitos fundamentais das RSSFs, suas principais características, aplicações, implementação sob o protocolo IEEE 802.15.4, bem como abordagens de IA focadas neste tipo de aplicações de rede. O Capítulo 3 resume os principais trabalhos relacionados à formação de redes, clusterização de dados, tratamento de regiões críticas, priorização de tráfego e abordagens voltadas à eficiência energética e qualidade de serviço. O Capítulo 4 descreve a arquitetura proposta, detalhando os mecanismos de formação da rede *cluster-tree*, reconfiguração e escalonamento. O Capítulo 5 apresenta e discute os resultados das simulações realizadas, comparando-os com abordagens existentes na literatura. Por fim, o Capítulo 6 apresenta as conclusões e considerações finais deste trabalho.

2 Fundamentação Teórica

Neste capítulo são apresentados os conceitos relacionados ao tema deste trabalho: [RSSF](#), protocolos de comunicação e abordagens de escalonamento para priorização de tráfegos de dados, e técnicas para formação de topologias. Além disso, um estudo de técnicas de Inteligência Artificial (IA) para otimização dos problemas que envolvem as questões de [RSSFs](#) é apresentado.

Este capítulo está organizado da seguinte forma: a Seção [2.1](#) apresenta as principais características das [RSSFs](#), incluindo sua estrutura e topologias. O protocolo IEEE 802.15.4 e mecanismos de escalonamento são discutidos na Seção [2.2](#). Finalmente, a Seção [2.3](#) discute as abordagens de IA mais utilizadas em [RSSF](#).

2.1 Redes de Sensores sem Fio: Conceitos

As [RSSF](#) consistem em um tipo de rede *ad hoc*² na qual os dispositivos são capazes de monitorar o ambiente e comunicarem-se por meio de Rádio Frequência (RF), normalmente, com a finalidade de coletar dados e encaminhá-los para uma estação base, ou BS. Devido aos avanços da micro e nanoeletrônica, os dispositivos destas redes têm compreendido nodos cada vez mais compactos, sendo utilizados inclusive em ambientes hostis, onde o uso de cabos e da atuação humana é inviável. Desse modo, essas redes têm sido empregadas em diversas áreas como: no monitoramento e controle residencial, agricultura inteligente, supervisão clínica de pacientes, prevenção de desastres e automação industrial [74].

Os nodos de uma [RSSF](#) são tipicamente chamados de nós-sensores, que geralmente, constituem uma estrutura simples (Figura 1) e de tamanho reduzido, composta de um microcontrolador alimentado por uma bateria comum, um módulo de rádio para comunicação *wireless* (sem fio) e os sensores acoplados para detecção das variáveis físicas, como a temperatura, umidade, pressão, luminosidade, ou presença de objetos, por exemplo.




Figura 1: Exemplo de nó-sensor de uma [RSSF](#) e sua composição básica.

Os nodos podem ser diferenciados quanto às suas funções na rede em: nodos finais (*end-nodes*) e nodos *relays*. Nodos *relays* são aqueles com funções mais complexas,

²Redes *ad hoc* são redes em que os dispositivos se comunicam de forma direta, sem a necessidade de um elemento central, como um terminal de acesso intermediando a comunicação.

capazes de agregar, fundir e filtrar dados, e que atuam muitas vezes como nodos coordenadores, além de rotear as mensagens entre os nodos. Por outro lado, os nodos finais realizam as atividades mais básicas, como o sensoriamento e processamento local dos dados que são enviados para um nodo *relay* [15, 23]. Devido à maior complexidade de suas funções, os nodos *relays* apresentam maior consumo energético e, portanto, demandam algoritmos mais eficientes, uma vez que o esgotamento da bateria de um desses nodos pode comprometer a comunicação de diversos nodos finais com a estação base.

As RSSFs devem assegurar conectividade e cobertura adequadas da área monitorada, além de garantir alta escalabilidade por meio de uma topologia fisicamente bem estruturada. Esse desafio torna-se ainda mais crítico em virtude de uma característica marcante de muitas dessas redes: a presença de um grande número de nodos, que devem operar sob restrições de energia, baixas taxas de transmissão e limitações inerentes à comunicação sem fio em ambientes hostis, sujeitos a ruídos, interferências e atenuações do sinal.

Além dos aspectos mencionados, uma RSSF deve também assegurar o desempenho adequado da rede, o qual pode ser avaliado por meio de métricas de QoS, tais como o atraso máximo de comunicação fim a fim (do nó de origem ao nó de destino), a taxa média de perda de pacotes durante a transmissão de mensagens e a largura de banda efetivamente disponível. Considerando sua aplicação em diferentes contextos e cenários, uma RSSF pode ser classificada de acordo com os parâmetros propostos por [61], [14] e [31], conforme descrito a seguir.

Considerando Parâmetros de Rede: De acordo com critérios de conectividade e cobertura da rede, a forma de implantação dos nodos se distingue em: *aleatória* – quando os nodos são espalhados pelo ambiente sem posicionamento preciso, comumente aplicado em redes de larga escala e ambientes de difícil acesso; ou *determinística* – quando os nodos são implantados em posições específicas para o monitoramento, comum em áreas menores. Quanto à densidade, uma rede pode ser: *esparsa* – com poucos nodos por unidade de área; *densa* – quando há muitos nodos por área monitorada; ou *balanceada* – quando há uma distribuição equilibrada de nodos. Quanto à distribuição, uma rede pode ser: *regular* – quando a distribuição é uniforme (mesma quantidade de nodos por unidade de área); ou *irregular* – com distribuição não uniforme.

Considerando Parâmetros de Comunicação: Devido à natureza estocástica do ambiente monitorado, grupos de nodos, dependendo de suas localizações ou tipo de fenômeno observado, podem operar com cargas e intensidades diferentes, caracterizando o conceito de homogeneidade da rede. Uma rede *homogênea* apresenta nodos operando em fluxos de mensagens na mesma intensidade (periodicidade na geração de dados); enquanto uma rede *heterogênea* possui nodos operando em tráfegos distintos, por exemplo, nodos encarregados de monitorar temperatura enviando dados em menor frequência que nodos que monitoram umidade. Neste sentido, a disseminação de mensagens pode implicar em redes: *unidirecionais* – quando o fluxo parte somente em um sentido, por exemplo, dos nós-sensores para a Estação Base (também chamadas de redes de convergência – *convergecast*); ou *bidirecionais* – quando os dados fluem em ambos sentidos. Além disso, dependendo da aplicação, os nodos, com base no tempo, podem exercer

coletas de dados de forma: *periódica* – fazendo com que os nodos enviem dados de forma regular; *contínua* – quando os nodos enviam dados continuamente à medida que estes são detectados; *tempo real* – quando há uma restrição no tempo de resposta da rede, ou ainda; *reativa* – quando os dados são enviados conforme solicitação de outros nodos ou da Estação Base.

Considerando Parâmetros do Nodo: Além da ação cooperativa na rede e atuação autônoma sobre a área monitorada, os nodos ainda podem ter mobilidade. Nesse caso, caracterizam-se as redes como: *móveis* – quando os nodos mudam de posição durante o monitoramento; ou *estacionários* – quando permanecem imóveis até o fim das operações. Outra classificação em relação ao nodo tem como base os recursos de *hardware* disponíveis: *homogêneos* – aquelas em que todos os nodos possuem a mesma capacidade de processamento, armazenamento e fonte energética; ou *heterogêneos* – quando os nodos têm características físicas distintas.

2.1.1 Topologias de RSSF

A implantação de uma RSSF requer uma estrutura, física ou logicamente definida, que seja capaz de promover uma cobertura completa da rede, permitindo a comunicação entre os nodos, e lidar com modificações eventuais em sua estrutura, devido a eventuais desligamentos de nodos. Essa estrutura é chamada de topologia da rede. A formação topológica implica tanto no roteamento das mensagens, quanto na definição de caminhos e rotas estabelecidas entre as regiões monitoradas por meio da seleção correta de nodos. Esta seção visa destacar os principais tipos de topologias de RSSF, descrevendo de forma mais detalhada a topologia *cluster-tree*, foco principal deste trabalho.

O funcionamento correto de uma RSSF está constantemente sujeito a intervenções, seja pelas condições do ambiente ou pelas restrições dos dispositivos e limitações no canal sem fio. É comum haver o desligamento de um nodo por conta dos eventos externos ou pelo esgotamento dos recursos energéticos, que por sua vez pode ser causado por diversos fatores, como uma sobrecarga de dados, programação incorreta do período de atividade dos nodos, função inapropriada destinada ao nodo, entre outros. Dessa forma, um desligamento ou desassociação de um nodo pode comprometer não só a provisão da informação da região monitorada como também todo o funcionamento da rede em termos de cobertura, conectividade, restrições temporais e qualidade de serviço [4].

Algumas das principais topologias de RSSF são ilustradas na Figura 2. As topologias mais utilizados em RSSF de monitoramento e controle constituem o tipo estrela e *peer-to-peer* (ponto-a-ponto). As topologias em estrela compõem uma estrutura mais simples, onde a comunicação é realizada de forma centralizada, ou seja, toda a operação é gerenciada por um nodo central, geralmente um nodo coordenador. Assim, embora seja uma organização de rede fácil de implementar, esta topologia possui limitações quanto à comunicação e escalabilidade, visto que em caso de falha do dispositivo central, toda a comunicação é comprometida e a expansão de cobertura está limitada pelo sinal de RF do coordenador. Por outro lado, as topologias *peer-to-peer* são mais complexas, mas fornecem maior escalabilidade e flexibilidade. Dessa forma, se tornam opções mais interessantes, embora o gerenciamento da comunicação apresente certa complexidade, como




Figura 2: Tipos de topologias de RSSFs.

no caso das redes em grade (*grid* [67]), em malha (*mesh*) e em árvore.

Em geral, redes do tipo *grid* são implementadas sobre redes determinísticas, regulares e estacionárias, devido à sua composição lógica e posicionamento dos nós-sensores [67]. Por sua vez, as redes em malha (*mesh*) compõem o modelo mais utilizado em redes de larga-escala [104, 69], aleatórias, irregulares, heterogêneas e até mesmo, móveis, devido ao seu potencial em fornecer alta escalabilidade mesmo quando a distribuição dos nodos não é uniforme. Porém, tais redes possuem como principal desvantagem a alta complexidade em gerir as atividades dos nodos e principalmente, na definição funcional de cada dispositivo da rede para que a vida útil seja preservada.

Nesse contexto, as topologias em árvore destacam-se como alternativas promissoras em cenários nos quais o gerenciamento eficiente da comunicação e a economia de energia dos dispositivos são fatores primordiais. Mesmo em redes esparsas, irregulares ou distribuídas de forma aleatória, a estrutura hierárquica das árvores favorece uma comunicação mais previsível e organizada, possibilitando um comportamento determinístico no encaminhamento das mensagens. Vale destacar que uma topologia em árvore pode ser formalmente modelada pela teoria dos grafos, sendo um caso particular em que existe um único caminho entre quaisquer dois nodos da rede.

Um caso particular de topologia em árvore são as redes *cluster-tree* (árvore de agrupamentos). Essa topologia possui as vantagens do modelo em árvore combinadas com as do modelo em estrela. Tal topologia é ilustrada na Figura 3, representada tanto na sua estrutura lógica, quanto considerando a disposição física dos nodos sensores. Na figura, é possível ter-se uma noção do potencial de escalabilidade fornecido pelos nodos e o modo de operação da rede. Dessa forma, as RSSFs *cluster-tree* são apontadas pela literatura como sendo a topologia mais adequada para implementação de redes sem fio em larga-escala [59], consistindo em uma alternativa apropriada para cenários de redes de baixa latência e curto alcance, chamadas LR-WPANs (*Low Rate Wireless Personal Area Networks*).

2.1.2 Redes *cluster-tree*

Nas redes *cluster-tree*, cada vértice da árvore compõe um *cluster* (grupo de nodos) gerenciado por um dispositivo especial, chamado de *Cluster-Head* (CH), sendo composto por um nodo *relay*. O coordenador geral da rede é o CH principal. Ele geralmente




Figura 3: Topologia *cluster-tree*.

corresponde ao nodo raiz da árvore. Por razões históricas, esse nodo é tradicionalmente chamado de coordenador PAN, uma vez que o padrão IEEE 802.15.4, em suas primeiras especificações, foi concebido para redes de curto alcance, conhecidas como *Personal Area Network* (PAN).

Em redes que operam predominantemente em tráfego de convergência, comumente, o nodo raiz desempenha o papel de Estação Base, sendo chamado também de nodo *sink* ou “sorvedouro”. Quando o coordenador PAN desempenha a função de *sink*, os demais *cluster-heads* são responsáveis por coletar os dados do seu *cluster*, processá-los, e repassá-los para o coordenador PAN através de outros *clusters*. Além disso, dependendo da configuração do dispositivo, os CHs podem ainda realizar a filtragem, fusão e agregação dos dados.

Em redes *cluster-tree* bidirecionais, além de coleta de dados, os CHs (incluindo o coordenador PAN) podem enviar dados de controle para os nodos membros do seu grupo, no intuito de sincronizar a comunicação e gerenciar as atividades dentro *cluster*. Tal processo é possível através de protocolos adequados que suportam tal topologia (vide Seção 2.2), bem como o gerenciamento proporcionado por mecanismos de escalonamento do sono (Seção 2.1.3). Quando os CHs controlam cada *cluster* independentemente, diz-se que há uma atuação local, enquanto que quando somente o coordenador PAN é responsável por tais tarefas, tem-se uma atuação global na rede.

A hierarquia apresentada na Figura 3-a ilustra o processo de comunicação entre os *clusters* que deve ocorrer obedecendo os níveis da árvore, também representados pela definição de profundidade. Logo, conforme o nível aumenta, maior profundidade a árvore possui. Na Figura 3-b, um esboço mais realista da topologia é apresentado através de uma distribuição onde se percebe que o alcance de RF do coordenador é incapaz de cobrir todos os nodos. Dessa forma, a comunicação é realizada em múltiplos saltos (*multi-hop*), isto é, atravessando-se os níveis da árvore.

Nesse caso, quanto maior é a distância em termos de conexões entre um nó-sensor

e a raiz, mais profundo é aquele nodo e, conseqüentemente, mais saltos são necessários para que este troque dados com a Estação Base e *vice-versa*. Esta definição é importante pois a distância física nem sempre delimita a quantidade de níveis que separa um nodo da raiz. Tal comportamento é melhor observado na Figura 3-b, quanto ao CH 8 que poderia obter um nível mais próximo do coordenador PAN, não fosse a formação lógica entre os *clusters* que culmina em uma profundidade maior. Isso impacta em maiores atrasos entre os dados trocados entre o CH 8 e coordenador PAN, como pode também impactar sobre os fluxos que atravessam o caminho entre eles.

Ainda na Figura 3-b, o comportamento da rede apresentada é indesejado para redes focadas em conectividade e cobertura, visto que o conjunto $\{ON_1, ON_2, ON_3, ON_4\}$ representa os nodos órfãos que não foram cobertos no processo de formação. O termo nó-órfão tem origem com o modelo de associação dos nodos de redes hierárquicas, chamadas de relações pai-filho, onde os nodos membros de um *cluster* liderado por um dado CH são considerados filhos deste CH. Portanto, o CH pode ter filhos que também são CHs, além de filhos que são nós-sensores finais, também chamados de nós-folhas (uma analogia com a árvore, onde o ponto final de seu crescimento é a folha).

Problemas como os de orfandade dos nodos podem comprometer a conectividade e cobertura da rede, pois parte da área monitorada deixará de ser monitorada pela estação base. Por estes motivos, a construção adequada de topologias é um ponto essencial para redes de monitoramento e controle que visam conectividade, cobertura espacial, escalabilidade e desempenho, principalmente em redes de larga-escala (de grandes dimensões).

Em relação aos tráfegos de mensagens típicos em redes *cluster-tree*, a literatura define dois tipos: *downstream* e *upstream*. Sendo *upstream* o fluxo de dados que parte dos nós-sensores e é direcionado ao nó *sink*, também chamado tráfego de convergência. Enquanto *Downstream* é o tráfego de mensagens geradas pelo nó *sink* e direcionado para os nodos descendentes, geralmente denominado tráfego de controle. Também relacionados aos tipos de tráfegos, dois termos bastante frequentes na literatura tratam dos modos de comunicação dos nodos, que podem priorizar estes tráfegos de acordo com o modelo de escalonamento adotado, podendo ser: *top-down* ou *bottom-up*. O modelo *top-down* visa priorizar o tráfego *downstream*, enquanto o *bottom-up*, o tráfego *upstream*.

Ambos os termos também se fazem presentes na literatura quando relacionados à formação de redes *cluster-tree*, sendo o modo *top-down* referente ao processo de formação que é iniciado pelo coordenador PAN na tentativa de associar os nodos mais profundos. Enquanto no modo *bottom-up*, a formação é iniciada a partir dos nodos mais distantes e visam encontrar caminhos até o coordenador PAN. Além disso, a formação ainda pode ser classificada como *centralizada*, quando somente um nodo encarrega-se de tomar a decisão para selecionar nodos e formar *clusters*, ou *distribuída*, quando a formação é conduzida por decisões tomadas localmente por CHs de forma independente.

2.1.3 Escalonamento de sono em uma RSSF

Conforme mencionado, a topologia e funcionamento de uma RSSF deve essencialmente manter uma comunicação eficiente, promover alta escalabilidade e prover conectividade entre os nodos. O consumo energético dos dispositivos em redes desta natureza é uma das questões mais estudadas, tendo em vista que a maioria dos ambientes aos quais

os nodos são implantados e de difícil acesso e manutenção. Estas características impossibilitam que a troca de baterias, reposição de nodos, instalação de fonte energética mais sofisticada, entre outros métodos, sejam executados. Além disso, seja pelo ambiente ou pela quantidade de nodos, o custo para eventuais intervenções na estrutura é outro fator torna o gerenciamento de atividade entre os nodos uma estratégia fundamental.

A estratégia de revezamento do período de atividade e de inoperância dos nós-sensores é chamada de *escalonamento de sono*. O termo refere-se ao modo no qual cada nodo opera, podendo estar ‘acordado’ quando este realiza suas operações (detecção, processamento, filtragem, transmissão de dados, etc.) ou ‘dormindo’ quando este entra em modo de economia de energia (modo *sleep*). Quando um nodo está em modo *sleep*, praticamente todas as suas funções estão inoperantes, e quase não há consumo de bateria. Nesse caso, o nodo possui apenas um mecanismo de temporizador contando o tempo e aguardando o momento de acordar novamente.

O período de atividade mais o período em que o nodo está dormindo é chamado de ciclo de serviço (*duty-cycle*, relação entre tempo ‘acordado’ e ‘dormindo’ que se repete durante o monitoramento). Em redes baseadas em *clusters*, o coordenador PAN e os CHs coordenam os *duty-cycles* dos *clusters*. Dessa forma, estratégias de escalonamento podem ser aplicadas em diferentes níveis de uma *cluster-tree*, promovendo um chaveamento entre a hora de operar de um *cluster* com a hora de dormir de outros, no intuito de reduzir interferências, colisões e sobrecarga de dados [50, 34]. A Figura 4 ilustra exemplos de *duty-cycle* dos nodos (figuras 4-a – 4-d), bem como exemplos de escalonamento definidos na literatura, que têm como finalidade a priorização do tráfego de dados de redes bidirecionais, como o escalonamento *bottom-up* e *top-down*.




Figura 4: Exemplo de ciclos de serviços dos nodos e modos de escalonamento.

Conforme ilustrado, o escalonamento *bottom-up* (Figura 4-e) refere-se à organização de períodos de atividade dos nodos de forma a priorizar o tráfego *upstream* (tráfego de convergência). Desse modo, as mensagens geradas pelos nodos com maiores profundidades na árvore podem alcançar o coordenador PAN em um número menor de ciclos, a

partir da sequência estabelecida pelo escalonamento. Por outro lado, o escalonamento *top-down* pretende favorecer a entrega de mensagens em fluxo *downstream*, por exemplo, as mensagens geradas pelo *sink* podem alcançar os nodos mais profundos em único ciclo (conforme Figura 4-f). Esta figura ilustra uma possível configuração de *duty-cycle* e escalonamento para o modelo de rede mostrado anteriormente na Figura 3-a.

A vantagem de tal abordagem pode ser observada se considerarmos que as mensagens partindo de nodos com menores profundidades até alcançarem os nodos mais profundos, em modo *bottom-up*, precisariam de pelo menos mais dois ciclos totais para que cheguem com sucesso ao destino, no exemplo mostrado. Esta quantidade de ciclos parece pequena neste exemplo simples, porém, considerando uma rede em larga-escala, com profundidade 20, por exemplo, o cenário se torna inviável.

Além disso, não é interessante que o ciclo de serviço seja tão longo de forma que os nodos permaneçam muito tempo dormindo, pois, embora economizem energia, o dado monitorado pode ser impreciso, desatualizado ou ainda, insuficiente para notificar eventos que precisem ser tratados em redes reativas e de tempo-real. Assim, há um *trade-off* entre o tempo adequado para a comunicação de cada nodo e um tamanho ideal do ciclo de serviço, levando ao conceito de escalonabilidade. Uma rede é dita escalonável quando o tamanho do *duty-cycle* é suficiente para comportar a comunicação de todos os *clusters*, onde cada *cluster* deve possuir tempo de atividade suficiente para que todos os nodos se comuniquem com o CH.

Em redes baseadas em *clusters*, mesmo em cenários de alta densidade, é desejável que a quantidade de *clusters* formados não se estenda a ponto de comprometer a coleta de dados em determinadas regiões monitoradas ou ultrapassar o período de comunicação definido pelo *duty cycle* do coordenador. Redes que realizam o agrupamento de nodos em *clusters* e lidam com diferentes tipos de tráfego de dados requerem mecanismos que combinem um esquema de escalonamento adequado com a sincronização da comunicação, de modo a evitar congestionamento de mensagens, perdas excessivas de pacotes, e comprometimento da conectividade e cobertura dos nós sensores. Essa integração pode ser alcançada por meio de protocolos de comunicação apropriados, como o padrão IEEE 802.15.4.

2.2 O Padrão IEEE 802.15.4

No que tange à comunicação sem fio, diversos protocolos e tecnologias têm sido desenvolvidos no intuito de abranger as características que envolvem cada tipo de rede. O IEEE é o responsável pela padronização dos principais protocolos. Cada um deles implementa um modo de comunicação particular, que geralmente é direcionado para cada cenário em que os nodos são implantados.

Os protocolos de comunicação sem fio podem ser categorizados de acordo com sua capacidade de transmissão de dados, consumo energético e alcance do sinal de RF. Por exemplo, em redes sem fio voltadas às *Wireless Local Area Networks* (WLAN), o padrão IEEE 802.11 (*Wi-Fi*) oferece alcances típicos de até 100 m, porém com elevado consumo de energia. Já para as *Wireless Personal Area Network* (WPAN), com alcances médios de aproximadamente 15 m, o padrão IEEE 802.15.1 (*Bluetooth*) é mais adequado, apresentando menor consumo energético. No contexto das RSSFs, entretanto, devido à

natureza restritiva dos nodos e às exigências das aplicações, esses protocolos mostram-se insuficientes para atender às demandas de redes que operam com baixas taxas de transmissão e requerem elevada eficiência energética, como é o caso das **LR-WPANs** e das *Low-Power Wide Area Networks* (**LP-WANs**).

O IEEE 802.15.4 [27] se consolidou como um padrão base para a implantação de **LR-WPANs**, sendo usado na maior parte das aplicações de **RSSF** e soluções para **IoT**. Dessa forma, essa norma tem sido o componente essencial para o desenvolvimento de soluções que envolvem tecnologias como o 6lowPAN [97], MiWi [19], WirelessHART [102], ISA100 [103] e ZigBee [105]. Este último, sendo um dos principais aliados do padrão 802.15.4 na composição da pilha de protocolos ideal (conforme a Figura 5) que implementa as redes *cluster-tree* e **RSSFs** de larga-escala.




Figura 5: Pilha de protocolos IEEE 802.15.4/ZigBee e demais tecnologias baseadas no padrão 802.15.4.

O protocolo ZigBee define as camadas 7 e 3 do modelo *Open Systems Interconnection* (OSI), respectivamente *Application Layer* (APP) e *Network Layer* (NET), lidando com o gerenciamento de topologias, segurança e algoritmos de roteamento como *Ad-hoc On Demand Distance Vector* (AODV), *Dynamic Source Routing* (DSR) e *ZigBee Routing* (ZBR). Complementarmente, o padrão 802.15.4 define as camadas 1 e 2, respectivamente, a camada física *Physical Layer* (PHY) e subcamada de controle de acesso ao meio, *Media Access Control* (MAC).

A camada física permite a medição da qualidade de conexão entre os dispositivos por meio da troca de informações referentes à detecção de energia (*Energy Detection* (ED)) e de funções como o *Received Signal Strength Indicator* (RSSI) e o *Link Quality Indicator* (LQI). A norma especifica o uso da banda *Industrial, Scientific, and Medical* (ISM) não licenciada de 2,4 GHz para operação global, composta por 16 canais de comunicação, com capacidade de transmissão de até 250 kbps. Também são previstas faixas sub-gigahertz destinadas a comunicações de longo alcance: a de 868 MHz, restrita a países da Europa, com um único canal e taxa máxima de 20 kbps; e a de 915 MHz, utilizada nos Estados Unidos, China e Japão, oferecendo 10 canais com taxa de até 40 kbps.




Figura 6: Estrutura do *superframe*.

2.2.1 Subcamada MAC do IEEE 802.15.4

O grande potencial do IEEE 802.15.4 se deve à implementação da camada de acesso ao meio (MAC) que pode operar em diferentes modos: o modo com *beacons* (quadros de sinalização trocados entre os nodos) chamado de *beacon-enabled mode*, e o modo sem *beacons* (*non-beacon mode*). No modo com *beacons*, os nodos podem se comunicar através de uma estrutura chamada de *Superframe*, a qual é delimitada por parâmetros que ditam o período de atividade dos nodos. Assim, o parâmetro *Beacon Order* (BO) e *Superframe Order* (SO) definem respectivamente, o intervalo chamado de *Beacon Interval* (BI) e o período *Superframe Duration* (SD), conforme a Figura 6.

O BI corresponde ao intervalo no qual nodos coordenadores (CHs) devem transmitir periodicamente seus quadros de *beacons*, enquanto que o SD define o período de atividade dos *clusters*. Assim, BI e SD são definidos como segue:

$$BI = aBaseSuperframeDuration \times 2^{BO} \text{ símbolos}, \quad 0 \leq BO \leq 14, \quad (1)$$

$$SD = aBaseSuperframeDuration \times 2^{SO} \text{ símbolos}, \quad 0 \leq SO \leq BO \leq 14 \quad (2)$$

onde o valor 14 é o limite especificado pela norma para operar o modo com *beacon* (sendo BO=15, a representação do modo sem *beacon*). A variável *aBaseSuperframeDuration* corresponde à duração mínima de um *superframe* quando SO = 0, o que equivale a 960 símbolos. Considerando a operação na banda de 2,4 GHz, esse valor corresponde a uma duração de 15,36 ms, sendo cada símbolo composto por 4 bits.

O BI possui uma porção ativa e, opcionalmente, uma porção inativa. Assim, quando BO é maior que SO, significa que existe uma parte inativa e nodos podem entrar em modo de economia de energia. A porção ativa do *superframe* inicia-se imediatamente após o quadro de *beacon* enviado pelo coordenador, definindo o período em que os nodos, tanto coordenadores quanto nós-sensores, trocam mensagens. Esta porção é subdividida em dois períodos: *Contention Access Period* (CAP) e *Contention Free Period* (CFP).

Durante o CAP, os nós-sensores competem pelo canal sem fio por meio do algoritmo de acesso ao meio *Carrier Sense Multiple Access with Collision Avoidance* (CSMA-CA), que visa evitar colisões durante a transmissão. O CFP, por sua vez, é opcional e, quando configurado, permite que o coordenador reserve intervalos de tempo garantidos — os *Guaranteed Time Slotss* (GTSs) —, assegurando que determinados nodos tenham acesso dedicado ao canal e possam transmitir suas mensagens sem contenção.

Em relação aos tipos de topologias suportadas, o padrão 802.15.4 fornece suporte para operação em modo estrela e ponto-a-ponto. Em modo estrela, os nodos se comunicam diretamente com o coordenador; enquanto em redes ponto-a-ponto, dependendo da

configuração e do modo de operação da subcamada MAC, redes mais complexas como: *mesh*, *grid* e *cluster-tree* podem ser implementadas. Em topologias *cluster-tree* baseadas no padrão IEEE 802.15.4, a comunicação dentro de um *cluster* é sincronizada pela troca de quadros *beacon* que são periodicamente transmitidos pelos CHs. Logo, os *beacons* são responsáveis por sincronizar os nodos de cada *cluster*, identificar o PAN e delimitar a estrutura do *superframe*.

O modelo de comunicação hierárquica estabelecido pela topologia *cluster-tree* quando implementado sobre o modo de operação *beacon-enabled*, permite a sincronização da comunicação entre *clusters* e fornece melhor capacidade de gerenciamento das atividades dos nodos. Consequentemente, este gerenciamento favorece o uso da bateria dos dispositivos, que quando aliado a um mecanismos de escalonamento do sono, podem estender a vida útil da rede a partir da distribuição adequada de SDs dentro do BI. Além disso, mecanismos de escalonamentos adequados podem favorecer a comunicação de redes de tempo-real.

O envio de quadros de *beacons* sem a implementação de mecanismos de sincronização pode resultar em colisões entre quadros de *beacons* de *clusters* vizinhos e/ou quadros de dados [51]. Dessa forma, torna-se necessário o uso de técnicas de sincronização, como o método de ordenação de períodos ativos chamado de escalonamento de *beacons*, que atende à estratégia de escalonamento do sono na comunicação.

Ao longo dos anos, atualizações das camadas PHY e MAC têm sido gradualmente implementadas, provendo melhorias conforme as necessidades e avanços percebidos nos modelos de rádio. As versões do padrão são descritas na Tabela 1.

2.2.2 Modos de comunicação estendidos do IEEE 802.15.4

A demanda por novas aplicações IoT vem exigindo redes que suportem requisitos de QoS como latência, rendimento, energia, confiabilidade e robustez. Tais demandas têm provocado a mobilização dos grupos de trabalho referentes ao padrão 802.15.4, voltando esforços para novas atualizações publicadas em diferentes versões no decorrer dos anos.

A partir da emenda IEEE 802.15.4-e [28], além de modificações na camada PHY, importantes modificações na camada MAC acarretaram em novos modos, como: Blink RFID, *Asynchronous Multi-Channel Adaptation* (AMCA), *Low-Latency Deterministic Networks* (LLDN), *Deterministic and Synchronous Multi-channel Extension* (DSME) e *Time Slotted Channel Hopping* (TSCH). Cada modo é voltado para um específico tipo de situação, o que acarreta em mudanças pontuais na subcamada MAC, como por exemplo, o adição de um novo parâmetro da composição do *superframe* do modo DSME, nesse caso o *macMulti-superframeOrder* (MO), que define uma subdivisão do *superframe*, tal que $0 \leq SO \leq MO \leq BO \leq 14$, e a possibilidade de maiores links dedicados fora do CFP no modo TSCH, por meio da definição de *Absolute Slot Numbers* (ASN) que são alocados durante o CAP.

Nos últimos anos, a pilha de protocolos IEEE 802.15.4/ZigBee tem se consolidado como um padrão *de facto* para a implementação de RSSFs em larga escala e para a construção de redes do tipo *cluster-tree*, em virtude dos recursos oferecidos pelo modo de operação *beacon-enabled*. De acordo com a ZigBee Alliance — organização responsável pela definição das camadas superiores do protocolo ZigBee —, a maioria das implantações

Tabela 1: Versões do padrão IEEE 802.15.4.

Versões IEEE	Descrição
802.15.4-2003 [26]	Primeira versão do padrão, fornece duas camadas físicas com a modulação do tipo <i>Direct Sequence Spread Spectrum</i> (DSSS): uma para bandas de frequência 868 MHz e 915 MHz e outra para 2,4 GHz.
802.15.4-2006 [41]	Define melhorias para a camada física: para ambientes <i>outdoor</i> em 868 MHz e 915 MHz com modulação em <i>Binary Phase-Shift Keying</i> (BPSK) e <i>Quadrature Phase-Shift Key</i> (QPSK) para ambientes <i>indoor</i> em 2,4 GHz, com QPSK.
802.15.4a-2007 [42]	Define duas novas camadas físicas em 2,4 GHz: uma com tecnologia <i>Ultra-Wide Band</i> (UWB) e outra para uso de <i>Chirp Spread Spectrum</i> (CSS).
802.15.4c 802.15.4d-2009	Configuração da modulação para bandas: 868 e 915 MHz. Além da extensão das bandas 779-787 MHz (para China) e 950-956 MHz (para Japão).
802.15.4-2011 [27]	Fornece um padrão para interfaces de aplicações com RFID e sensores, além de definir nova camada física para a banda 2,4 GHz e 433 MHz.
802.15.4e-2011 [28]	Define melhorias na camada MAC para suporte à aplicações voltadas à automação industrial, implementações de salto entre canais, dando suporte a tecnologias como ISA SP100.11a e WirelessHART. Além disso, especifica alterações para acoplamento do pacote MAC 802.15.4 com <i>Internet Protocol</i> (IP), como adotado pela tecnologia 6LoWPAN no uso do IPv6.
802.15.4g-2012 [17]	Emenda que define as <i>Smart Utility Network</i> (SUN), uma especificação de camada física para aplicações de controle de processos, como a <i>Smart Grid Utility Networks</i> , focadas em redes de Distribuição de Energia Elétrica para conexões de baixa velocidade.
802.15.4-2015 [29]	Versão que integra as especificações para dispositivos de LR-WPANs e LP-WANs. Uma variedade de camadas físicas (PHYs) foi definida para cobrir uma ampla variedade de bandas de frequência.
802.15.4-2020 [30]	Aprimora características da camada física, relacionados à UWB com codificação para aumentar a integridade e a precisão das medições de alcance. A camada MAC apresenta melhorias no suporte ao controle dos procedimentos relacionados à obtenção de dado quando em redes móveis.

que demandam alta escalabilidade tem adotado topologias *mesh* combinadas com protocolos de roteamento reativo, que atualizam as informações de vizinhança entre os nodos conforme a necessidade, sendo o [AODV](#) um dos mais utilizados. Este estudo, por sua vez, concentra-se na construção de uma árvore de *clusters*, a qual pode ser considerada um caso particular de uma rede *mesh*.

2.3 Técnicas de Inteligência Artificial aplicadas em [RSSFs](#)

Nesta seção, são abordadas as principais técnicas de Inteligência Artificial (IA) aplicadas às soluções de IoT e [RSSF](#), introduzindo primeiramente um debate sobre o tema com alguns dos conceitos da IA e suas subáreas, em seguida destacando alguns dos algoritmos usados para classificação de dados e abordagens para tomada de decisão. Portanto, a seção é organizada em: [2.3.1](#) definições de [IA](#) e subáreas, [2.3.2](#) definições de Aprendizagem de Máquina ([AM](#)) e [AM](#) embarcada, [2.3.3](#) técnicas de clusterização e classificação de dados e [2.3.4](#) algoritmos de otimização meta-heurísticos aplicados em [RSSFs](#).

2.3.1 Inteligência Artificial: conceitos

A Inteligência Artificial ([IA](#)) é um campo da Ciência da Computação que busca reproduzir, por meios computacionais, o comportamento e as capacidades humanas para tratar situações diversas de forma otimizada. Nesse sentido, entende-se por otimização a capacidade aprimorada dos sistemas computacionais em armazenar uma grande quantidade de dados, processá-los em alta velocidade e automatizar operações em um nível impraticável pelo ser humano. Consequentemente, por meio de algoritmos, representações e análises estatísticas, a IA é um recurso que tem se demonstrado eficiente para lidar com problemas infactíveis, com complexidade que demorariam um tempo indesejável pelos métodos tradicionais.

A [IA](#) pode ser definida como um estudo de agentes que recebem percepções do ambiente e executam ações [84]. Existe um entendimento de que a [IA](#) e as principais vertentes que a compõe, são baseadas na aquisição do conhecimento através dos seguintes tipos de raciocínio: (i) **indução**: quando o conhecimento é inferido através da extração de um conjunto de dados tomados como verdade, ou seja, parte de informações específicas para produzir uma informação generaliz (ii) **dedução**: quando o conhecimento é inferido através de suposições e a relação entre elas são verdadeiras, assim, parte-se de uma generalização para se obter uma informação particular; e (iii) **abdução**: quando a obtenção de conhecimento depende de um fator de confiança para definir a probabilidade daquela informação estar correta.

A partir destes conceitos é possível perceber o quão abrangente é a [IA](#), atuando em várias áreas do conhecimento e originando áreas como a Ciência de Dados, Robótica, Representação do conhecimento e Inteligência Computacional. Em suas subdivisões destacam-se os campos da IA moderna, como: Aprendizagem de Máquina, Visão Computacional, Processamento de Linguagem Natural ([PLN](#)), Redes Neurais Artificiais ([RNA](#)), bem como áreas da IA clássica, como: Representação de conhecimento, Lógica Proposicional e Programação baseada em Restrições.

Recentemente, propostas envolvendo técnicas de diversas áreas da IA têm contribuído para otimizar a construção das RSSFs e contornar os problemas que mais afetam a qualidade de serviço em ambientes de larga escala. Dentre as principais técnicas encontra-se a AM (ou em inglês, *Machine Learning* (ML)), a subárea da IA de maior destaque nos últimos anos, voltada para o aperfeiçoamento do processo de tomada de decisão por parte de um sistema autônomo que se baseia no treinamento dos dados e reajuste de múltiplas camadas de aprendizado (neurônios artificiais).

Tendo em vista este crescimento da AM nos sistemas tradicionais e aplicações da IA generativa, a próxima seção destaca algumas das definições e técnicas derivadas da AM bem como aplicações da AM embarcada, também presente em muitas soluções de RSSFs e IoT, sendo competitiva em relação abordagens de otimização.

2.3.2 Aprendizagem de Máquina

A Aprendizagem de Máquina (AM) é a área da computação que investiga como um sistema pode aprender e agir em situações desconhecidas. Nessa abordagem, o sistema é capaz de aprender ou aprimorar seu desempenho automaticamente, com base no conhecimento adquirido a partir dos dados disponíveis, por meio de um raciocínio indutivo, sendo capaz de executar tarefas que não lhe foram explicitamente programadas [73]. O aprendizado pode ser obtido através de uma abordagem baseada em exemplos (conjunto de dados ou regras) ou ainda através de experiência adquirida ao longo de iterações por meio de tentativas e erros.

Aprendizado supervisionado

Esta técnica consiste de abordagem centrada em exemplos, ou seja, as modificações proporcionadas pelo sistema consideram um conjunto de dados de entrada para produção de uma saída desejada. Assim, após o processo de treinamento, o método supervisionado visa definir a função f que melhor estima uma saída y a partir de uma entrada x , logo, $f : x \rightarrow y$. Nesse caso, a saída desejada é algo que se conhece, como, por exemplo, uma classe, um padrão, a parte de uma imagem, etc.

O termo supervisionado faz referência ao conhecimento da saída rotulada a partir dos dados de treinamento. Esta rotulação funciona como um supervisor que guia as escolhas do agente sobre os dados desconhecidos. Por exemplo, se desejamos classificar um conjunto de imagens de animais, o sistema deverá treinar uma certa quantidade de dados (imagens rotuladas como pertencentes à classe gato, cachorro, cavalo) para, em seguida, com o conhecimento adquirido, rotular imagens que ainda não se conhece.

Abordagens de aprendizagem supervisionada são usadas em tarefas de regressão e classificação. Onde a classificação pode considerar diferentes métodos para se alcançar a saída desejada (exemplo da classe de animais), podendo ser implementada através de lógica, por meio de métodos baseados em instâncias como o k -NN, ou por aprendizagem por meio de técnicas de Redes Neurais (RNA) e Aprendizagem Profunda (*Deep Learning*). Por outro lado, a regressão consiste da técnica de aprendizado que realiza previsões de valores baseado em um histórico, por meio de notação matemática, ou ainda, que permite minimizar erros quando deseja-se lidar com dados numéricos de forma precisa.

Aprendizado não-supervisionado

As abordagens desta categoria, por sua vez, caracterizam-se pela obtenção de conhecimento sem dados rotulados. Embora esta técnica também seja centrada em exemplos, o sistema não tem a identificação da saída por meio de um supervisor. Assim, a saída não corresponde a um dado concreto, obrigando o agente a identificar padrões com base nos dados de entrada disponibilizados.

Este método é bastante usado para clusterização (agrupamento de dados), redução de dimensionalidade e detecção de anomalias. Por exemplo, quando busca-se identificar intervalos de valores processados por um grupo de dispositivos, não se sabe ao certo quantos grupos serão gerados, porém, a partir da análise das variáveis de entrada, o agente pode estimar saídas com intervalos de maior verossimilhança e excluir dados anômalos, de acordo os padrões identificados.

Técnicas de Redução de Dimensionalidade visam eliminar anomalias através da análise multivariada de entradas, seja por meio de combinação linear das variáveis como nas abordagens baseadas em Análise de Componentes, como *Principal Component Analysis* (PCA) e *Independent Component Analysis* (ICA), ou por fatoração de matrizes como no *Singular Value Decomposition* (SDV). Por outro lado, as Técnicas de clusterização consistem de algoritmos de identificação de similaridade baseado na distância entre os valores observados, como no caso do *k-means*, *DBSCAN*, *fuzzy-c-means* e a clusterização hierárquica, abordagens que serão detalhadas na subseção seguinte.

Aprendizado por reforço

O aprendizado por reforço ocorre por meio da interação contínua entre o agente e o ambiente. Em vez de exemplos rotulados, o agente recebe recompensas ou penalidades conforme executa ações, aprendendo gradualmente quais decisões maximizam o retorno acumulado. Trata-se de um processo baseado em tentativa e erro, adequado para problemas sequenciais nos quais a escolha atual influencia estados e recompensas futuras.

O aprendizado por reforço (AR) obteve destaque ao longo dos anos principalmente na área de jogos. Soluções automatizadas para que as máquinas fossem capaz de vencer o raciocínio humano em jogos como os de tabuleiro e de *Atari*³, foram importantes para alavancar a Aprendizagem de Máquina como uma alternativa às abordagens até então vigentes, como as técnicas do campo da IC que implementavam Computação Evolutiva, Teoria de Jogos e Classificadores.

Particularmente, em AR as técnicas podem ser baseadas em modelo ou não, sendo aquelas não baseadas em modelos (*model-free*) caracterizadas pelo uso de informação semelhante ao método supervisionado, embora a extração dos dados seja realizada por meio de experiência. Por este motivo, algumas literaturas chamam-nas de aprendizado semi-supervisionado. Enquanto isso, técnicas baseadas em modelo são orientadas por políticas e função-valor para prever soluções ótimas e estabelecer melhores métodos de aprendizagem. Métodos baseados em política aprendem uma função estocástica para mapear estados a partir de ações, já os baseados em função-valor aprendem valores com base no par (ação, valor) para definir a melhor ação.

³Jogos de *Atari* são jogos eletrônicos de até 2 jogadores, surgiram na década de 70.

Os algoritmos abordados aqui são apresentados como forma de contextualizar os fundamentos que inspiram a maioria das abordagens estudadas na literatura e a sua relevância nos sistemas de tomadas de decisão, principalmente por serem baseados em dados e por compreenderem as particularidades dos sistemas distribuídos. Além disso, são explorados modelos de treinamento e algoritmos que apresentam potencial de redução do processamento, que em muitos casos se faz excessivo, quando comparado as soluções convencionais de *Deep Learning* ou mesmo TinyML (detalhada no tópico seguinte). Isto torna estes modelos mais adequados para arquiteturas IoT com recursos limitados, oferecendo um equilíbrio entre poder de processamento e capacidade de tomada de decisão assertiva em dispositivos IoT.

TinyML: Aprendizagem de Máquina embarcada

Com a forte ascensão do uso de algoritmos de AM em sistemas computacionais tradicionais, os dispositivos que compõem a infraestrutura de comunicação das aplicações IoT e RSSF também passaram a ser inseridos nesse contexto, dando origem ao TinyML (aprendizado de máquina aplicado a dispositivos com baixa capacidade computacional, também denominado *ML embarcada*). Essa tecnologia é voltada à implantação de modelos de aprendizado de máquina em dispositivos e sistemas microcontrolados de baixa potência, memória reduzida e limitada capacidade de processamento, com destaque para aplicações que envolvem o processamento discretizado de imagens.

A ideia básica do TinyML é não tratar o problema completamente na borda, delegando à nuvem a parte principal do processamento [92]. Somente após a consolidação dos dados na nuvem, estes retornam de forma compactada e ajustada para a borda, possibilitando seu uso de modo compatível com a aplicação.

Contudo, essa abordagem nem sempre é compatível com protocolos de baixa largura de banda amplamente utilizados em IoT, como o IEEE 802.15.4. A combinação entre limitações de hardware e a necessidade de maiores larguras de banda impõe desafios significativos à implementação de soluções de IA em ambientes IoT.

2.3.3 Técnicas de clusterização e classificação

Nesta subseção são apresentadas as principais técnicas de classificação e clusterização de dados relevantes para o desenvolvimento deste trabalho. Tais técnicas são comumente utilizadas por aplicações orientadas à informação, como em soluções que envolvem *Big Data* e IoT, e são úteis no gerenciamento de arquitetura baseadas em dados.

Primeiramente, é importante destacar que técnicas de clusterização (agrupamento) são métodos não-supervisionados que, como visto, extraem dados de um conjunto de entrada para criar grupos, que são estabelecidos pelos padrões identificados. Em contraste, técnicas de classificação são métodos que podem agrupar dados a partir de definição prévia da quantidade de grupos que se deseja criar. Nesse contexto, pretende-se avaliar o impacto da fase de agrupamento de dados sobre as questões de RSSFs que se deseja alcançar quando implementadas com técnicas de clusterização como: *k-means*, *DBSCAN*, *Fuzzy-c-means* e clusterização hierárquica; e técnicas de classificação como o *k-NN*. A Figura 7 esboça o comportamento de cada técnica.




Figura 7: Técnicas de clusterização e classificação de dados.

O *k-means* (ou *k* médias) é um algoritmo não-supervisionado clássico, que cria grupos de dados distintos por meio da identificação de similaridade entre os valores detectados. A similaridade é descoberta através da análise da distância que separa um dado de outro, calculada com base na distância entre os pontos e os centroides (valores centrais) observados no conjunto de dados. O cálculo pode ser obtido pela formulação Euclidiana entre os pares, ou com base em fórmulas de distância de Manhattan, Chebyshev e Minkowski, o que torna o algoritmo aplicável em escala multidimensional, com mais de uma variável nas coordenadas principais. O *k-means* então cria *clusters* considerando o valor de *k*, que delimita consequentemente quantos grupos serão formados, e a distância dos dados em relação aos centroides. Com os primeiros centroides definidos, o algoritmo verifica a distância de cada ponto até cada um dos *k* centroides e aqueles que obtiverem maior proximidade são agrupados. A cada novo valor agrupado o algoritmo atualiza o centroide através da média entre valores daquele *cluster*, finalizando quando não há mais modificações significativas no valor dos centroides.

No exemplo da Figura 7-a, com *k*=2, temos um grupo de círculos verdes e um grupo de losangos vermelhos. Cada dado de entrada ainda não classificado tem sua distância medida até o centroide 1 (*d1c1*, no caso do ponto de dado 1 e *d2c1* no caso do ponto de dado 2) e até o centroide 2 (*d2c1* e *d2c2*, respectivamente para ambos os pontos).

Seguindo a mesma ideia, o método *fuzzy-c-means* também se baseia na média de valores do *cluster* para atualização dos centroides. A diferença neste algoritmo está relacionada a probabilidade de um dado pertencer a mais de um *cluster*, característica apontada como um ponto fraco da abordagem *k-means*, logo, esta técnica é um aprimoramento.

ramento da abordagem anterior. No *k-means*, muitas vezes ocorre de um dado estar a praticamente a mesma distancia entre 2 *clusters* (ou mais, dependendo do valor *k*), porém, este somente pode compor um deles. Nessa fase, o algoritmo *fuzzy-c-means* utiliza da aplicação de funções baseadas em lógica *fuzzy* para avaliar qual o grau de pertinência do dado nos *clusters* candidatos. Tal comportamento é observado pelas Figura 7-c, representado dado 1 como um ponto limitante entre os centroides 1 e 2, de acordo com as respectivas distâncias $d1c1$ e $d1c2$.

Por sua vez, o algoritmo DBSCAN (*Density-Based Spatial Clustering for Application with Noise*) difere das abordagens anteriores por não necessitar da definição da quantidade de grupos a formar. Esse processo é descoberto ao longo dos cálculos da distância de cada ponto com seus vizinhos, sendo mais rápido que os anteriores. Dessa forma, o algoritmo se baseia num raio de distância ($\mathcal{E}$) que vai delimitar quais dados pertencem àquele grupo. Primeiramente, o algoritmo escolhe um ponto de dado e verifica se dentro do raio estabelecido se encontram dados vizinhos. Todos os vizinhos dentro do raio compõem o *cluster* daquele ponto de dado e o algoritmo executa recursivamente o mesmo raio em todos os valores membros do *cluster*, expandindo o tamanho do grupo caso haja mais dados próximos não agrupados. Caso não sejam encontrados mais dados, significa que não existem mais candidatos ao grupo ou que todos os dados pertencem a um só grupo (o que é indesejável). Assim, se ainda há dados a percorrer, é escolhido um ponto aleatório para que o algoritmo execute um novo agrupamento. A Figura 7-d ilustra o processo para um grupo inicial.

De acordo com a literatura [80], em redes em que os nodos devem atuar de forma precisa sobre a região monitorada ou ainda, para aplicações com foco na detecção de *outliers* (dados anômalos), tanto o algoritmo *fuzzy-c-means* quanto o DBSCAN são alternativas mais interessantes para agrupar dados, em comparação com o *k-means*. Além da velocidade e custo computacional do DBSCAN serem mais interessantes, a abordagem *fuzzy-c-means* pode sobressair-se em relação a definição de novos grupos prioritários.

Ainda sobre os métodos não-supervisionados, a clusterização hierárquica é uma abordagem dita como aglomerativa, que representa cada dado isoladamente como um *cluster* até ramificar-se para todo grupo de pontos no espaço de dados disponível. Esta abordagem também verifica dado por dado a probabilidade de agrupamento entre os pontos, que em seguida serão correlacionados às distâncias dos seus vizinhos. O processo de aglomeração se repete até que se alcancem todos os dados, nesse caso, ilustrados por um dendrograma. Um dendrograma é uma estrutura gráfica que permite visualizar as possibilidades de *clusters* formados a partir das distâncias entre entradas avaliadas. A Figura 7-e destaca o processo e esboça o dendrograma.

Um método de agrupamento por classificação tem sido representado pelo algoritmo *k-NN* (*k-Nearest Neighbors*, ou os *k* vizinhos mais próximos) que nesse caso vai fornecer precisão na classificação de dados quando forem usadas abordagens onde a quantidade de grupos a serem formadas é conhecida. Nesse caso, o valor de *k* recebido pelo *k-NN* não se refere à quantidade de *clusters*, mas à quantidade de dados vizinhos que serão avaliados para decidir a pertinência do dado no grupo. Conforme a Figura 7-b, o dado 1 tem a possibilidade de pertencer ao grupo de círculos verdes ou de losangos vermelhos. Nesse caso, com $k=3$, existem 2 dados em verdes e 1 em vermelho para avaliar, se as distâncias $d1k1$ e $d1k2$ forem menores que $d1k3$, o dado será incluído ao grupo verde,

caso $d1k3$ menor, será classificado como vermelho.

2.3.4 Algoritmos meta-heurísticos

Concomitante às técnicas de AM apresentadas, algumas soluções meta-heurísticas são inspiradas nos sistemas biológicos e no comportamento dos seres da natureza, como os derivados de técnicas evolucionários e baseados em enxame, representados na Figura 8. Estes algoritmos tem estado cada vez mais presentes em soluções para os problemas envolvendo as questões de formação e roteamento de RSSFs, bem como a definição de subconjuntos mínimos e abordagens para clusterização como o problema de cobertura (SCP - *Set Covering Problem*).




Figura 8: Algoritmos meta-heurísticos (adaptada de [52]).

Enquanto técnicas de AM e RNA tentam reproduzir o processo de aquisição de conhecimento humano e replicar o neurônio biológico, abordagens da Computação Evolutiva (em inglês *Evolutionary Computing* e *Evolving Computing*), se inspira na definição de soluções baseadas em populações e comportamento dos animais. A computação evolutiva é, portanto, uma meta-heurística populacional baseada na teoria evolutiva de Darwin, onde os algoritmos resultam da aplicação recursiva de heurísticas baseadas na sequência: reprodução da população, imposição de variações aleatórias, promoção de competição e seleção de candidatos da população.

Dessa forma, a reprodução e evolução das soluções são orientadas por parâmetros que qualificam determinado candidato como mais apto (através da atribuição de notas), dando origem a novas soluções candidatas. Esses parâmetros são chamados hiperparâmetros e o resultado (nota) atribuído à combinação resultante da evolução é chamado de valor relativo adaptativo ou *fitness*. Tal valor é denominado relativo porque, na maioria dos problemas, não é conhecido onde se encontra o ótimo, logo não se pode medir a qualidade do indivíduo de forma absoluta. Trata-se, então, de uma busca em espaço

de soluções candidatas de forma probabilística, onde tal busca compõe as etapas de exploração e exploração, sendo a primeira uma abordagem mais ampla (expandindo a área de busca) e a segunda, uma intensificação do escopo local. Dentre as principais técnicas meta-heurísticas usadas em aplicações [RSSFs](#) para os problemas mencionados destacam-se os Algoritmos Genéticos (*Genetic Algorithm* ([GA](#))), *Simulated Annealing* ([SA](#)), Colônia de Formigas (*Ant Colony Optimization* ([ACO](#))) e [PSO](#) conforme representado na Figura 8.

A maioria dos algoritmos meta-heurísticos possuem flexibilidade em sua definição, seja na forma de inicialização de candidatos, modificação de hiper-parâmetros e definição da função d e *fitness*. Esta última sendo caracterizada pela etapa de maior importância, e as vezes maior complexidade, nestes algoritmos. Um exemplo bastante comum, em abordagens baseadas em [GAs](#) são aplicados às etapas de reprodução e evolução os mecanismos de clonagem, mutação e *crossover*, que são conduzidos por critérios de parada e pela função *fitness*. Abordagens baseadas em [SA](#) por sua vez possuem uma fase de exploração maior que a abordagem de [GAs](#) por aplicar hiper-parâmetros que simulam a variação de temperatura intercalando entre aquecimento e resfriamento de um sistema que vai reproduzir a descoberta de uma solução mais eficaz. Técnicas de [SA](#) são bastante usadas no problema de caixeiro viajante, que também é comumente presente na definição de roteamento em [RSSFs](#) e definição de subgrupos mínimos.

A abordagem adotada neste trabalho utiliza algoritmos meta-heurísticos, em especial o Particle Swarm Optimization (PSO). Assim como os algoritmos genéticos, o método opera com populações que evoluem ao longo das iterações, definindo uma função de *fitness* responsável pela seleção da configuração ótima. O [PSO](#) permite ajustar parâmetros que equilibram a busca por ótimos locais e globais, controlando as fases de exploração e exploração, de modo semelhante ao Simulated Annealing. Os detalhes do [PSO](#) são apresentados a seguir.

Abordagens baseadas em otimização por enxame de partículas – A otimização por enxame de partículas, ou [PSO](#) é uma área da Inteligência Computacional mais especificamente do ramo da Computação Natural que se baseia no comportamento dos seres da natureza. [PSO](#) é uma das técnicas de otimização mais simples, que consiste em uma abordagem bioinspirada nos movimentos de animais, como gatos, peixes e bandos de pássaros em busca de alimento e abrigo. A base do algoritmo compreende partes cognitivas e sociais, que conduzem a evolução das partículas à medida que o valor da função de aptidão é minimizado ou maximizado.

Convencionalmente, a velocidade e a posição das partículas são definidas da seguinte forma:

$$v_{t+1} = \underbrace{\omega \cdot v_t}_{inertia} + \underbrace{c1\varphi1 \cdot (P_b - x_i)}_{cognitive\ part} + \underbrace{c2\varphi2 \cdot (G_b - x_i)}_{social\ part} \quad (3)$$

$$x_{t+1} = x_t + v_t \quad (4)$$

onde v_{t+1} é a velocidade da partícula calculada a partir da velocidade em um instante anterior t ; x_{t+1} é a posição resultante da velocidade aplicada sobre a partícula; P_b corresponde à melhor posição individual de uma partícula; e G_b corresponde à melhor posição do enxame. Cada parte da Eq. 3 é ponderado pelas constantes de aceleração $c1$ e $c2$, e ω

correspondendo ao fator de inércia que é usado como critério de parada. Tais constantes possuem valores de domínio real no intervalo $[0,1]$.

Como é comum nas técnicas de otimização, exploração e exploração são dois conceitos que se referem a diferentes formas de buscar soluções ótimas. A exploração envolve a busca por regiões novas e inexploradas do espaço de busca, enquanto a exploração envolve a iteração entre as soluções alcançáveis no escopo local para otimizar ainda mais a combinação de posições possíveis. As fases de exploração e exploração do algoritmo PSO são balanceadas por ω cujo valor inicial é geralmente próximo de 1 (por exemplo, 0.9), que deve ter comportamento adaptativo, decaindo ao longo das iterações até que a partícula atinja a convergência.

Conforme novas modelagens foram sendo feitas, o algoritmo PSO original sofreu modificações interessantes para lidar com problemas combinatórios e definir soluções no espaço discreto. As abordagens focadas na classificação e definição de uma saída descontínua são geralmente denominadas PSO Discreto (DPSO) ou PSO Combinatório – *Combinatorial Particle Swarm Optimization* (CPSO). Neste caso, a função velocidade não é definida aproximadamente pela Eq. 4, uma vez que representa um valor contínuo e, portanto, a posição pode ser definida como:

$$x_{t+1} = \begin{cases} 0, & \text{if } x_t = P_b \\ 1, & \text{if } x_t < G_b \\ -1, & \text{otherwise} \end{cases} \quad (5)$$

onde os resultados, em uma abordagem DPSO, podem inferir o movimento das partículas em direção a um valor influenciado pelo comportamento exploratório individual ou global, melhor ou aleatório.

Um caso particular é quando existem apenas duas saídas possíveis. Essa abordagem é chamada de PSO Binário – *Binary Particle Swarm Optimization* (BPSO). Assim, a maneira mais simples de definir a posição é a seguinte:

$$x_{t+1} = \begin{cases} 0, & \text{if } rand() \geq S(x_t) \\ 1, & \text{otherwise} \end{cases} \quad (6)$$

onde um valor aleatório $rand()$ é gerado e comparado com um método de discretização $S(x_t)$. O método mais utilizado na literatura corresponde a uma definição de bit baseada na função sigmóide como $S(x_t) = 1/(1 + e^{-x_t})$.

2.3.5 Considerações referentes às abordagens baseadas em IA

Esta seção apresentou e discutiu as principais técnicas de IA atualmente utilizadas e que se adequam às necessidades de sistemas IoT e de soluções envolvendo RSSFs orientadas a dados. Além disso, foram explorados algoritmos e técnicas de otimização baseados em meta-heurísticas, voltados à busca por soluções mais eficientes. Na sequência, discute-se como essas técnicas se relacionam com os mecanismos implementados na arquitetura proposta nesta tese, considerando os objetivos definidos no escopo da pesquisa.

Embora não garantam a solução ótima, abordagens de otimização podem resultar em melhores configurações em tempo satisfatório, obedecendo às limitações impostas pelos

dispositivos e cenários específicos estudados ao longo deste trabalho. Visto que a maioria dos problemas dessas redes pode ter como gargalo a capacidade de processamento e a energia gasta no momento da configuração, abordagens de otimização com algoritmos mais simples se mostram interessantes na definição de soluções quando comparadas às técnicas derivadas da [AM](#). Este ponto é relevante principalmente quando se trata de problemas de natureza *NP-complete* e *NP-hard*, como *SCP*, *Minimum Set*, ESM e a definição de caminhos em grafos acíclicos, os quais exigem poder computacional alto de dispositivos robustos e aplicações em nuvem.

É importante enfatizar que a proposta desenvolvida neste trabalho descreve um processamento de borda na arquitetura [IoT](#), como uma solução que deve atender a nodos implantados em locais onde a comunicação com a nuvem possa ser inviável e em casos onde a resposta deve fluir tão breve quanto é recebida dos sensores. Como se trata de um mecanismo que, em diferentes estágios, lida com o gerenciamento dos dados para descoberta de padrões de similaridade (periodicidade de transmissão) e obtenção de conhecimento, cada processo deve compor uma técnica adequada para tais objetivos. Logo, tanto para agrupar dados quanto para lidar com incertezas na etapa de formação da rede, as técnicas utilizadas em cada módulo da arquitetura proposta no [Capítulo 4](#) foram definidas com base no levantamento bibliográfico realizado.

O estudo foca em técnicas de clusterização de dados e otimização da tomada de decisão no processo de formação de *clusters*, seleção de *cluster-heads* e escalonamento da atividade dos nós de forma adequada. Cada processo operando em conjunto para atender cenários onde a comunicação remota é limitada ou onde é necessário obter respostas rápidas diretamente dos sensores. A clusterização tem como objetivo classificar os nodos em prioridades de acordo com o tráfego gerado em cada região monitorada. Enquanto a formação dos *clusters* e seleção dos [CHs](#) descreve a melhor combinação de caminhos em que a entrega de mensagens é priorizada. É importante destacar que essa abordagem visa agrupar os dados monitorados, e não os nodos em clusters de comunicação, o que é uma distinção importante no contexto de [RSSFs](#).

Além disso, a análise topológica da rede envolve conceitos da teoria dos grafos, como caminhos mínimos, árvores geradoras mínimas (*Spanning Trees*) e grafos ponderados com base em custos de enlace. A complexidade envolvida pode variar de logarítmica, como em buscas em árvores ($O(\log n)$), até exponencial ou fatorial ($O(e^n)$, $O(n!)$), conforme o tamanho do espaço de busca varia. Em redes com centenas de nodos, muitas combinações de topologias tornam-se inatíveis até mesmo para dispositivos robustos.

Nesse contexto, técnicas inspiradas na Computação Natural, como Algoritmos Genéticos (GA) e *Simulated Annealing* (SA), têm se mostrado eficazes para explorar espaços de busca extensos. Essas técnicas envolvem fases de exploração e exploração, assim como em soluções de *Aprendizagem por Reforço* ([AR](#)), e são capazes de buscar soluções adequadas em tempo polinomial $O(n^k)$, conforme demonstrado por [\[10\]](#). O *Simulated Annealing*, por exemplo, busca evitar ótimos locais com o uso de funções probabilísticas, enquanto os Algoritmos Genéticos simulam populações evolutivas para encontrar soluções viáveis ao longo de gerações. Este comportamento é semelhante a evolução de partículas usadas pelas abordagens de [PSO](#).

Essas abordagens meta-heurísticas são valiosas justamente por sua adaptabilidade e capacidade de lidar com problemas complexos sem exigir modelagens específicas para

cada situação. Superam, em muitos casos, técnicas tradicionais como algoritmos gananciosos, busca em profundidade e A*, tanto em eficiência quanto em tempo de resposta.

Assim, a técnica abordada na proposta deste trabalho considera o uso de PSO e suas variantes discretas (como BPSO, CPSO) para construção de mecanismos de formação topológica adequados à priorização de *hotspots* em RSSFs. Além disso, a técnica usada é comparada com abordagens heurísticas e outras abordagens de otimização simplificadas discretas, destacando a complexidade algorítmica e obtenção de soluções ótimas. Algo que assim como nos métodos usados em GA e SA podem ser obtidos com ajustes estratégicos e funções probabilísticas. Para isso, a técnica utiliza meta-heurística para atingir múltiplos objetivos de QoS ao mesmo tempo em que preserva o uso baixo de energia, e se faz relevante especialmente quando comparados a abordagens que aplicam TinyML e soluções em nuvem.

O capítulo seguinte discorre sobre os principais trabalhos que envolvem as soluções de RSSFs e IoT, que lidam com os problemas descritos e que utilizam os algoritmos e abordagens explorados nesta seção. Nele, são sumarizados aqueles que apresentam melhorias e objetivos similares aos tratados pela proposta deste trabalho, destacando técnicas e metodologia abordada para implementação.

3 Trabalhos Relacionados

Este capítulo apresenta os trabalhos mais relevantes em relação à proposta desta tese de doutorado. Entre eles, são destacados os trabalhos que envolvem a formação topológica de **RSSFs** que preocupam-se com a preservação da vida útil da rede, Qualidade de Serviço (**QoS**) e a diferenciação de fluxos de dados. Além disso, são sumarizados as propostas que focam na implementação de esquemas compatíveis com o padrão IEEE 802.15.4, bem como as propostas que utilizam técnicas de inteligência no desenvolvimento de protocolos e mecanismos baseados em dados de monitoramento, seleção de rotas e nodos para formar estruturas de redes, escalonamento de atividades e gerenciamento da comunicação.

3.1 Trabalhos com Foco na Eficiência Energética

Primeiramente, é importante destacar que existe uma abordagem bastante difundida na literatura, denominada de *Low-Energy Adaptive Clustering Hierarchy* (**LEACH**) [38], que veio a se tornar referência em redes baseadas em *cluster* devido ao foco na eficiência energética e no desempenho dos nodos em atividade na rede. Tal protocolo tem contribuído para abordagens que vieram a compor o estado-da-arte no contexto de preservação da bateria em redes de monitoramento, originalmente visando controlar o consumo energético dos nodos de uma **RSSFs** através do revezamento na seleção de *cluster-heads* (**CHs**), o que também contribui para o balanceamento da carga processada em cada região monitorada.

Topologias de **RSSF** em geral, utilizam o escalonamento de atividades frequentemente para atender aos requisitos de energia e comunicação, através de estratégias de revezamento. No caso do **LEACH**, o revezamento é realizado entre os nodos que ora atuam como nós finais, ora como *cluster-heads*, o que proporciona a economia de recursos energéticos, pois enquanto um nodo está “acordado” realizando operações, os demais podem “dormir” economizando a bateria. Porém, tal estratégia dificulta o gerenciamento da informação coletada pelos nós-sensores e pode impedir que a Qualidade de Serviço (**QoS**) seja obtida devido às frequentes modificações na topologia que este processo causa. Assim, as propostas derivadas do protocolo LEACH original passaram a englobar o escalonamento de atividades dos nodos, diferenciação de tráfegos e mecanismos de controle topológico de forma a aprimorar a seleção de nodos na formação das estruturas.

Esquemas como: **DL-LEACH** [60], **LEACH-MAE** [3], **Q-LEACH** [24], entre outros, são abordagens derivadas do protocolo LEACH original que aplicam diferentes metodologias para reduzir constantes modificações na topologia ao mesmo tempo em que permite prolongar a vida útil dos dispositivos. Neste contexto, a proposta LEACH-MAE (*LEACH Mobile Average Energy based*) [3] implementa um mecanismo para selecionar melhores nodos **CHs** em **RSSFs** com nodos móveis, que define uma probabilidade de seleção para cada nó candidato proporcional a energia residual média coletada dos nodos identificados. Esta estratégia é frequentemente utilizada na literatura, que embora possibilite mapear os nodos com melhor capacidade de coordenação a partir dos recursos identificados, exige a troca de informação adicional entre os nodos para notificar a vizinhança sobre o nível de energia que estes armazenam, o que aumenta a carga.

A proposta **DL-LEACH** (*Double Level LEACH*) [60] propõe um mecanismo de dupla seleção de *cluster-heads*, que primeiro identifica os nodos candidatos pela sua energia residual, formando uma topologia inicial como a abordagem anterior, mas em seguida considera a profundidade e quantidade de nodos vizinhos como critérios para correção da topologia a fim de balancear a carga em *clusters* mais próximos da estação base. O processo é semelhante ao mecanismo de partição topológica utilizado em **LEACH-PT** [35] e **P-LEACH** [82]. Sendo **P-LEACH** uma abordagem que combina protocolo LEACH com uma arquitetura chamada de PEGASIS [45], voltada para a disseminação de mensagens em fluxo de convergência, que forma *clusters* antes de criar rotas até uma estação base. Essa ideia pretende isolar ramos com diferentes carga de dados de modo que o balanceamento dos tráfegos seja controlado pelo **CH** no momento da associação dos nodos.

Enquanto isso, **LEACH-PT** (*LEACH Partition Topology*) [35], propõe a formação da topologia dividida em regiões, de modo a limitar a quantidade de *clusters* formados para que não exceda a quantidade de carga e conseqüentemente, economize energia dos nodos. No entanto, embora tais abordagens forneçam melhorias no que diz respeito ao consumo de energia, as métricas de rede que envolvem **QoS** são impactadas negativamente pela modificação frequente na rotação de **CHs**, tanto em redes móveis quanto em redes estacionárias. Além disso, a construção não uniforme da topologia não garante total cobertura da rede monitorada, sendo inviável priorizar tráfegos distintos.

Recentemente, o trabalho em [32] correlacionou a distância entre os nodos, juntamente com a profundidade e as informações de carga de cada nodo, para amenizar os problemas causados pela rotação dos **CHs**. Esta abordagem usa como base a ideia de limiares definidos no esquema **Q-LEACH** (*Quadrant-LEACH* trabalho proposto por [24] que considera dividir a rede em regiões de interesses conforme os dados monitorados) para avaliar o número de *clusters* formados e sua influência no prolongamento do tempo de vida da rede. Porém, o ponto crítico desta proposta é a utilização do sinal **RSSI** (*Received Signal Strength Indicator*) para a fase de seleção de nodos, além de considerar o uso de equipamentos de GPS (*Global Position System*) para obter a informação de localização dos nodos na formação de *clusters*, o que aumenta significativamente o consumo energético da rede.

O uso de **RSSI** é comumente utilizado na associação dos nodos e é realizado por meio da troca de informação pelo canal sem fio. A detecção deste indicador pela camada física pretende estimar a distância entre os nodos envolvidos e na maioria das vezes é utilizada para selecionar nodos mais distantes para que maior cobertura seja alcançada. No entanto, o uso de tal recurso é uma questão de pesquisa frequentemente levantada sobre a confiabilidade do canal sem fio, que enfrenta a presença de obstáculos e ruídos provocados por fatores externos, fazendo com que o valor de **RSSI** detectado não corresponda à distância real dos dispositivos. Além disso, o uso de componentes de *hardware* para orientar os nodos sobre a localização, como o caso do GPS, é uma prática não recomendável tanto pelo consumo de bateria adicional quanto pelo custo de acoplamento aos nodos.

3.2 Trabalhos com Foco na Formação Topológica

Abordagens de formação topológica podem ser classificadas como centralizadas ou distribuídas. Nas abordagens centralizadas, as decisões são tomadas por uma entidade com visão global da rede, o que facilita o cálculo de rotas e a definição dos melhores caminhos de comunicação entre origem e destino [15]. Por outro lado, nas abordagens distribuídas, cada nó toma decisões de forma autônoma, baseando-se apenas nas informações locais de sua vizinhança — geralmente de um ou dois saltos — o que reduz a necessidade de controle centralizado e aumenta a escalabilidade da rede.

Uma abordagem centralizada foi proposta no trabalho descrito em [11] chamada de **GTC** (*Generic Top-down Clustering*) que pretende conectar ramos em uma *cluster-tree* a partir da escolha proporcionada pela estação base. Tal proposta é baseada na ideia de formação de *cluster* discutida pelos mesmos autores em [12] denominada de **HHC** (*Hop-ahead Hierarchical Cluster*). Nesse caso, a formação segue um modo *top-down* que não considera informações de vizinhança, profundidade, localização ou sincronização de tempo de atividade dos nodos. A seleção de CHs então é realizada considerando o tempo de vida (TTL – *Time To Live*) das mensagens que levam para atravessar cada nível da *cluster-tree* a fim de aumentar a escalabilidade da rede percebendo-se o alcance destas mensagens. Assim, limites são definidos para o número máximo de membros em um *cluster* e número de CHs filhos para cada CH de modo que não sobrecarregue a estação base ou os demais CHs com a ramificação de muitas rotas. Esta proposta inicialmente reduz a sobrecarga da fase de associação, mas após este processo a estrutura resultante é então reajustada em uma etapa adicional que utiliza os parâmetros de energia e profundidade de cada nó, modificando a topologia. Além disso, o trabalho não avalia as métricas de QoS, exceto para a avaliação da energia impactada pelo número de *clusters* formados.

Por sua vez, o trabalho de [16] implementa uma abordagem de formação *bottom-up* distribuída com foco na auto-organização dos nodos, chamado de **Self-Organization method**. Neste caso, a formação da rede *cluster-tree* é dividida em duas etapas, sendo a primeira baseada na política de seleção do melhor nodo CH considerando sua carga energética, e a segunda, a formação da árvore a partir da escolha feita pelos CHs definidos conforme os dados monitorados em cada *cluster*. Embora a proposta esteja focada em formar uma RSSF de modo distribuído entre cada *cluster*, a subdivisão da fase de formação e a configuração da árvore resultante cria um gargalo na rede, o que pode aumentar a sobrecarga de comunicação e desperdiçar energia em uma fase em que isso deveria ser evitado. A proposta se destaca por ter sido implementada em ambientes do mundo real e com equipamentos compatíveis com IEEE 802.15.4, no entanto, as métricas de QoS não foram abordadas.

3.2.1 Formações topológicas orientadas a dados

Nesta seção são apresentados trabalhos que tratam da formação topológica de RSSFs, do escalonamento das atividades dos nodos, da priorização de tráfego de dados e de abordagens baseadas no padrão IEEE 802.15.4, nas quais o comportamento da rede é ajustado dinamicamente a partir dos dados gerados pela própria aplicação. Muitos desses traba-

lhos são classificados como *data-driven*, pois utilizam os dados coletados pelos sensores — tais como temperatura, umidade e pressão — não apenas para o monitoramento do ambiente, mas também como fonte de informação para detectar mudanças no ambiente monitorado e acionar mecanismos de adaptação na rede. Esses dados, portanto, diferenciam-se daqueles voltados ao monitoramento do próprio sistema, como profundidade da árvore, vizinhança entre nodos ou nível de energia residual, que refletem o estado interno da rede.

Uma proposta da literatura que permite priorizar diferentes tráfegos de dados é o chamado esquema **DbCTF** (*Data-based Cluster-Tree Formation*) [9] que utiliza os dados monitorados de um ambiente do mundo real para agrupar nós de acordo com suas características. As características de dados representam a periodicidade em que os dados são coletados pelos nós-sensores, que nesse contexto podem ser classificados como nodos prioritários, quando a taxa de geração de dados periódica é alta ou não prioritários, quando esta taxa é baixa. Nessa abordagem, os *clusters* são formados pela ação do Coordenador do PAN que seleciona os nodos em um estilo *top-down* e com base no valor de **RSSI** obtido. Antes da fase de seleção, os dados de todos os nodos são submetidos a um processo de clusterização por meio do algoritmo *K-means*, formando uma rede homogênea de *clusters*. Embora tal abordagem promova auto-adaptação ao ambiente monitorado pela técnica de agrupamento precedente a fase de seleção, o esquema orientado pelo **RSSI** na fase de associação esbarra nas questões de confiabilidade, além da rede resultante apresentar uma quantidade considerável de nós modificados (nós com prioridade mais baixa tornam-se nós de prioridade mais alta), o que aumenta a carga processada pela rede impactando negativamente nas métricas de QoS.

Anteriormente, um algoritmo para formação redes em *clusters* proposto por [98] denominado **CHSMST+** (*Clustering based on Hyper Surface and Minimum Spanning Tree Plus*) utilizou os dados obtidos de vários pontos da área monitorada em uma cidade, para criar topologias a fim de informar a estação base sobre eventuais problemas urbanos, como acidentes e congestionamentos, por exemplo. Tal abordagem envolve algoritmos de roteamento para buscar menor caminho na estrutura resultante (do grafo), o que também busca reduzir o consumo dos nodos participantes do processo de formação da rede. Tal abordagem não avalia qualquer métrica de **QoS** ou em relação ao consumo energético.

Por sua vez, o trabalho intitulado **ACA**rch (*Adaptive Clustering Architecture*) [91] implementa um modelo de formação distribuído para redes *cluster-tree* preocupando-se em fornecer **QoS**. Nesse caso, a seleção de nodos utiliza de um arquitetura em que o algoritmo de formação inicia no coordenador PAN e em seguida repassa para cada **CH** o poder de decidir como formar novos *clusters*, o que torna a proposta distribuída. Nesse trabalho foi utilizado um esquema de distribuição de período de atividade dos nodos proporcional aos dados processados em cada *cluster*, embora tal proposta não utilize os dados como critério para formação, somente para escalonamento de *beacons* conforme a subcamada MAC do padrão IEEE 802.15.4.

É importante destacar que o modelo de escalonamento de *beacons* é uma estratégia bastante utilizada na literatura, principalmente para redes baseadas no IEEE 802.15.4 com foco no gerenciamento eficiente da comunicação e da economia de energia. As vantagens de tal estratégia são demonstradas no trabalho de [50, 51] denominado de

TDBS (*Time Division Beacon Scheduling*), que por meio de técnicas de escalonamento lida com os principais problemas na comunicação de redes em *clusters* referentes ao canal sem fio, colisões, ciclo de serviço dos *cluster-heads* e nodos membros, entre outros.

Assim, propostas como as de alocação de banda e reordenação definidas no trabalho de [88], aprimoram o escalonamento através de uma abordagem dinâmica de configuração dos *clusters*. Posteriormente, seguindo esta linha, os esquemas implementados por [55] distribuem a duração de *superframes* (**SD** – *Superframe Duration*) conforme os dados detectados pelos nós-sensores, promovendo assim abordagens mais eficientes para abordar as questões levantadas em [50] e [51].

Basicamente, a proposta **DBR** (*Dynamic Bandwidth Re-allocation*) e **DCR** (*Dynamic Cluster scheduling Reordering*) [88] projetam uma *cluster-tree* para reordenar dinamicamente **CHs** e realocar sua largura de banda. O esquema de reordenamento **DCR** compreende um algoritmo que executa o escalonamento com base na prioridade, número de ciclos, conjunto de nós vizinhos e profundidade dos **CHs**. Enquanto isso, o esquema de alocação **DBR** aumenta a largura de banda dos **CHs** ao mesmo tempo em que diminui de outros. Contudo, embora as abordagens sejam dinamicamente adaptadas à rede, o método não considera a carga imposta pelos nós sensores ou uma formação de rede direcionada.

Por outro lado, o trabalho de [55] consiste da definição de dois mecanismos de alocação de *superframes*: **Load-SDA** e **Nodes-SDA**. A abordagem **Load-SDA** considera a carga de dados gerada pelos nós sensores, permitindo a definição de períodos ativos de comunicação proporcionais para cada **CH**. Já a técnica **Nodes-SDA** considera a quantidade de nós descendentes de cada **CH**, definindo proporcionalmente os valores para *SD* e *BI* de cada *cluster* de acordo com a densidade obtida.

Essas abordagens conduzem a construção de esquemas eficientes tanto para priorização de diferentes fluxos quanto para algoritmos de escalonamento de *clusters*. Um exemplo, é o mecanismo implementado em [57], denominado de **Fast-HyBeS** (*Fast Hybrid Beacon Scheduling*), que consiste de uma abordagem híbrida de escalonamento para disseminação rápida de mensagens de controle em tráfego *downstream*, ao mesmo tempo em que reduz os atrasos fim-a-fim processado durante o fluxo de monitoramento. Posteriormente, um mecanismo de reconfiguração dinâmica de redes *cluster-tree*, denominado de **DyRET** (*Dynamic REconfiguration mechanism of cluster-Tree*) [63] voltado para aplicações em larga-escala, considerando situações de desastres e sistemas de tempo-real, baseia-se nesta ideia para permitir que os nodos atuem sobre a rede monitorada, reconfigurando adequadamente cada *cluster* conforme eventos são detectados pelos nós-sensores.

3.2.2 Formações voltadas para aplicações IoT

Por sua vez, o trabalho intitulado **EDS-MAC** (*Energy-efficient Dynamic Scheduling hybrid MAC protocol*) [96] utilizou os dados de energia para escalar a comunicação entre os nodos em uma rede para aplicações **IoT** na indústria. O mecanismo é dividido em dois estágios: a formação de *clusters* e a transmissão de dados baseada no esquema de formação proposto. Para isso, o esquema de seleção de nós **CHs** inicia no coordenador PAN e em seguida é distribuído pelos próprios **CHs** eleitos, conduzindo a priorização

dos tráfegos de dados conforme a energia e a posição dos nodos é descoberta localmente. Portanto, trata-se de uma abordagem semi-distribuída que visa fornecer QoS, embora não seja baseada nos dados monitorados.

Similarmente, um trabalho recente denominado **CTEEDG** (*Cluster-Tree based Energy Efficient Data Gathering*) [46] também focado em aplicações industriais no âmbito da IoT, propõe um mecanismo robusto para formação de topologia de *cluster-tree*, que implementa um método de lógica *fuzzy* visando encontrar um valor de aptidão para o número de CHs na RSSF. Assim, a topologia é formada após a fase de seleção dos nodos e a fase de definição de papéis que cada um destes executa na rede, compreendendo um processo de aprovação entre nós de um mesmo *cluster*. Este processo é um fator limitante da proposta, visto que para cada *cluster-head* que executa o sistema de *fuzzyficação*, o mecanismo requer alta capacidade de processamento dos nós intermediários, bem como alguma capacidade de armazenamento de memória para lidar com a sobrecarga (*overhead*) nas trocas de mensagens na fase de seleção e aprovação dos nós participantes em cada *cluster*.

3.2.3 Comparação entre propostas de formação topológica

A Tabela 2 sumariza as principais abordagens discutidas nas subseções anteriores.

Tabela 2: Trabalhos relevantes à formação topológica de RSSFs.

Proposta	Características					
	Abordagem	Direção	Baseado em Dados	Eficiência Energética	QoS	Priorização de Tráfegos
DL-LEACH [60]	Centralizada	-	✗	✓	✗	✓
LEACH-MAE [24]	Distribuída	BU	✗	✓	✗	✗
P-LEACH [82]	Distribuída	BU	✓	✓	✗	✗
LEACH-PT [35]	Distribuída	TD	✓	✓	✗	✗
Self-Organiz [16]	Distribuída	BU	✓	✓	-	✗
ACArch [91]	Distribuída	TD	✓	✓	✓	✗
CHSMST+ [98]	Distribuída	-	✓	✗	-	✓
GTC, HHC [11]	Centralizada	TD	✗	✓	✓	✗
DbCTF [9]	Centralizada	TD	✓	✗	✓	✓
CTEEDG [46]	Distribuída	TD*	✗	✓	✓	✓
EDS-MAC [96]	Semi-distribuída	BU*	✗	✓	✓	✓

NOTA: TD “*Top-down*”; BU “*Bottom-up*”; * “mecanismos que não utilizam abordagens puras”; - “mecanismos que não identificam tal característica”.

3.3 Trabalhos com Formação Baseadas em Inteligência Artificial

Nesta seção são apresentados os principais trabalhos que utilizam técnicas de Inteligência Artificial (IA) no processo de formação topológica de redes. A Subseção 3.3.1

destaca propostas que envolvem a eficiente clusterização de nodos (agrupamentos de nodos fisicamente na rede) e as etapas de seleção de CHs e formação de rotas até a estação base. Assim, os trabalhos sumarizados envolvem as abordagens que fazem uso de AM e algoritmos de otimização para selecionar CHs, formar *clusters* e definir rotas entre os nós-sensores e a estação base. A Subseção 3.3.2 faz um comparativo destas abordagens.

3.3.1 Estratégias usando IA para formação topológica

Como mencionado, o problema em definir uma topologia ideal a partir dos nodos de um ambiente de monitoramento em larga-escala pode ter complexidade exponencial ou fatorial, dependendo de como este é modelado. Nesse sentido, para obter soluções em tempo polinomial, frequentemente são utilizadas as técnicas de otimização, que em sua maioria, derivam de técnicas do ramo da IC e que abordam o uso de lógica difusa (*Fuzzy*), AG e *Simulated Annealing*. Por outro lado, alternativas de otimização de busca pela solução ótima em menor tempo, abordagens derivadas da AM envolvem algoritmos supervisionados, não-supervisionados, semi-supervisionados e o AR, entre outras técnicas de aprendizagem.

Em redes baseadas em *clusters*, a qualidade da comunicação entre os nodos pode ser estabelecida por um método de clusterização adequado (nesse caso, considerando que o agrupamento é realizado associando-se os nodos fisicamente na rede). Assim, quanto mais nodos podem ser agrupados em um mesmo *cluster*, menos saltos são necessários para a informação ser propagada e maior cobertura da região monitorada é obtida. Além disso, a clusterização de nodos acarretam em vantagens significativas para a agregação dos dados em redes de monitoramento e no gerenciamento da comunicação.

Um trabalho recente, intitulado **HQCA** (*High Quality Clustering Algorithm*) [13], busca otimizar o método de agrupamento dos nodos de modo que, o processo de seleção de CHs tenha complexidade reduzida. Inicialmente, são formados os *clusters* com base na distância geográfica entre os nodos, para que cada nodo no grupo obtenha as informações de toda a vizinhança. Em seguida, a partir da análise do valor de energia residual de cada grupo, os CHs são selecionados. A primeira fase consiste em dividir o ambiente em *grid* (rede em grade com regiões separadas por blocos), formando uma topologia inicial com os nodos em cada bloco. Em seguida, são agrupados os nodos com base na distância obtida por cada nodo da *grid* (chamada de distância *intra-cluster*), que por sua vez, conduz a conexão entre os *clusters* a partir da distância entre blocos com diferentes *clusters* (distância *inter-clusters*). Quando todos os *clusters* estão formados, o método de seleção de CH é realizado em cada *cluster* por meio de um processo de *fuzzificação* e *defuzzificação* que envolve o valor da energia residual dos nodos membros, definida como “baixa”, “media”, “alta” e “muito alta”, além da distancia *inter-cluster* que pretende reduzir a quantidade de saltos até a estação base, definida como “longe”, “perto” e “média”.

O trabalho apresenta uma importante métrica de avaliação da eficiência energética da rede, como a estimativa do tempo de vida dos nodos, avaliando diferentes técnicas de clusterização dos dados (nesse caso, dados de energia do nodo), quantidade de *clusters* formados e relação de tempo de atividade dos nodos CHs. Porém, tal abordagem não preocupa-se com a eficiente comunicação dos nodos, Qualidade de Serviço (QoS) e ainda,

considera o uso de equipamentos GPS para formar os *clusters* na fase inicial.

Desse modo, a ideia de prover QoS em RSSFs baseadas no padrão IEEE 802.15.4 foi abordada e implementada em um experimento real (*testbed*) no trabalho denominado de **GMLA** (*Genetic Machine Learning Algorithm*) [78]. Nessa proposta, um Algoritmo Genético foi utilizado para otimizar o processo de troca de mensagens entre os nodos sensores e a estação base, com intuito de assegurar que a entrega de mensagens para o nó *sink* não reduza drasticamente conforme aumentam a quantidade de nodos membros da rede. Embora tal abordagem não tenha focado nos dados monitorados pela aplicação ou pretenda priorizar tráfegos distintos, o resultado apresentado demonstra que é possível aumentar a entrega de mensagens disseminadas para o *sink* ao mesmo tempo em que preserva a vida útil dos nodos, mesmo em uma rede em topologia estrela. Assim, a cada novo membro conectado à estação base o algoritmo trata cada nodo como um indivíduo da população que evolui a cada geração que mede a porcentagem de mensagens entregues com sucesso (métrica definida como Qof – *Quality of Freshdata*) e o nível de energia residual (E_f – Eficiência energética).

Seguindo a ideia de prolongar a vida útil dos CHs e escolher melhores rotas entre *clusters* e a estação base, a proposta denominada de **GA-ANFIS** (*Genetic Algorithms with Adaptive Neuro-Fuzzy Inference System*) [6] utiliza um método para criar *clusters* com base na informação de distância (geográfica) obtida entre os nodos e a estação base. Tal método consiste de um Algoritmo Genético que otimiza o processo de agrupamento dos nodos conforme novas gerações são executadas envolvendo cada nodo do *cluster*.

Em seguida, a seleção de melhor candidato a CH é realizado dentro de *cluster* por meio de lógica *fuzzy*, que define índice de “alta”, “média” e “baixa” probabilidade a um CH candidato, com base na distância (profundidade) e valor de energia residual. Assim, quanto maior energia residual e menor a distância da estação base, maior probabilidade o nodo possui de se tornar CH, da mesma forma, a definição de rota (escolha de qual nodo deve ser pai ou filho na relação entre os *clusters*) segue a mesma abordagem. Embora estas não sejam abordagens que proporcionam priorização de tráfegos de dados, importantes métricas de QoS e energia foram avaliadas pelo método proposto.

Outra abordagem com foco na otimização do processo de formação da rede é denominada de **DESA** (*Differential Evolution and Simulated Annealing*) [79] que combina um mecanismo baseado em programação genética, para agrupar os nodos do ambiente, e um método de seleção de CHs que busca pela solução ótima global do grafo conectado através da técnica *Simulated Annealing*. Embora tal abordagem não considere os dados monitorados, uma avaliação do tempo de vida dos nodos CHs, bem como a quantidade de *clusters* ótima e o QoS (que avalia a quantidade de mensagens entregues à estação base) foram questões abordadas pelo processo de otimização proposto.

Considerando as abordagens baseadas em AM, algumas abordagens mais recentes tem utilizado de algoritmos não-supervisionados, supervisionados e semi-supervisionados, bem como o AR. Assim, uma proposta focada no consumo energético de nodos CHs é implementada no trabalho nomeado de **EKMT** (*Energy K-Means Technique*) [43]. Nessa abordagem, os nodos da rede são agrupados considerando uma execução do algoritmo *K-means* de modo multidimensional, que se baseia nos dados de distância geográfica entre os nodos e a estação base, além de considerar o valor de energia obtido em cada *cluster*.

Desse modo, uma topologia inicial é formada considerando a distância obtida pelos nodos em relação aos vizinhos, que tem inicialmente um **CH** eleito pelo valor de energia residual mais próximo de um limite pré-estabelecido. Em seguida, uma reconfiguração da topologia é realizada com base na re-execução do *K-means*, para definir o melhor nodo a se tornar **CH** após a modificação do valor de centroide identificado no processo de clusterização. O trabalho preocupa-se principalmente com a preservação da vida útil dos nodos e pretende reduzir a profundidade da rede a partir da clusterização dos dados referente à energia e localização geográfica dos nodos com o *sink*. A abordagem não considera os dados monitorados pelos nodos (somente dados de energia e localização), mas os atrasos fim-a-fim, a entrega de mensagens ao *sink* e a energia são avaliados em comparação com uma técnica de *K-means* unidimensional.

Seguindo a mesma técnica de clusterização, um trabalho focado em prevenir ataques a **RSSFs** baseadas em *cluster* utiliza o *K-means* para identificar *outliers* (anomalias) em relação ao tráfego percebido por cada **CH**. O algoritmo é chamado de **Hybrid Anomaly Detection Algorithm** [100] e é aplicado localmente, em cada *cluster*, sendo uma reconfiguração para seleção de novos **CHs** realizada a cada nodo identificado por um limiar que distancia sua taxa de dados do valor de centroide definido. Este mecanismo permite identificar e evitar os ataques que sobrecarregam a rede, ao mesmo tempo em que bateria dos nodos é conservada. O algoritmo considera apenas a carga de dados imposta em cada *cluster*, não necessariamente considerando os valores monitorados para identificar anomalias. Porém, os atrasos de comunicação fim-a-fim são avaliados para os cenários de ataques mais conhecidos no contexto de **RSSFs**.

O trabalho intitulado **SSCFD** (*Semi-Supervised Clustering Fire Detection*) [94] implementa um modelo de clusterização baseada nos dados monitorados para selecionar **CHs** e classificar diferentes regiões da rede monitorada. Tal mecanismo baseia-se no grau de emergência de uma aplicação que pretende prevenir queimadas em florestas. A proposta é formar inicialmente uma topologia com *clusters* onde os nodos são selecionados pelo nível de energia residual, *a priori*. Em seguida, cada *cluster-head* coleta os dados de cada região e determina se consiste de uma região de baixo, médio ou alto risco, de acordo com os centroides obtidos da clusterização.

Os dados coletados inicialmente são utilizados como *dataset* (base do conhecimento) para o treinamento da fase de supervisão, e em seguida, a cada novo dado de incêndio monitorado os **CHs** realizam o trabalho local para notificar a estação base sobre as áreas de interesse. O trabalho apresenta uma completa análise de **QoS** dos cenários avaliados, além de considerar os dados monitorados e o gerenciamento de diferentes tráfegos de dados. O fator limitante nesse caso, trata-se das fases sequenciais do mecanismo, que obrigam aos **CHs** realizarem treinamentos prévios para em seguida dividir a rede conforme prioridade de atuação dos nodos. Após isso, a reconfiguração da topologia se dá de acordo com as detecções percebidas em cada grupo. Além disso, quanto maior quantidade de nodos agrupados por região de interesse, maior o trabalho requisitado aos **CHs** localmente.

Por sua vez, abordagens mais complexas que envolvem as Redes Neurais Artificiais (**RNA**) e a aprendizagem profunda (*Deep Learning*) utilizam da simulação de neurônios para treinar os dados que caracterizam os nós-sensores, como a taxa de dados, níveis de energia, profundidade e número de vizinhos, no intuito de definir topologias de **RSSFs**

com diferentes propósitos.

Nesse sentido, com foco em descobrir os melhores nodos candidatos a **CH** em uma **RSSF** para lidar com a poluição em um ambiente fabril, uma **RNA** é proposta no trabalho abreviado de **ELDC**, um acrônimo não intuitivo para o termo *An Artificial Neural Network based Energy-Efficient and Robust Routing Scheme for Pollution Monitoring* [71]. Essa proposta utiliza como dados: a distancia (em profundidade) e energia residual dos nodos para formar *clusters* e criar rotas até a estação base. Tais rotas devem compor todos os nodos da rede de forma que a quantidade de saltos seja reduzida e o grau dos nodos (quantidade de conexões) não exceda um predeterminado limiar.

Assim, a rede neural proposta consiste de 3 camadas que representa cada etapa de formação da rede, deve ajustar os dados de entrada de cada neurônio para que se alcance o valor de saída que identifica os nível de energia, vizinhança e profundidade do melhor candidato a nodo **CH**. Cada neurônio nesse caso, refere-se a um critério que pode representar: a distância entre os **CHs**, o nível de energia do nodo, o tráfego de dados suportado, o número de nodos vizinhos, etc. implicando em pesos a serem reajustados no treinamento. Ao final do treinamento, a rede é configurada de modo que os **CHs** eleitos comportem a menor quantidade de saltos até o *sink* e cada *cluster* possua o menor grau possível. Neste estudo as métricas que definem o **QoS** não são avaliadas e a técnica gera uma grande quantidade de conjuntos de treinamento até que um valor adequado seja capaz de determinar os **CHs** ideais pelo processo de retro-propagação (*backpropagation*).

Similarmente, a abordagem denominada de **Hybrid Wireless Ad-hoc network Routing Technique** [54] implementa uma rede neural com Aprendizagem Profunda (*Deep Learning*) que correlaciona basicamente as características avaliadas na abordagem anterior, mas de forma que, antes de executar a reconfiguração da topologia, todo o treinamento da rede neural é realizado virtualmente pelo nó central que nesse caso gerencia toda a comunicação. Tal abordagem possui como desvantagens o mesmo problema da abordagem anterior, exigindo maior desempenho computacional na busca pela melhor rota. Além disso, a rede considera uma abordagem com múltiplos nodos *sink* (*multi-sink*) em um ambiente onde todos nodos tem capacidade de mobilidade.

Por fim, abordagens que implementam mecanismos de Aprendizado por Reforço (**AR**) com foco no controle topológico e na provimento de **QoS** da rede são apresentados. Dessa forma, com foco em selecionar *Cluster-heads* em uma rede móvel com múltiplos *sinks*, a proposta **FROMS** (*Feedback ROuting to Multiple Sinks*) [33] utiliza de Aprendizado por Reforço (**AR**) para definir o melhores rotas até a estação base mais próxima. Tal abordagem utiliza as informações trocadas entre os nodos móveis, que devem armazenar e atualizar periodicamente o número de saltos, distância geográfica e bateria restante de cada nodo vizinho. Desse modo, cada nodo é representado como um agente, que deve interagir com o ambiente e escolher melhores decisões com base na modelagem de *Markov* (*Markov Decision Process* (**MDP**)) e uma aplicação do algoritmo *Q-learning*.

Os estados nesse caso, os autores consideram cada estação base e cada nodo candidato a **CH** a ser escolhido como melhor rota como destinos possíveis e os modelam como estados dentro do processo de seleção. Assim, quanto mais nodos identificados no momento da formação maior a complexidade em se executar o processo de aprendizagem. Além disso, o conjunto de estados é discretizado em sub-ações, que ao final de uma sequência de sub-ações corresponde a uma ação completa que vai definir o novo estado e as recom-

pensas que devem ser calculadas com base no *Q-valor*. Nessa abordagem o *Q-valor* de cada ação é representado pela quantidade de saltos necessárias para se alcançar a estação base mais próxima. A proposta é interessante para redes móveis tolerantes a falha, que em caso de perda de conexão encontra melhores nodos na vizinhança. Além disso, uma comparação com diferentes protocolos de roteamento é realizado, apresentando resultados em relação às métricas de QoS. Tal proposta apresenta limitações em redes de larga-escala, abordagens de agrupamento e a complexidade do processo de seleção pode ser muito alta se os estados não forem corretamente modelados.

Mais tarde, uma abordagem que segue a mesma linha, tem focado na redução do *overhead* (sobrecarga na troca de mensagens) e nos desgaste energético de redes de baixa latência. A proposta denominada de **RL-Probe** (*Reinforcement Learning for unicast and broadcast Probe*) [8] define a melhor formação de topologia em malha a partir da construção dos grafos de comunicação obtidos a partir do protocolo RPL (*Routing Protocol for Low power and lossy networks*), comumente utilizado em RSSFs que incorporam o protocolo IP versão 6 (IPv6). Assim, a configuração dos nodos é definida com base na qualidade de conexão (*link*) sem fio avaliada pelo valor LQE (*Link Quality Estimation*, ou Estimativa de Qualidade de *Link*).

Esta estimativa desempenha um papel crucial para detectar os comportamentos dinâmicos dos *links* e manter a estabilidade da topologia. Logo, a disponibilidade de uma estrutura baseada em LQE altamente eficiente, precisa e adaptativa é essencial para permitir que qualquer protocolo de roteamento selecione o melhor caminho de roteamento em condições de rede que variam no tempo. Nesse contexto, a ideia é identificar *links* de alta qualidade de curta duração, de modo que seja reduzida a quantidade de retransmissões. Tal mecanismo é capaz de prever variações de curto prazo na qualidade dos *links* e evitar procedimentos dispendiosos de re-seleção de rota que são acionados por falhas de *link*, comumente observados em redes sob protocolo RPL. Para isso, cada conexão entre os nodos retorna valores de recompensa do estado observado baseado nas ações tomadas a cada conexão avaliada. Para manter as informações atualizadas sobre a qualidade do *link*, a proposta combina mecanismos de monitoramento síncronos e assíncronos para minimizar a sobrecarga de medição sem interromper as alterações de roteamento.

Por sua vez, visando construir uma estrutura de rede de convergência e aumentar a cobertura da região monitorada, o protocolo **MRL-SCSO** (*Multi-agent Reinforcement Learning-Based Self-Configuration and Self-Optimization*) [83] é proposto. Nesta abordagem, cada nodo da rede é considerado um agente do ambiente, que pode tomar decisões sobre quais melhores nodos candidatos a trafegar suas mensagens para alcançar a estação base em tempo satisfatório. Para isso, a modelagem de *Markov* (MDP) utilizada define que cada nodo pode encontrar-se nos estados: “ativo”, “ocioso”, “dormindo” e “descobrimo vizinhos”. Assim, cada nodo individualmente é responsável por estabelecer a escolha de melhor caminho até o *sink* através do mecanismo de exploração e exploração que acarreta em recompensas avaliadas pela avaliação de qualidade do *link* e da energia residual. A qualidade do *link* nesse caso utiliza as variáveis de detecção de energia e RSSI providas pela camada física do padrão IEEE 802.15.4 no modo com *beacons*. O trabalho ainda avalia as taxas de pacotes entregues ao *sink*, pacotes perdidos na troca de mensagens e os atrasos fim-a-fim, comparando cenários com 10 a 50 nodos.

3.3.2 Comparação entre as propostas baseadas em IA

Esta subseção resume trabalhos sobre controle topológico de [RSSF](#) com técnicas diversas de [IA](#). A Tabela 3 classifica as propostas por abordagem, campo da [IA](#), topologia de rede, critérios de decisão e suporte à [QoS](#).

Tabela 3: Propostas de formação de [RSSF](#)s com otimização e Aprendizado de Máquina.

Proposta	Características				
	Abordagem	Técnica	Rede	Crítérios	QoS
HQCA [13]	Centralizada	AG	Grade	Energia do grupo e distância (geográfica)	✗
GMLA [78]	Distribuída	AG e Classificadores	Estrela	Energia e Taxa de Entrega	✓
GA-ANFIS [6]	Distribuída	AG e Fuzzy	Árvore e Malha	Energia residual e distância (geográfica)	✓
DESA [79]	Distribuída	AG e <i>Simulated Annealing</i>	Árvore e Malha	Energia e distância (em saltos)	✓
EKMT [43]	Centralizada	<i>K-means</i>	Árvore e Malha	Energia residual e distância (geográfica)	✓
HADA* [100]	Semidistribuída	<i>K-means</i>	-	Limiar do nível de energia	✓
ELDC [71]	Distribuída	RNA	Árvore	Distância (geográfica e em saltos), Vizinhança, Energia	✗
HWART* [54]	Centralizada	RNA e <i>Deep Learning</i>	Árvore	Distância (geográfica), Vizinhança e Energia	✗
SSCFD [94]	Semidistribuída	AM Semi-Supervisionado	-	Dados Monitorados	✓
FROMS [33]	Distribuída	AM com AR e <i>Q-learning</i>	Malha	Energia de vizinhos e distância (geográfica e em saltos)	✓
RL-Probe [8]	Centralizada	AM com AR	Grade e Malha	RSSI e LQE	✓
MRL-SCSO [83]	Distribuída	AM com AR	-	Energia e Qualidade do <i>Link</i> sem Fio	✓

NOTA: * “Siglas não utilizadas originalmente”; - “mecanismos que não identificam tal característica”; HADA “*Hybrid Anomaly Detection Algorithm*”; HWART “*Hybrid Wireless Ad-hoc network Routing Technique*”.

3.4 Trabalhos com Algoritmos de Otimização

Esta seção apresenta uma visão geral da pesquisa sobre [RSSF](#)s com identificação de regiões de atenção (*hotspots*) e abordagens de reconfiguração de rede orientadas a dados, com ênfase em propostas que empregam algoritmos de otimização. Para organizar adequadamente os trabalhos relacionados, iniciamos pelos estudos que tratam de regiões de

atenção (Subseção 3.5), seguido daqueles que exploram algoritmos gerais de otimização aplicados a RSSFs, e, por fim, os que abordam mecanismos de configuração topológica (Subseção 3.4.1). Quando um trabalho se enquadra em mais de uma dessas categorias, ele é discutido naquela que julgamos mais representativa. Adicionalmente, apresentamos uma comparação sucinta entre os principais estudos baseados em meta-heurísticas, agrupados conforme sua abordagem (Subseção 3.4.2).

À medida que as técnicas de otimização e variantes do PSO se tornaram atraentes para o problema de seleção de subconjuntos de cluster, muitas propostas mostram-se promissoras para a formação de topologias de RSSF. A maioria deles utiliza métodos heurísticos para lidar com o controle da topologia.

De acordo com a literatura, esta questão prevê sobrecarga de comunicação, alto processamento computacional e soluções algorítmicas complexas. Desta forma, os métodos heurísticos têm enfrentado algumas limitações quando diferentes cenários são avaliados. Conforme analisado por [53], algoritmos gananciosos obtiveram resultados indesejáveis em comparação com técnicas de otimização baseadas em abordagens GA e Branch and Bound (B&B). Segundo esta pesquisa, esse tipo de problema acarreta sobrecarga de comunicação, alto processamento computacional e soluções algorítmicas complexas. Assim, métodos heurísticos gananciosos não são adequados para fornecer soluções apropriadas, quando comparados a outras técnicas de otimização [53], como aquelas baseadas em GA, PSO ou B&B. Assim, aqui são sumarizadas as propostas no domínio da otimização, focadas principalmente em PSO, GA e algoritmos projetados para resolver problemas de ótimos locais. Além disso, o foco é identificar propostas preocupadas não apenas em lidar com problemas comuns de eficiência energética e cobertura de rede, mas também em explorar o fornecimento de QoS em termos de redução de atrasos de comunicação, sobrecarga de mensagens e requisitos de rede em tempo real.

Uma combinação de algoritmos de PSO e inspiração harmônica foi proposta em [89]. No Algoritmo de *Harmony Search Algorithm* (HSA), as soluções são obtidas através de um processo de geração de harmonias de inspiração musical, onde a evolução de partículas do PSO se comporta semelhante a transição entre notas e tons sendo modelada por matrizes de decimais até alcançar uma combinação factível (mais harmônica). O estudo demonstrou que as limitações enfrentadas pelo algoritmo PSO original para escapar dos ótimos locais poderiam ser superadas com a adição do algoritmo HSA. Esta proposta foca principalmente no desempenho na busca de ótimos globais, o que é comprovado quando se comparam abordagens heurísticas (gananciosas). Porém, a proposta incorre em alto consumo de hardware e complexidade computacional derivada da modelagem descrita e manipulação de matrizes.

Uma proposta destacada neste contexto, define um mecanismo PSO para balanceamento de energia em RSSFs baseadas em clusters, que tenta encontrar a melhor posição dos CHs de acordo com as coordenadas dos nós. O algoritmo denominado *PSO-based Energy Efficient Cluster Head Selection* (PSO-ECHS) [81] define uma função de aptidão que visa maximizar a soma da energia residual de todos os CHs e outra função de aptidão para minimizar a distância inter-cluster. Este método apresenta desvantagens na utilização de dispositivos GPS para obtenção da posição, e no *overhead* de troca de mensagens para informar a energia (periodicamente) e as coordenadas (considerando também os valores RSSI), porém explora bem a evolução de partículas na definição de *clusters*.

Em [77], um *Improved Adaptive PSO* (IAPSO) é proposto e comparado às abordagens combinatórias de PSO e SA. O foco está na comparação do desempenho de abordagens multiobjetivo com abordagens de *single-objective*, onde é demonstrado que o IAPSO tem desempenho superior em termos de taxa de entrega quando comparados ao SA e CPSO, utilizando dados de energia para otimização. Outra avaliação provida pelo trabalho mostrou uma pequena vantagem em usar IAPSO em modo multiobjetivo, comumente envolvendo a avaliação de múltiplas variáveis e funções e em muitos trabalhos definidos como (MOB - *multi objective*), que nesse caso, foi incorporado ao algoritmo de *Ant Colony Optimization* (ACO), melhorando a cobertura da rede e na comunicação entre nós. O custo computacional e a sobrecarga de dados não foram avaliados.

Considerando o PSO, o trabalho de [47] propôs uma nova forma de representar partículas como conexões entre nós, com formas diretas e indiretas, para evitar problemas de roteamento insolúveis. Embora o processo de modelagem de partículas seja complexo e consuma muitos recursos, a função de transferência proposta resolve problemas com funções de normalização, como tangente sigmóide e hiperbólica (bastante usadas na literatura). A função de aptidão utilizada visa maximizar a energia acumulada dos CHs, e os resultados alcançados mostram que o BPSO usado é mais eficaz do que outras técnicas como GA, PSO tradicional e algoritmos gananciosos.

O protocolo denominado **GOAC** (*Genetic Algorithm-based Optimized Clustering*) combina funções MOB e GA para superar o problema de alocação de *cluster-heads*. O algoritmo considera informações sobre o número de nós vizinhos, localização e energia residual para selecionar o menor número de nós para cobrir a região monitorada. Além disso, esta abordagem tratou da questão dos nós hotspots através de um MS(multi sink)-GOAC, considerando a geração de eventos na rede em regiões isoladas (distantes do *sink*). A desvantagem desta abordagem reside na quantidade de informações trocadas entre os nós para processar os três parâmetros da função MOB (definidos como FP1, FP2 e FP3), o que causa grande sobrecarga. Para isso, o protocolo adiciona recursos energéticos (o que é indesejável para abordagens leves). Outro ponto importante é que só foi possível lidar com *hotspots* isolados quando os nós dos CHs passaram a operar como *sink* (multi-sink), o que também não é desejável. Por conta disso, tal proposta foi classificada nesta seção e não com foco precisamente em *hotspot*.

A proposta denominada *Multi-objective Cluster Head based Energy-aware Optimized Routing algorithm* (**MCH-EOR**) foi desenvolvida em [72]. A fim de aumentar a vida útil das RSSFs por meio do agrupamento e seleção de CH usando SFO (*SailFish Optimizer*), os autores definem três etapas. Nas etapas de agrupamento e seleção de CH, o método utiliza pacotes de dados MAC contendo o sinalizador de ativação, ID da camada, localização do nó, ID do cluster e ID do nó. Para selecionar os nós sensores de desativação/ativação e CH, são necessários o sinalizador de ativação e a localização do nó. Na fase de rota baseada em otimização, o SFO é usado para selecionar caminhos dos nós descendentes até a estação base e é aplicado em quatro funções de aptidão, respectivamente, minimizando a distância intra e inter-cluster e maximizando a energia residual e a cobertura do raio de alcance.

Da mesma forma, o **BFO-FOA** proposto por [68] é um método que combina *Bacterial Foraging Optimization* (BFO) com um *Fruitfly Optimization Algorithm* (FOA) e utiliza diferentes funções de aptidão em cada etapa do processo (formação de caminho, seleção

de CH e agrupamento). Uma função minimiza a distância intra-cluster enquanto outra maximiza a energia residual dos CHs. Este método pode ter custos de processamento e sobrecarga de dados mais elevados, mas proporciona maior precisão. Essa precisão é demonstrada pela melhoria das métricas de QoS, como atraso e entrega de pacotes em GA, PSO e ACO. Posteriormente, a combinação de funções MOB teve como objetivo otimizar as métricas de QoS do método ARSH-FATI [7], utilizando um modelo de inicialização de partículas composto por uma população de matrizes $n \times m$. O processo é semelhante a um GA e compartilha as mesmas desvantagens de [68]. Porém, comparado a abordagens heurísticas, como CPSO e PSO-ECHS [81], o ARSH-FATI apresentou melhorias em termos de pacotes recebidos pela estação base.

Posteriormente, semelhante ao Kaushik et al. [47], uma proposta denominada BPSO-A [62] focou na redução do número de CHs na rede e na otimização do consumo de energia. Portanto, o empregamos como método comparativo com a nossa abordagem, pois representa uma estratégia recente baseada no BPSO que visa alcançar a homogeneidade da rede. Para conseguir isso, o BPSO-A utiliza uma função multiobjetivo composta pelas funções $f1$, $f2$ e $f3$. A função $f1$ visa maximizar a cobertura da rede considerando o desvio padrão das distâncias entre cada nó e seus vizinhos. A função $f2$ busca otimizar o consumo de energia avaliando o tempo de dormir de cada nó (a proporção de nós inativos em relação ao total de nós). A função $f3$ serve como índice de uniformidade de distribuição de nós, indicando o número de nós por cluster. Vale ressaltar que o BPSO-A não considera a priorização de nós com base em diferentes taxas de dados e conformidade com RSSFs baseadas em 802.15.4, e depende de dados de localização e energia que requerem recálculos frequentes.

O mecanismo RLDCSSA-CDG (*Reinforcement Learning-based Dynamic Clustering of Sleep Scheduling Algorithm*) [25] constrói um método de aprendizado por reforço para agendar nós periódica e dinamicamente. Nessa abordagem, os nós são usados como agentes, e cada agente seleciona aleatoriamente uma ação do conjunto de ações A e implementa a estratégia RL. Em cada rodada, o agente identifica a ação ideal com base nas experiências registradas na tabela de recompensas e ASV (*action select value*). Em seguida, as recompensas são calculadas e a tabela ASV é atualizada. Semelhante aos métodos usados em Tiny-ML, quando o perceptron multicamadas é usado para treinar a rede, tais abordagens podem ser computacionalmente custosas, embora mais precisas, exigem alto processamento. O RLDCSSA-CDG proposto é processado através das fases definidas como 3F: fundação, formação e encaminhamento (*forwarding*). Primeiramente, a arquitetura da rede é fundada e os CHs são selecionados. Em seguida, os nós sensores são reunidos dinamicamente em clusters para melhor comunicação na fase de formação. Nessa fase, várias iterações são realizadas para definir um agrupamento de nós suficiente, o que requer altos recursos computacionais. Por fim, o processo de transmissão é organizado com base em um algoritmo adaptativo de escalonamento de acordar/dormir para transmitir os dados no tempo calculado pela fase de encaminhamento.

3.4.1 Configuração da topologia de RSSF

O trabalho descrito em [85] descreve uma arquitetura adequada para reconfigurar RSSFs IEEE 802.15.4-com foco na detecção de intrusões. A fase de seleção dos CHs

é otimizada de forma semelhante às propostas anteriores (com maximização da energia residual e minimização da distância entre os membros do cluster e os CHs). Porém, tal proposta adiciona um fator de decisão para eleger CHs que avalia o grau de confiança, ao mesmo tempo em que detecta nós maliciosos. O grau de confiança é obtido a partir da camada de enlace de dados e otimiza o processo de seleção e detecção de mau comportamento dos nós vizinhos. A avaliação de QoS é superficial, mas o mecanismo de seleção reduz o número de CHs candidatos.

Em [101] é definido um mecanismo para construir caminhos entre nós sensores e múltiplos sinks visando a comunicação bidirecional através de uma abordagem baseada em um DSMST (*Dynamic Spanning Tree with Mobile Sink*). Vários sinks dependem de informações de energia, velocidade, distância e localização para selecionar CHs e formar caminhos. O principal objetivo dos autores é reduzir o consumo de energia em RSSFs baseadas em localização multi-sink devido às frequentes atualizações de localização e rota. Além disso, visam alcançar melhor equilíbrio de carga e reduzir o congestionamento de dados. Embora apenas o consumo de energia e o número de nós mortos se mostrem eficazes, a complexidade algorítmica se mostra competitiva em comparação com outros algoritmos.

Recentemente, alguns estudos focaram na seleção e roteamento de CH para ambientes IoT dedicados. Semelhante à nossa abordagem, o trabalho proposto por [37] implementa um mecanismo robusto para eleição de CH baseado na otimização de enxame, neste caso, uma *Whale Optimization* (WO), visando definir um número adequado de clusters. Além disso, o autor define um algoritmo *Harris Hawks Optimization* (HHO) para criar caminhos entre os nós sensores e a estação base. No entanto, tal estudo não considera a priorização de *hotspots*, e as métricas de QoS avaliadas abordam apenas critérios de vida útil.

No mesmo contexto, semelhante à nossa abordagem, a proposta denominada SWA-RAM [95] também divide a formação de cluster e seleção de CH em duas fases. Contudo, o objetivo principal é prolongar a vida útil da rede sem priorizar diferentes tipos de tráfego de dados. Além disso, embora esta abordagem tenha reduzido com sucesso a perda de pacotes em aproximadamente 10%, é importante notar que o atraso não é considerado, e as informações de posição do nó foram utilizadas em ambas as fases descritas.

Finalmente, a abordagem conhecida como **OptGACHE** [75] descreve um mecanismo de otimização que utiliza um GA para eleição de CHs. Esta abordagem centra-se principalmente no aumento da eficiência energética e demonstrou estabilidade em vários cenários. O processo de eleição do CH envolve uma função de aptidão complexa, que aborda fatores como densidade do nó, posição do nó, níveis de energia e diversas capacidades do nó. No entanto, a troca frequente de informações de energia durante as repetidas atualizações pode levar ao aumento do processamento e do consumo de energia. Apesar disso, o método apresenta economias de energia significativas em relação a outros métodos de GA.

3.4.2 Comparação entre abordagens de otimização

Como visto, a maioria dos trabalhos envolve meta-heurísticas na formação da topologia de RSSF focada na questão do consumo de energia, abordando uma função objetivo

para minimizar o consumo de energia. Algumas dessas propostas utilizam funções multiobjetivo visando superar vários problemas ao mesmo tempo. Porém, os resultados nem sempre são eficientes em termos de QoS. Suposições como o conhecimento do posicionamento dos nós (por exemplo, via GPS) ou a determinação do estado de carga das baterias, e a necessidade desta informação ser inserida em cargas úteis de quadros trocados na rede, podem comprometer o consumo computacional e de energia. ou custos financeiros em cenários do mundo real.

A Tabela 4 resume os principais trabalhos desta seção, comparando as abordagens de otimização e as características da rede usadas como critérios para tomada de decisão.

Tabela 4: Comparação de trabalhos relacionados a meta-heurísticas.

Proposta	Objetivo	Abordagem	Características
GOAC [99]	Cria caminhos adequados entre nodos em hotspot e a BS através da seleção de CH com GA.	GA-based	Depende de múltiplos nós sink e recurso energético extra
ARSH-FATI [7]	GA for CH seleção guiada por funções multi-objetivo	GA e PSO	Alto processamento computacional
OptGACHE [75]	Seleciona CHs com uma abordagem GA que define uma função complexa	GA	Necessita ciência de localização e energia
PSO-ECHS [81]	Seleção de CH baseada em distância intra-cluster, distância da BS e energia residual.	PSO-based	Necessita ciência de localização e energia
IAPSO [77]	Definição de CHs por adaptação do PSO para minimizar energia e maximizar cobertura.	PSO-based	Necessita ciência de energia
DiscPSO* [47]	Estende a vida útil da RSSF por redução de energia durante a fase de roteamento.	PSO-based	Modelagem complexa e alto custo computacional
BPSO-A [62]	Estende a vida útil ao reduzir o número de CHs.	PSO-based	Necessita ciência de localização
BFO-FOA [68]	Função multi-objetivo para clusterização e seleção de CH	BFO-based	Alta sobrecarga e custo computacional
MCH-EOR [72]	Maximize WSN lifetime and avoid premature death of nodes close to the BS via optimal path selection by SFO.	SFO-based	Need to be energy-aware
TrurstCH* [85]	Arquitetura que define a posição de CH, seguido por fase de otimização e validação.	Função Multi-objetivo	Alta sobrecarga de mensagens para obter dado de energia
DSMST [101]	Reduz o consumo energético ao formar caminhos baseados na energia, localização, distância e velocidade	Árvore gerado mínima	Além da localização, muitos dados são trocados
SWARAM [95]	Seleciona CHs com algoritmo Osprey Optimization e formação baseado na distância.	OOA-based	Precisa de localização e energia com alta complexidade

WO-HHO [37]	Otimização em fase dupla: seleciona CHs com otimização, e cria caminhos com algoritmo HHO usando posição, energia e vizinhos.	Swarm-based	Precisa de localização e energia com alta complexidade
--------------------	--	-------------	--

NOTA: * “Siglas não utilizadas originalmente”; DiscPSO “*abordagem baseada em PSO discreto*”; TrustCH “*abordagem que seleciona CHs para garantir segurança*”;

3.5 Abordagens Relacionadas com *hotspots*

Os trabalhos apresentados nesta seção abordam regiões especiais da rede, comumente denominadas *hotspot*. É importante destacar que o significado desse termo varia conforme a abordagem de cada autor. Nesta tese, *hotspot* — também chamadas regiões de atenção — são áreas monitoradas onde foram detectados eventos que exigem priorização no monitoramento, resultando em aumento deliberado da frequência de envio das mensagens. Já nos trabalhos relacionados a seguir, *hotspot* referem-se a áreas caracterizadas por tráfego naturalmente elevado, geralmente suscetíveis a congestionamento. Isso ocorre, por exemplo, em regiões próximas à estação base, onde há acúmulo de dados provenientes de múltiplos nós descendentes. Nos trabalhos a seguir, optou-se por manter o termo *hotspot* ao descrevê-los para preservar a nomenclatura utilizada pelos próprios autores

Abordagens que lidam com o desafio de priorizar a atividade dos nós com localização que comprometem o fluxo de dados da rede, são destacadas a seguir. O trabalho de Collotta et al. [22] define um escalonamento prioritário para aplicações de automação residencial ao realizar modificações no protocolo de acesso ao meio para definir os períodos de atividade. Para isso, é proposto o *Priority-Based CSMA-CA* ou **CSMA-CA-PB**, em que o mecanismo de **GTS** do 802.15.4 é usado para atender às demandas de temporização ao ajustar parâmetros de BE (*backoff exponent*) e CW (*contention window*) de cada nó. Esta abordagem se torna complexa conforme a rede escala, tornando a gestão do intervalo de beacon cada vez mais dependente de ajustes. No entanto, o *testbed* realizado é importante para observar os ganhos sobre abordagem padrão *slotted* CSMA-CA superada pela modificação do protocolo CSMA-CA-PB combinado com **GTS**.

Em [36], uma diferenciação de tráfego usando ciclo de trabalho (*duty-cycle*) adaptativo para redes 802.15.4 é proposta usando ajuste do CSMA-CA. Vários trabalhos também exploram alguns dos seus parâmetros para alargar o tempo de transmissão de nodos mais prioritários. A proposta definida como **DP** (*Dynamic Priority*) with **DDC** (*Dynamic Duty Cycle*) identifica os nodos prioritários com DC=1 como uma tag de identificação de prioridade, alterando valores de *backoff* maiores para o nodo ter mais chances de ser atendidos, além de alocar GTS imediatos no período CFP, priorizando-o durante todo *superframe*. A estratégia reduz o período CAP dos demais nodos. Posteriormente, o mecanismo definido como **PriMula** (*Priority-aware Multi-channel Adaptive*) [76] define um mecanismo de priorização para **RSSFs** baseadas no IEEE 802.15.4, demonstrando ganhos quanto a redução na perda de pacotes. O mecanismo insere mensagens de prioridade para organizar a rede com base em escalonamento multicanal. Uma avaliação com TelosB foi realizada, demonstrando a viabilidade da proposta. Os atrasos não são precisamente abordados, porém a avaliação da quantidade de nodos atendidos demonstra eficiência em ambientes de larga escala.

Inspirado no trabalho de [88], o **TDCS-PCC** (*TDCS Period Crossing Constraint*) [2]

estende o método original, propondo heurísticas para beneficiar métricas de confiabilidade e tempo de vida. O método proposto supera na maioria dos casos o TDCS original, fornecendo alta confiabilidade quando implantado em cenários de larga escala, com centenas de cluster-heads. O estudo mostra que a energia é otimizada, bem como a redução no tempo de computação de escalonamento adequada da rede, para permitir a maior quantidade de CHs ativos por mais tempo. A abordagem não foca no desempenho, métricas de atraso e perdas de pacotes não são avaliadas, mas demonstra um ganho de tempo em processar escalonamento que atende aos nós de diferentes fluxos (prioridades) com heurísticas que se sobressaem a métodos de otimização robustos.

Conforme discutido na Seção 2.2, as abordagens que envolvem GTS geralmente têm o objetivo de atender aplicações em tempo real, dedicando *slots* de tempo garantido a alguns nós, mas isso pode afetar o atraso para os nós restantes na planta. Assim como os métodos TSCH, que visam evitar atrasos crescentes, distribuindo pacotes por diferentes *slots* de canal em transmissão simultânea, com a desvantagem de depender de camada de aplicação robusta para lidar com interferências, sendo cada vez mais frequentes devido ao tempo de despertar dos nós envolvidos compartilhar o mesmo período. O TSCH do padrão 802.15.4 é amplamente utilizado para monitoramento em larga escala de redes *mesh*.

Nesse contexto, dois algoritmos obtiveram grande ênfase ao demonstrar a redução de atraso em aplicações com tempo crítico. A *Low-Latency Scheduling Function* (LLSF) [18] visa encadear os slots de tempo usados em um caminho multi-salto para reduzir a latência de ponta a ponta. Esse escalonamento é definido em um processo de três etapas: i. para cada *slot* de recepção do salto anterior, determinar o número de slots (o “gap”) entre aquele e o *slot* de recepção anterior do mesmo vizinho; ii. escolher o *slot* com a maior lacuna à sua esquerda; e iii. escolher o novo *slot* de transmissão para que o próximo salto seja o slot não utilizado mais próximo à direita do *slot* de recepção selecionado. Essa heurística é comprometida quando submetida por múltiplos fluxos. Por outro lado, o algoritmo *Adaptive Multi-hop Scheduling* (AMUS) [44] permite o escalonamento multi-salto para reservar recursos de comunicação ao longo da rota definida para cada conjunto de *links* de comunicação ponta a ponta.

Posteriormente, o algoritmo **SPRF** (*Scheduling Priority for Real-time Flows*) [90] provou superar o AMUS e o LLFS ao encontrar *links* livres para *streaming* com base em um cálculo de prioridade de nó. O algoritmo SPRF é um esquema de escalonamento centralizado para TSCH. Seu principal objetivo é alocar intervalos de tempo e canais para transmissões, garantindo que os fluxos cumpram seus prazos. Uma das principais etapas do SPRF é o cálculo de prioridade, onde a prioridade de um fluxo i é definida por: $p_i = D_i / (D_i - HOFD_i)$, sendo D_i o prazo de cada nó e $HOFD_i$ é a profundidade de cada CH (saltos residuais para o destino do fluxo). Essa etapa é muito semelhante à abordagem que define SD em carga SDA [56] e formação de rede a partir da profundidade [58], por isso é usado como comparação ao mecanismo de escalonamento proposto neste trabalho. Fluxos com maior número de saltos restantes e prazos menores têm maior prioridade. As etapas restantes são: um método de correspondência máxima baseado em prioridade que utiliza o algoritmo Blossom para encontrar o maior conjunto de enlaces que podem transmitir simultaneamente sem conflito. Os enlaces são adicionados ao pareamento com base na prioridade mais alta do fluxo associado. E, finalmente, um

algoritmo de colaração de grafos é usado para alocação de canais, construindo um grafo de interferência para evitar colisões entre enlaces próximos. Esse processo continua até que todos os fluxos sejam transmitidos ou o limite de tempo seja atingido. Se um fluxo não puder ser transmitido dentro do prazo, ele falha.

Recentemente, uma técnica de *superframe* adaptável foi proposta por [48] para atender ao ambiente de IoT provido por redes IEEE 802.15.4, onde a energia e a priorização de nodos é o foco principal. O *superframe* padrão do IEEE 802.15.4 é reconfigurado, tornando o CFP o período inicial, para primeiramente atender os nodos de maior atenção (nodos em *hotspot*), e logo depois o período de inatividade é inserido para todos os nós (*sleep mode*). Esse tempo é proporcional ao tamanho do intervalo de *beacon* corrente, sendo calculado como metade do BI. Assim, o período de inatividade desloca o período CAP de concorrência para o fim do *superframe* de modo a garantir que todos os nodos economizam a energia calculada como suficiente para suportar a rede. Esta abordagem não modifica a camada de enlace como o CSMA-CA-PB mas a reorganização do *superframe* pode ser um agravante. Este é denominada A *NovelSuperframe structure and optimal time slot allocation* e também é um dos escalonamentos comparado com a proposta deste trabalho.

Em seguida, o mecanismo DGS (DSME-GTS Scheduling) de [21], propôs uma abordagem que define a formação de uma rede cluster-tree IEEE 802.15.4 combinada com um escalonamento de prioridades baseado na distribuição de canais. A ideia principal baseia-se na *association order* (AO) para definir a prioridade do nó, otimizar o número de *slots* e maximizar os canais disponíveis, o que é usado para criar o escalonamento do nó. Esse mecanismo foi inspirado no trabalho anterior de [20] que criou um escalonamento simples chamado LBS (*Localized Beacon Synchronization*), um método semi-distribuído que utiliza informações de 2 saltos (pai e avô de cada nó) para solicitar o tempo de sincronização do *beacon* com a estação base.

O trabalho de [86] apresentou um mecanismo de escalonamento probabilístico baseado em prioridades, projetado para transmissão de dados confiável e em tempo real em Redes de Área Corporal Sem Fio (WBANs). Esse mecanismo, denominado TPLBS (*Traffic Priority-based Load Balancing and Scheduling*), visa garantir a entrega de dados com eficiência energética e com reconhecimento da qualidade de serviço (QoS). Para isso, mecanismos de buffer são usados em cada *cluster-head*, que contém duas filas principais: Fila Local (Q_L): armazena pacotes recebidos de sensores na WBAN associada ao CH; e Fila Remota (Q_R): armazena pacotes recebidos de outros nós. Cada fila é logicamente dividida em quatro subfilas, que se ajustam dinamicamente ao volume de tráfego de diferentes classes de prioridade: i. emergência (prioridade mais alta), ii. tráfego periódico de alta prioridade, iii. tráfego aperiódico e iv. tráfego não médico (prioridade mais baixa).

3.5.1 Comparação entre abordagens relacionadas a *hotspots*

Para resumir a comparação entre as abordagens tratadas nesta seção, a Tabela 5 sumariza os principais trabalhos descritos considerando tipo de atuação dos coordenadores da rede, técnica usada para reconfiguração e interpretação dos dados, topologia de rede, critérios abordados para atingir os objetivos e o provimento de qualidade de serviço.

Tabela 5: Propostas para reconfiguração de RSSFs com foco em hotspots.

Proposta	Características				
	Abordagem	Técnica	Rede	Critérios	QoS
TDCS-PCC [2]	Centralizada	Teoria de grafos	Cluster-tree	confiabilidade e vida útil	✗
DP & DDC [36]	Centralizada	parâmetros CSMA mensagens MAC	Árvore	mensagens de prioridade	✓
PriMulA [76]	Distribuída	TSCH e mensagens MAC	Cluster-tree	mensagens prioritárias e deadlines	✓
CSMA-CA-PB [22]	Centralizada	parâmetros CSMA e rate monotonic	Mesh	energia e confiabilidade	✗
DGS [21]	Semi-distribuída	DSME e GTS	Cluster-tree	slots prioritários e profundidade	✓
LLSF [18]	Distribuída	TSCH	Mesh	gaps para priorizar slots	✓
AMUS [44]	Centralizada	TSCH e RSSI	Mesh	slots prioritários e profundidade	✓
SPRF [90]	Centralizada	TSCH e grafos	Árvore	cálculo de prioridade e profundidade	✓
TPLBS [86]	Semi-distribuída	Buffers	Cluster-tree	filas de prioridade e probabilidade	✓
NovelSuperf* [48]	Centralizada	GTS e superframe	Cluster-tree	slots prioritários e prolongar vida útil	✓

NOTA: * “Siglas não utilizadas originalmente”; NovelSuperf “*abordagem de escalonamento que propõe nova estrutura de superframe*”.

Finalmente, após sumarizar os principais trabalhos que envolvem os temas que estuda este trabalho, o capítulo seguinte descreve a proposta de reconfiguração de RSSFs com foco em formação topológica e escalonamento prioritário para regiões de atenção com foco em QoS.

4 Arquitetura do Sistema

Este capítulo introduz a proposta de tese deste trabalho de doutorado. A Seção 4.1 estabelece o contexto da pesquisa, apresentando o modelo de sistema e as premissas adotadas. Em seguida, a Seção 4.2 detalha a arquitetura proposta, enfatizando sua organização modular. Os mecanismos essenciais de reconfiguração são aprofundados nas seções subsequentes: a formação topológica, na Seção 4.3, e o reescalonamento dos *beacons*, na Seção 4.5. Por fim, a Seção 4.7 encerra o capítulo discutindo a arquitetura como um todo, com destaque para sua flexibilidade em acomodar, futuramente, novos mecanismos e aprimoramentos.

4.1 Modelo do Sistema

Para a implementação dos módulos da arquitetura proposta, o modelo de sistema considera uma rede de monitoramento e controle em larga escala, na qual os nodos estão distribuídos uniformemente pelo ambiente e encaminham seus dados a um nodo coordenador central (coordenador PAN). A rede é estacionária, e os nodos não possuem conhecimento de suas próprias localizações. Apenas a estação base — que atua simultaneamente como *sink* e coordenador PAN — dispõe de energia ilimitada para processar as informações de vizinhança e as leituras do ambiente monitorado.

As principais suposições para a rede são:

- PR-1** Uma área de larga escala é monitorada por uma **RSSF** compatível com o modo *beacon-enabled* do padrão IEEE 802.15.4, em que vários nodos necessitam de múltiplos saltos para alcançar o coordenador PAN;
- PR-2** Todos os nodos utilizam o mesmo canal de comunicação na banda ISM de 2,4 GHz, caracterizando um único domínio de colisão;
- PR-3** O nodo coordenador, a partir dos dados recebidos, é responsável por executar as tarefas de determinação de vizinhança dos nodos e detecção de regiões de atenção (*hotspots*);
- PR-4** A rede é configurada em uma topologia *cluster-tree*, hierárquica, estacionária e bidirecional, sendo o nodo coordenador o *sink* e raiz da árvore. Ele também é responsável pela seleção dos **CHs** de cada *cluster* e pelo escalonamento das *superframe durations* (**SD**) da rede;
- PR-5** O nodo coordenador, diferentemente dos demais, possui recursos energéticos ilimitados;
- PR-6** Os nodos, incluindo os **CHs**, são autônomos (quanto à leitura de dados e tomada de decisão) e transmitem apenas durante seus respectivos **SDs**;
- PR-7** Os nodos são estáticos, não conhecem suas localizações, não dependem de dispositivos GPS e não utilizam informações de intensidade do sinal (**RSSI**) como

parâmetros para determinar vizinhanças durante o processo de associação e formação da rede;

PR-8 Todos os nodos pertencentes a um mesmo *cluster* alcançam seu CH com um único salto, e suas comunicações ocorrem durante o CAP, disputando acesso ao meio por meio do protocolo CSMA/CA;

PR-9 Quanto ao modelo de comunicação, a rede é *time-driven*, uma vez que os nodos transmitem de forma periódica. Contudo, ela é heterogênea quanto à periodicidade de transmissão de dados, pois algumas regiões consideradas como regiões de atenção poderão ter suas periodicidades aumentadas, de modo que mais informações sobre elas alcancem o coordenador;

PR-10 Novas regiões de atenção podem surgir ou desaparecer dinamicamente, e nodos podem se associar ou se dessociar da rede ao longo do tempo. Portanto, a rede precisa ser periodicamente reconfigurada pelo nodo coordenador para manter sua operação adequada.

Conforme a Premissa PR-6, o modelo não pressupõe informações de posição, utilizando apenas a vizinhança de cada nodo obtida por mensagens encaminhadas ao coordenador. Essa abordagem elimina a necessidade de transmitir dados como posição, RSSI ou energia residual, o que é especialmente vantajoso dado o limite de tamanho da carga útil em quadros IEEE 802.15.4.

A última premissa PR-9 é muito importante para a definição da arquitetura, pois exclui abordagens *off-line* para a configuração da rede e, ao mesmo tempo, reforça a necessidade de soluções leves, cuja complexidade computacional permita que a rede permaneça operacional, o maior tempo possível, durante o processo de reconfiguração.

Existem três suposições adicionais, válidas apenas para a fase de inicialização da rede:

PR-10 No funcionamento inicial da rede, os nodos operam como uma rede *ad hoc* padrão, sem qualquer estrutura hierárquica pré-estabelecida, mas não há nodos órfãos nem segmentos da rede desconexos;

PR-11 Por meio de trocas de mensagens, roteadas via um algoritmo simples baseado em AODV, os nodos compartilham seus identificadores (*nodeID*) e informações de vizinhança (incluindo lista de profundidade e vizinhos) entre si;

PR-12 Somente após essas informações alcançarem o nodo coordenador é que ele inicia a detecção das regiões de atenção, a organização da formação topológica e o escalonamento da rede, conforme as premissas PR-2 e PR-3.

Conforme ressaltado na premissa PR-10, assume-se que não há regiões desconexas na rede. Em síntese, um algoritmo adequado de formação da *cluster-tree* sempre produzirá uma árvore viável, na qual todos os nós-sensores conseguem alcançar a BS por meio de múltiplos saltos.

4.2 Componentes da Arquitetura do Sistema

A arquitetura proposta nesta seção tem como objetivo definir mecanismos de reconfiguração de RSSFs orientados por dados, cujo foco é otimizar o desempenho em relação às métricas de QoS durante o processo de monitoramento. Para isso, a arquitetura é organizada em módulos que abrangem desde a criação de uma tabela de adjacências de nodos até a definição da estrutura e dos períodos de atividade dos dispositivos.

Seis módulos direcionam o processo de formação da rede, a qual evolui desde uma configuração *ad hoc* aleatória até a consolidação de uma rede *cluster-tree*, eficiente e orientada pelos dados de monitoramento. A reconfiguração final da rede fundamenta-se em um mecanismo de escalonamento que prioriza os nodos de regiões de atenção, buscando não comprometer o funcionamento dos demais nodos da rede.

A arquitetura é ilustrada na Figura 9. Nela, as etapas são conduzidas pelo fluxo de execução representado pelas setas sólidas, que indicam a sequência dos módulos 1 a 6. Os módulos principais da arquitetura proposta — denominados CALiPSO e BRAZA — são detalhados, respectivamente, nas seções 4.3 e 4.5.




Figura 9: Diagrama de blocos da arquitetura do sistema proposto.

Conforme estabelecido na Premissa PR-9, alterações no ambiente monitorado podem ocorrer durante o funcionamento da rede. Esses eventos, representados pela seta tracejada no Módulo 6, implicam na necessidade de uma nova rodada de reconfigurações na rede. Outra situação que também pode alterar a sequência de execução da arquitetura ocorre no Módulo 4, durante a definição de uma partícula ótima. Caso a verificação de escalonabilidade da rede indique que há um escalonamento de *beacons* inviável segundo o padrão IEEE 802.15.4, o processo deve ser reiniciado até que uma configuração válida seja encontrada.

A seguir, são descritos os módulos que compõem a arquitetura proposta.

Módulo 1: Formação Topológica *Ad-hoc* Inicial — Este é o módulo inicial da arquitetura. Nessa etapa, são consideradas as características de uma rede *ad-hoc* padrão, operando em uma topologia aleatória do tipo *mesh*, implantada sobre um ambiente de larga escala para fins de monitoramento das variáveis por meio dos nós-sensores.

Nesse contexto, a rede é composta por um nodo que atua como coordenador geral, responsável por coletar informações provenientes de múltiplos nós-sensores, os quais se comunicam sem qualquer gerenciamento centralizado, sincronização de períodos de atividade ou estrutura hierárquica — podendo, portanto, ser interpretada como uma rede em malha. Considera-se que toda a configuração inicial, mesmo que inapropriada para as necessidades do modelo proposto, deve ser suficiente para permitir que as mensagens contendo informações sobre os nodos alcancem o coordenador geral, por exemplo, por meio do tráfego de mensagens conduzido por um algoritmo de roteamento simples, como o [AODV](#).

É importante destacar que, como se trata de uma configuração aleatória com comportamento não determinístico e sem gerenciamento da comunicação, leva certo tempo para que as informações de todos os nodos alcancem o coordenador PAN.

Módulo 2: Criação da Tabela de Adjacências — Nesse módulo, o coordenador PAN é responsável por criar uma tabela de vizinhança entre os nodos, a partir dos dados coletados durante o monitoramento executado na formação inicial. As informações que o coordenador é capaz de identificar incluem a identificação de cada nodo (*nodeID*), os valores detectados das grandezas físicas e uma lista limitada de nodos vizinhos.

Com base nessas informações, o coordenador PAN encarrega-se de atribuir valores de profundidade (distância em número de saltos) entre cada nodo e ele próprio, necessitando, para isso, de um mecanismo de descoberta de vizinhança, conforme descrito a seguir.

É importante destacar que a abordagem utilizada para o processo de associação dos nodos, seleção de [CHs](#) e formação de *clusters* não considera o valor de intensidade de sinal detectado pela camada física ([RSSI](#)), frequentemente adotado em diversas soluções da literatura. Conforme ilustrado pelo Algoritmo 1, o nodo coordenador executa um algoritmo distribuído que é aplicado recursivamente aos demais nodos, permitindo que cada um deles, de forma autônoma, descubra sua profundidade em relação à raiz.

Nesse algoritmo, inicialmente, são atribuídos o valor de profundidade $prof = 1$ aos nodos presentes na lista de vizinhos (linha 4) e $prof = 0$ a todos os demais (linha 6). Em seguida, o coordenador PAN percorre a lista de vizinhos de cada nodo, atribuindo aos nodos com $prof = 0$ (representados por m) um valor de profundidade atualizado com base na menor profundidade entre os nodos identificados (linhas 13–16). Isso significa que os nodos m verificam (linha 13) se em sua lista de vizinhos há o endereço de algum nodo n (isto é, nodos com $prof \neq 0$). Como cada nodo pode possuir múltiplos vizinhos, a atualização do valor de profundidade deve ser controlada de modo que apenas o vizinho com o menor valor de profundidade seja considerado. Esse controle é realizado por meio da variável *Profundidade* (linhas 7 e 16) e do sinalizador $FLAG_{prof}$ (linhas 9 e 17).

A Figura 10 ilustra o processo executado pelo algoritmo, em que 10-a) representa a

Algoritmo 1 Algoritmo de Descoberta de Vizinhança

```
1: função DESCOBREVIZINHANCA(nodo, lista_nodos)
2:   para nodo n in lista_nodos faça
3:     se PANCoord.addr  $\in$  n.neighb então
4:       n.prof  $\leftarrow$  1
5:     senão
6:       n.prof  $\leftarrow$  0
7:   Profundidade  $\leftarrow$  1
8:   faça
9:     FLAGprof  $\leftarrow$  False
10:    para nodo n  $\in$  lista_nodos faça
11:      se n.prof == Profundidade então
12:        para nodo m  $\in$  lista_nodos faça
13:          se m.prof == 0 && n.addr  $\in$  m.neighb então
14:            m.prof  $\leftarrow$  Profundidade + 1
15:            FLAGprof  $\leftarrow$  True
16:          Profundidade  $\leftarrow$  Profundidade + 1
17:    enquanto FLAGprof == True
```

atribuição de profundidade aos nodos iniciais e 10-b) indica a replicação do algoritmo pelos nodos que atualizam sua profundidade com base na vizinhança. As tabelas no lado direito da figura mostram a identificação dos nodos realizada pelo coordenador PAN, bem como os dados coletados dos oito primeiros nodos do ambiente (temperatura é representada em °C e umidade em Rh).



A Figura 10 também distingue os nodos em prioritários e não prioritários. O processo de classificação desses nodos, bem como o significado da priorização deles, é detalhado a seguir.

Módulo 3: Classificação dos Nodos — Após a coleta de dados e a identificação da profundidade de cada nodo da rede através da tabela de vizinhanças, o coordenador PAN utiliza os dados monitorados pelos nós-sensores para classificar cada nodo em grupos de prioridade. Os valores referentes aos dados monitorados pela aplicação passam por um processo de clusterização aplicando-se algumas das técnicas de *data clustering* abordadas na Seção 2.3.3.

A Figura 11 ilustra um exemplo desse processo. Os dados coletados — apresentados na coluna 3 da tabela dessa figura — são analisados e agrupados de acordo com a similaridade identificada em grupos de nodos **prioritários** que correspondem aos nodos em áreas de atenção (*hotspots*) e **não prioritários**, que correspondem aos nodos das demais regiões da rede.


Para os oito primeiros nodos analisados, foram identificados um não prioritário, composto por cinco nodos, e um prioritário, composto por três. Esse exemplo ilustra o comportamento resultante da aplicação do algoritmo K-means sobre a análise bidimensional das variáveis de umidade e temperatura.

Convém destacar que a clusterização realizada neste módulo tem por objetivo a for-



ID	PROF	Dados	Vizinhos
1	1	(25°C, 25Rh)	[0; 2; 3; 6]
2	1	(24°C, 24Rh)	[0; 1; 3; 6]
3	1	(32°C, 14Rh)	[0; 1; 2; 4; 9]
4	1	(23°C, 24Rh)	[0; 7; 3; 11]
5	1	(22°C, 25Rh)	[0; 6; 12; 15]
6	1	(21°C, 25Rh)	[0; 1; 2; 12]
7	0	(33°C, 16Rh)	[4; 8; 9]
8	0	(36°C, 15Rh)	[7; 18; 21; 22]

a) Execução inicial do algoritmo de Descoberta de Vizinhança e Criação da Tabela pelo Coordenador PAN



ID	PROF	Dados	Vizinhos
1	1	(25°C, 25Rh)	[0; 2; 3; 6]
2	1	(24°C, 24Rh)	[0; 1; 3; 6]
3	1	(32°C, 14Rh)	[0; 1; 2; 4; 9]
4	1	(23°C, 24Rh)	[0; 7; 3; 11]
5	1	(22°C, 25Rh)	[0; 6; 12; 15]
6	1	(21°C, 25Rh)	[0; 1; 2; 12]
7	2	(33°C, 16Rh)	[4; 8; 9]
8	3	(36°C, 15Rh)	[7; 18; 21; 22]

b) Replicação do algoritmo para os demais nodos ao passo em que a tabela vai sendo atualizada

Figura 10: Algoritmo de descoberta de profundidade e criação da tabela de vizinhança.

mação de grupos de dados, o que difere do agrupamento topológico de nodos no contexto de formação de clusters na árvore. Assim, busca-se apenas associar cada nodo a uma característica de geração de dados, sem qualquer relação com a proximidade espacial entre eles. Em outras palavras, a inclusão de dois nodos em um mesmo grupo de prioridade não implica que estejam fisicamente próximos.

Após a classificação dos nodos em grupos, ou seja, a identificação de regiões de atenção, a formação da árvore é iniciada, conforme descrito a seguir.

Módulo 4: Formação da Árvore e Escalonamento da Rede — Este módulo trata da formação da rede em estrutura *cluster-tree*. Ele é organizado em três submódulos. O primeiro é responsável por determinar valores iniciais para as partículas do algoritmo BPSO. O segundo submódulo é responsável por fazer a evolução das partículas. O terceiro é um processo de verificação de escalonabilidade da rede. Esses submódulos são descritos a seguir:




Figura 11: Identificação de grupos prioritários a partir da clusterização de dados.

Definição das Partículas Iniciais: esse primeiro submódulo reúne as informações de cada nodo classificado como prioritário, indicando sua pertinência a regiões de atenção (*hotspots*), além dos valores de profundidade e do número de vizinhos, os quais foram obtidos no Módulo 2.

Evolução das Partículas: em seguida, um segundo submódulo executa o processo de definição das partículas do algoritmo baseado em **BPSO**, que são então submetidas à etapa de evolução, visando determinar a configuração topológica mais adequada. Esse processo é otimizado pela capacidade de tomada de decisão da meta-heurística empregada, superando as limitações inerentes ao método heurístico. Os detalhes do mecanismo de formação baseado em **BPSO** são apresentados na Seção 4.3.

Após obter a sequência de ações — que resulta na melhor configuração obtida da árvore —, a estrutura formada neste módulo é submetida à fase de verificação da escalonabilidade de *beacons* da rede. Nessa etapa, os períodos de atividade devem obedecer às restrições impostas pelo padrão IEEE 802.15.4, o qual determina que a duração do *superframe* seja configurada por meio dos parâmetros Beacon Order (**BO**) e Superframe Order (**SO**), definidos em múltiplos de potências de 2.

Verificação de escalonabilidade: essa fase compõe o módulo de formação e precede a execução da rede *cluster-tree* resultante da melhor sequência de ações obtida no processo de otimização por **PSO**. Com a estrutura estabelecida nos submódulos 4.1 e 4.2, o presente método é responsável por executar a verificação de escalonabilidade, a partir da distribuição eficiente de períodos ativos (*Superframe Durations* – **SD**) de cada *cluster*.

O processo de escalonamento adotado neste trabalho baseia-se na técnica *Load-SDA* [55], a qual aloca durações de *superframes* de forma proporcional para cada **CH**, considerando a carga de dados imposta pelos nodos. Para isso, assume-se que cada nodo possui um fluxo de mensagens F_i , enviado periodicamente ao coordenador PAN.

Cada fluxo é caracterizado pelo tamanho da mensagem e pela periodicidade de geração, impondo um fator de utilização sobre a rede.

Dessa forma, a definição dos períodos de atividade de cada *cluster* deve respeitar a restrição de que o tamanho do Intervalo de *Beacon* (BI) seja capaz de acomodar todas as durações de *superframe* (SDs) e, simultaneamente, componha o menor período possível ($P_{\min}$) do conjunto de fluxos F . Assim, tem-se:

$$\sum_{j=1}^{N_{CH}} SD_j \leq BI \leq P_{\min} \quad (7)$$

onde SD_j é a duração do *superframe* alocada para CH_j , N_{CH} é o número total de *cluster-heads* gerados na árvore e BI é o intervalo de *beacon*.

Dessa forma, para alocar SDs adequadamente, a técnica *Load-SDA* define como X o número de mensagens transferidas ao longo de uma duração mínima de *superframe*, com base no tempo T_{TXD} necessário para a transmissão de um único pacote, como segue:

$$X = \left\lfloor \left(\frac{SD_{\min}}{T_{TXD}} \right) \times p_s \right\rfloor, \quad (8)$$

sendo $SD_{\min}$ correspondente à duração quando $SO = 0$ (contando apenas o valor de *aBaseSuperframeDuration*) e p_s a probabilidade de uma transmissão bem-sucedida.

Nesse caso, o tempo T_{TXD} é definido por [49] como $T_{TXD} = T_{BACK} + T_{PKT} + T_{TX_RADIO} + T_{ACK}$, sendo T_{BACK} o período de *backoff* que cada dispositivo aguarda para acessar o canal sem fio, T_{PKT} o tempo de transmissão do pacote, denotado por $\frac{L_{PKT}}{Rad}$ (L_{PKT} corresponde ao tamanho do quadro de dados e Rad é a taxa de dados suportada pelo rádio). O valor T_{TX_RADIO} corresponde ao tempo que o rádio leva para alternar entre os diferentes modos de operação e T_{ACK} corresponde ao tempo de transmissão de confirmações, denotado por $\frac{L_{ACK}}{Rad}$ (L_{ACK} é o tamanho do quadro de confirmação).

A definição do SD necessário para cada CH_j , de acordo com a carga de dados imposta pelos nodos da ramificação da árvore, é definida pela Equação 9:

$$SD_j = \left\lceil \frac{\sum i \in F_{desc} \left\lfloor \frac{P_i}{BI} \right\rfloor}{X} \right\rceil \times SD_{\min} \quad , \quad (9)$$

onde $\sum i \in F_{desc} \left\lfloor \frac{P_i}{BI} \right\rfloor$ corresponde ao número máximo de mensagens geradas pelo conjunto de nodos filhos do *cluster-head* CH_j (incluindo o tráfego de mensagens acumulado de CHs filhos), com periodicidade de dados P_i durante um intervalo de *beacon* (BI). A Figura 12, adaptada de [63] esboça o processo realizado pela técnica.

Como observado, para cada *cluster* é atribuída uma duração de *superframe* (SD) proporcional à carga processada pelo CH. Nesse exemplo ilustrativo, um ramo da árvore com um CH 7 obtém um valor de SD maior que seus CHs filhos 12 e 13, devido ao acúmulo calculado pela Equação 9. Assim, ao final da distribuição de todos os SDs, o coordenador PAN escalona todos os *clusters* em modo *bottom-up*, a fim de que o




Figura 12: Exemplo de verificação de escalonabilidade pela técnica *Load-SDA*.

seu intervalo de *beacon* (BI) seja capaz de acomodar todos esses períodos de atividades acumulados.

A Figura 12-b ilustra um exemplo de estrutura escalonável composta apenas por três *clusters*. Nessa configuração, o somatório de SD_1 , SD_2 e SD_3 ajusta-se ao BI estabelecido pelo coordenador PAN, resultando ainda em um período inativo, evidenciando que todos os *clusters* podem permanecer em *sleep mode*. Mais precisamente, o somatório dos SOs atribuídos a cada *cluster* totaliza aproximadamente 108 milissegundos, acomodando com folga um $SD_{\min}$ ($\approx 15,36$ ms) dentro do BI definido para $BO = 3$ (≈ 123 ms).

Por outro lado, a Figura 12-c mostra a eventual inserção de um quarto *cluster*. Nessa situação, apenas o menor valor possível de SO — correspondente a $SD_{\min}$ — poderia ser atribuído a esse novo *cluster*, visto que qualquer valor de SO maior que zero faria o somatório dos *superframes* ultrapassar o BI, tornando a rede não escalonável.

Quando a verificação deste módulo identifica que a escalonabilidade é atendida, a rede começa, enfim, a operar conforme a *cluster-tree* formada. Caso contrário, na verificação da não escalonabilidade da rede, ocorre uma retroalimentação nesse módulo para determinação de novas partículas iniciais do PSO.

Módulo 5: Reescalonamento de *beacons* de Nodos Prioritários — Este módulo é responsável por definir o reescalonamento de *beacons* que deve priorizar os nodos em regiões de atenção. Assim, é criado um mecanismo que ordena os nodos em *bottom-up* utilizando as abordagens descritas em SDA-Load [56] e TDCS [88], porém, escalonando os nodos prioritários (de regiões de atenção) antes e os não prioritários depois. Dessa forma, é definida uma estratégia multi BO para o coordenador PAN, que não modifica o padrão. Diferente de várias abordagens que modificam as normas do padrão, o esquema definido neste módulo utiliza as mesmas fórmulas de atribuição de BO e SO para o coordenador PAN, porém define um momento intermediário (com BO múltiplo) que atende primeiro aos nodos que exigem maior atenção, e no intervalo de folgas, atende parte dos demais nodos. Em seguida, os *beacons* subsequentes atendem os demais nodos por partes, o que possibilita estender tal mecanismo para diferentes níveis de prioridade. Os detalhes do mecanismo de reescalonamento prioritário proposto são descritos na Seção 4.5.

Módulo 6: Execução e Supervisão — Por fim, este módulo de controle da arquitetura consiste em um sistema supervisor que verifica periodicamente se ocorreram mudanças na estrutura da rede durante a execução (ex., nodos na tabela de vizinhança se desassociaram por eventos externos, esgotamento de bateria etc.) ou se surgiram mudanças significativas nas regiões de atenção. Nesses casos, o sistema de controle notifica o coordenador PAN, que aciona novamente o Módulo 2 da arquitetura, reexecutando o algoritmo de determinação da tabela de vizinhanças. A partir desse ponto, uma nova formação da *cluster-tree* é estabelecida juntamente com o escalonamento da rede adequado.

4.3 CALiPSO: Mecanismo de Reconfiguração Baseada em BPSO

Esta seção descreve o método de formação topológica proposto para priorização de nodos e de tráfegos de dados oriundos de regiões de atenção. O método desenvolvido é nomeado de **CALiPSO** (*Cluster-head Allocation with Lightweight PSO*) e é baseado no modelo de Otimização de Enxame de Partículas Binárias (**BPSO**).

4.3.1 Exemplo ilustrativo

Conforme discutido anteriormente, a etapa de formação inicial da rede, associada à identificação das regiões de atenção, deriva da análise dos dados coletados pelos nós-sensores. Essa análise possibilita a detecção de comportamentos anômalos ou padrões críticos que caracterizam eventos relevantes no ambiente monitorado. Exemplos incluem variações abruptas de temperatura ou umidade, indícios de vazamento de gases, sinais iniciais de incêndio, degradação operacional em uma planta *outdoor* ou a possível presença de intrusos.

A Figura 13 ilustra um exemplo de formação da rede, no qual uma região de atenção é identificada. Nesta região, composta pelos nodos 9, 14, 15 e 20, um único *cluster* da *cluster-tree* pode ser criado para abrigá-los, exigindo a seleção de um nodo para atuar como **CH**. Como todos os nodos dessa região de atenção conseguem se comunicar entre si com apenas um salto, qualquer um deles seria um candidato potencial ao papel de **CH**.




Figura 13: Um exemplo de uma parte da **RSSF** com uma região de atenção.

Na representação da Figura 13, para simplificar, apenas a área de cobertura do coordenador PAN é ilustrada, omitindo-se a dos demais nodos. As linhas entre os nodos indicam enlaces entre aqueles que podem se comunicar diretamente, ou seja, alcançáveis com apenas um salto. Os possíveis caminhos utilizados pelos CHs até a BS são estabelecidos a partir desses enlaces. O valor da variável d (profundidade) corresponde ao número mínimo de saltos necessários para alcançar a BS, podendo ser determinado por meio de um algoritmo simples [64].

4.3.2 Representação de Partícula, Exploração e Exploração no CALiPSO

No contexto do CALiPSO, cada partícula é representada como uma sequência de bits, onde cada bit 1 representa um CH e o bit 0 representa os nodos membros que devem pertencer a pelo menos um *cluster*. A abordagem proposta é descrita como leve (*lightweight*) pois o esquema de evolução das partículas reduz a complexidade da formulação tradicional do algoritmo PSO. Em vez de calcular valores contínuos e usar uma função de normalização a cada iteração para obter novas partículas, é utilizada uma estratégia de rotação de bits para buscar posições de ótimo local. Essa estratégia não apenas reduz o processamento das partículas pela função de normalização em cada partícula, mas lida de forma adequada com o dilema da exploração e exploração característicos das técnicas de otimização baseadas em IA.

O algoritmo de formação possui uma fase de inicialização flexível de partículas, onde o modo padrão considera que existe pelo menos um CH por profundidade e um número mínimo de CHs por região de atenção. Esse mecanismo pode ser estendido para aderir a novos critérios de inicialização. A evolução das partículas é conduzida por movimentos de rotação (deslocamentos circulares), o que representa uma busca pela melhor configuração. Uma partícula de n bits, por exemplo, precisa apenas de $n - 1$ movimentos para explorar todas as alternativas de rotação.




Figura 14: Evolução da partícula que troca o CH do nodo 20 para o nodo 15.

Por exemplo, considerando a região de atenção mostrada na Figura 13, assumindo um único *cluster* com os nodos 9, 14, 15 e 20, inicialmente, com a partícula “0001”, o nodo 20 seria o CH (Figura 14a). Após uma rotação, a partícula se torna “0010”, e o nodo 15 se tornaria o CH (Figura 14b). Cada nova configuração de partícula retorna um valor de uma função de aptidão, neste caso, definida para minimizar uma soma, que quanto menor, melhor será a configuração CH, como segue:

$$F_f = \min \sum Depth(CH_i) \quad (10)$$

onde F_f é a função de aptidão que visa minimizar a soma da profundidade dos nodos CHs definidos (ou seja, cada i corresponde à posição da partícula marcada como bit 1).

A partir de F_f é possível inferir uma quantidade adequada de CHs e estimar um número satisfatório de saltos entre os nodos da região de atenção e da BS, a fim de reduzir sua latência. Assim, a cadeia de bits que retorna a menor soma de profundidade é a melhor candidata (sendo avaliada como viável se a conectividade e a orfandade forem respeitadas).

4.3.3 Fluxograma do mecanismo CALiPSO

A Figura 15 ilustra o funcionamento do CALiPSO, desde os movimentos e a evolução das partículas até sua combinação para a obtenção de novas configurações viáveis. O CALiPSO inicializa simultaneamente uma partícula contendo nodos de todas as regiões de atenção e subpartículas formadas por nodos de cada região de atenção individualmente. A evolução paralela dessas partículas e subpartículas aumenta a probabilidade de encontrar configurações mais adequadas na seleção do CH.

Em qualquer abordagem PSO, a fase de inicialização de partículas e subpartículas desempenha um papel crucial na busca de soluções ótimas durante a execução do algoritmo. É possível ter configurações melhores ou piores, dependendo do número de partículas iniciais e de como elas são predefinidas. Conforme apontado na literatura, a maioria das propostas de PSO inicializa partículas aleatoriamente, o que pode levar a um elevado número de iterações até a convergência do algoritmo.

Em contraste, como cada bit 1 na partícula significa um nodo com função CH, o CALiPSO considera que o método de inicialização seria baseado em dados inferidos da tabela de nodos, considerando principalmente a vizinhança e profundidade dos nodos. Qualquer proposta de inicialização de partículas deve levar em conta que uma configuração válida sempre exigirá pelo menos um CH para cada nível da árvore.

No entanto, é importante notar que o CALiPSO não está vinculado a uma técnica de inicialização específica. Além disso, mais de uma técnica de inicialização pode ser usada simultaneamente. Na Seção 5.4.5, concretamente antes da análise algorítmica, são detalhadas quatro técnicas baseadas em informações da tabela de nodos, que são utilizadas para simulações desta proposta na Seção 5.1.

Outra questão essencial no algoritmo CALiPSO que necessita ser detalhada é o movimento de rotação das partículas. Uma nova partícula viável gerada a partir de uma rotação leva à descoberta de um número adequado de CHs, bem como a busca pela melhor rotação individual em subpartículas detecta áreas descobertas. Esses movimentos de rotação podem ser resumidos da seguinte forma:

1. **Movimento de rotação de partículas completas:** Este movimento trata uma partícula como uma sequência de bits que compreende todos os nodos de todas as regiões de atenção e faz parte da fase de exploração do algoritmo proposto. Neste movimento, os bits à direita invadem os bits à esquerda e o bit mais significativo é movido para o bit menos significativo.
2. **Movimentos de rotação de subpartículas:** Esses movimentos fazem parte da fase de exploração e visam encontrar os ótimos locais para cada região de atenção.




Figura 15: Evolução de partículas e sub-partículas do algoritmo CALiPSO.

Nesse caso, a cada rotação, novas posições são descobertas como melhores posições de **CH** para as regiões de atenção específicas.

Quando subpartículas individuais são inicializadas em regiões diferentes, o movimento de rotação busca melhores posições de **CH**. Cada subpartícula identificada como viável é combinada com subpartículas de outra região para obter melhores resultados da função de aptidão (combinações com soma mínima de profundidades).

O critério de parada deste algoritmo **BPSO** depende do tamanho completo da partícula. Este critério é obtido dividindo pela metade o número de movimentos possíveis subtraído do número de iterações da última solução ótima. Por exemplo, suponha que uma partícula tenha 10 bits de comprimento (o que representa um máximo de 1.023 movimentos) e o último ótimo global foi encontrado na 400ª iteração. Nesse caso, a busca subsequente pela solução ótima gastará até 311 iterações (ou seja, $(1023-400)/2$). Esta abordagem atende aos critérios para encontrar soluções próximas e abrange a maioria

dos movimentos possíveis.

É importante notar que o algoritmo do CALiPSO previamente descrito é usado para selecionar CHs e formar *clusters* e caminhos de regiões de atenção (cujos nodos são prioritários) para BS. Porém, depois disso, novos *clusters* e caminhos também são formados para os demais nodos (nodos não prioritários), seguindo uma abordagem de seleção *bottom-up* mais direta, onde os CHs são escolhidos com base na profundidade mínima.

4.4 Exemplo de aplicação do mecanismo CALiPSO

A Figura 16 apresenta um exemplo de cenário de rede *mesh* aleatória com duas regiões de atenção, onde a primeira contém quatro nodos e a segunda, oito. A identificação desses nodos é realizada na etapa de detecção de regiões de atenção, onde o coordenador PAN separa esses nodos por prioridade, assumindo que os nodos da região de atenção possuem maior prioridade. O objetivo é definir o número adequado de CHs, selecionando aqueles que são os melhores candidatos (reduzindo o número de saltos para o BS).

Por exemplo, partindo de uma partícula inicial 000100110100 composta por todos os nodos da região de atenção (nodos 9, 14, 15, 20, 19, 22, 23, 27, 29, 30, 32 e 33), após algumas rotações, uma partícula 000010011010 pode ser alcançada, na qual os nodos 19, 27, 29 e 32 seriam CHs. No entanto, esta configuração resulta em nenhum nodo CH na primeira região de atenção (os quatro bits mais significativos). Portanto, novos movimentos deverão ser realizados até que soluções viáveis sejam encontradas.

Em relação aos movimentos de rotação das subpartículas, na segunda região de atenção, uma rotação na subpartícula 00011010 atinge 00110100. Essa rotação visa encontrar P_b para uma região específica, uma vez que 00110100 poderia retornar uma soma de profundidade de CHs menor que a cadeia de bits anterior. A combinação de melhores posições encontradas em cada região de atenção corresponde à partícula G_b .

Nestas circunstâncias, para marcar novas partículas como viáveis, o mecanismo verifica se as partículas resultantes dos movimentos de rotação atendem à verificação de orfandade e conectividade. Basicamente, a verificação de orfandade verifica se a partícula possui pelo menos um bit 0 cuja lista de vizinhos não possui o bit 1. E a verificação de conectividade verifica se os bits marcados como 1 são vizinhos. Se a primeira for falsa e a segunda verdadeira, a partícula é viável e é armazenada em uma estrutura de dados compondo as soluções.

Dependendo da abordagem, um nodo pode ser selecionado incorretamente como CH, criando um longo caminho com muitos nodos para chegar à BS. Por exemplo, a partícula 0100 na primeira região de atenção atribui o nodo 14 como CH, e o caminho para o BS incluiria os nodos 8, 4, 3 e 1. Para piorar a situação, as abordagens heurísticas podem selecionar CHs desnecessários dentro da mesma região de atenção, gerando saltos adicionais e, portanto, resultando em mais atrasos de comunicação. Esse comportamento seria representado em partículas que possuem dois ou mais bits 1 em suas *strings*. No entanto, como ilustrado em Figura 16, a primeira região de atenção tem a configuração 0010 como melhor posição (com o nodo 15 como CH), de acordo com o possível retorno da função de *fitness*, igual a 3 (via caminho 15 – 10 – BS).

Vale ressaltar que o CALiPSO retorna sempre o melhor caminho encontrado. Assim, o caminho 15 – 16 – 11 – BS seria um caminho alternativo para esta configuração da




Figura 16: Partículas viáveis e possíveis caminhos resultantes de suas rotações.

região de atenção caso algum nodo **CH** no caminho anterior não possa ser utilizado.

A abordagem CALiPSO visa ainda prevenir a formação de partículas inviáveis, como aquelas resultantes de **CHs** insuficientes ou excessivos. Por exemplo, assumindo a sub-partícula 00100010 na segunda região de atenção, a verificação de orfandade é satisfeita para os **CHs** 23 e 32, mas não há ligação entre eles. Por outro lado, uma partícula com muitos **CHs**, como em 11110111, não geraria um escalonamento de *beacon* viável do padrão IEEE 802.15.4, conforme descrito na Seção 2.2.

Observe que, durante a seleção de **CHs** para formação de caminho, alguns nodos fora da região de atenção podem ser modificados; ou seja, nodos não prioritários tornam-se prioritários. Por exemplo, o nodo 10 é modificado porque se torna parte do caminho da região de atenção para a **BS** quando o nodo 15 é selecionado como **CH**. Isso permite criar ramos mais homogêneos na *cluster-tree*, beneficiando o acúmulo de dados dos nodos em uma região de atenção e a priorização dos fluxos distintos a serem gerenciados pelo coordenador da rede.

Assim, o mecanismo CALiPSO tem como principal objetivo formar a *cluster-tree*, atendendo a clusterização dos fluxos em regiões de atenção. Porém, ainda é possível melhorar o desempenho das mensagens oriundas de nodos dessas regiões, por meio de um escalonamento de *beacons* adequado, conforme descrito na seção seguinte.

4.5 BRAZA: Reescalonamento de Nodos em Regiões de Atenção

O CALiPSO produz uma *cluster-tree* devidamente formada, acompanhada de um escalonamento de *beacons* funcional. Sua operação foi descrita de forma sintetizada no Módulo 4 da Seção 4.2 e detalhada no fluxograma da Figura 15. Ela evidencia a busca por partículas viáveis e sua posterior verificação por meio do teste de escalonabilidade.

Apesar de o CALiPSO privilegiar configurações em que nodos prioritários — aqueles situados nas regiões de atenção — tendem a ser agrupados em *clusters*, facilitando assim a priorização de seu tráfego, o escalonamento gerado é viável, é operacional, porém não incorpora critérios explícitos de priorização associados a tais nodos. Como discutido, o foco deste trabalho é o desenvolvimento de uma arquitetura capaz de reconfigurar RSSFs sujeitas à detecção dinâmica de regiões de atenção, nas quais as mensagens devem atingir a BS com maior frequência, menor perda e menor atraso. O objetivo central desta tese é que a arquitetura integre, de forma harmoniosa, um mecanismo de formação da *cluster-tree* com um mecanismo de escalonamento que priorize os dados provenientes dessas regiões.

Nesse contexto, apresenta-se o mecanismo de reescalonamento de *beacons*, denominado **BRAZA** — *Beacon Rescheduling Approach to prioritZe Alertness regions*. A sua ideia básica é ordenar individualmente os nodos prioritários e não prioritários em um escalonamento *bottom-up* e definir um *beacon* intermediário para que o coordenador PAN atenda todos os nodos prioritários e parte dos nodos não prioritários simultaneamente em um intervalo de *beacon*. Este método utiliza lacunas computadas pelos deslocamentos do escalonamento *bottom-up* durante o período CAP, considerando a profundidade e a taxa de dados de cada nodo na tabela de vizinhança.

Primeiramente, quando a *cluster-tree* é formada (Módulo 4), o coordenador PAN possui a tabela de vizinhança (Módulo 2) que abrange todos os nós-sensores, armazenando os dados como uma quádrupla $\{\text{nodeID}, \text{depth}, \text{SO}, \text{dataRate}\}$. Essa estrutura de dados é usada para ordenar os nodos por *dataRate* e, em seguida, pela *depth*. Para calcular o deslocamento de cada nodo, considera-se a seguinte equação:

$$\text{offset}_n = 2^{SO_n} \times SD_{\min} + \text{offset}_{n-1} \quad (11)$$

onde SO_n é a ordem do superframe de um nodo n , $SD_{\min}$ corresponde à duração mínima do superframe (no padrão 802.15.4, a constante é de 960 símbolos) e offset_{n-1} corresponde ao deslocamento do último nodo escalonado. Se o nodo n for o primeiro, $\text{offset}_{n-1} = 0$, caso contrário, offset_{n-1} é igual ao número de símbolos resultante da equação SD. Assim, o coordenador PAN ordena os nodos prioritários e não prioritários por profundidade (no estilo *bottom-up*).

Seja $\mathcal{N}$ o conjunto de todos os nodos não ordenados. O PANC cria um subconjunto $\mathcal{R}$ de nodos prioritários a partir de $\mathcal{N}$, filtrando $\text{dataRate} = \text{high}$. Da mesma forma, um subconjunto $\mathcal{B}$ é criado para nodos não prioritários, marcados com $\text{dataRate} = \text{regular}$ (como na Figura 17).

Então, o PANC ordena cada subconjunto de nodos seguindo estas formulações: $\forall n \in \mathcal{R}$, se $d_n = \max D(\mathcal{R})$ então n é o i -ésimo elemento do escalonamento, ou seja, $n \prec n'/n' \in \mathcal{R} - \{n\}$, e $\forall m \in \mathcal{B}$, se $d_m = \max D(\mathcal{B})$ então m é o j -ésimo elemento do escalonamento, ou seja, $m \prec m'/m' \in \mathcal{B} - \{m\}$. Onde d_n (resp. d_m) é a profundidade do




Figura 17: Ordem de escalonamento proposto.

nodo n (resp. m) e $\max D()$ é a profundidade máxima de um subconjunto. Este processo é descrito no Algoritmo 2 resultando no escalonamento de baixo para cima para $\mathcal{R}$ e $\mathcal{B}$.

Algoritmo 2 Cria um escalonamento *bottom-up*

```

1: procedure CALCULATE-OFFSET( $SO, offset_{prev}$ )
2:   return ( $pow(2, SO) \times 960$ ) +  $offset_{prev}$ 
3: procedure SORT-NODES-BY-DEPTH( $node\_list$ )
4:    $sorted\_nodes \leftarrow []$ 
5:    $maxD \leftarrow \max(node\_list_{depth})$  ▷ get maximum depth of the node list
6:   para each  $n$  in  $node\_list$  faça
7:     se  $n_{depth} < maxD$  então
8:        $sorted\_nodes.append(n)$ 
9:   return  $sorted\_nodes$ 
10: procedure BOTTOM-UP-SCHED( $sorted\_nodes$ )
11:    $offset_{prev} \leftarrow 0$ 
12:   para  $i, node$  in  $sorted\_nodes$  faça
13:      $sorted\_nodes[i] \leftarrow \{node_{ID}, node_{depth}, CALCULATE-OFFSET(node_{SO}, offset_{prev})\}$ 
14:      $offset_{prev} \leftarrow sorted\_nodes[i]_{SO}$ 
15:   return  $sorted\_nodes$  ▷ return sorted node list with updated offsets
16:  $priority\_nodes \leftarrow SORT-NODES-BY-DEPTH(priority\_list)$ 
17:  $BOTTOM-UP-SCHED(priority\_nodes)$ 

```

Conforme descrito, o procedimento CALCULATE-OFFSET executa a Equação 11 a ser aplicada sobre cada nodo na lista ordenada. Tal lista é obtida pela função SORT-NODES-BY-DEPTH, que compara a profundidade do nodo com a profundidade máxima do conjunto (linha 7). O método BOTTOM-UP-SCHED é responsável por modificar a lista ordenada com os respectivos deslocamentos (linhas 13-14).

A partir desse ponto, o PANC define um BO_{PRI} adequado para atender ao escalonamento de nodos prioritários com base na soma do desvio padrão dos nodos prioritários e no BO padrão retornado da configuração inicial da topologia. O BO padrão é o BO inicial que atende a todos os nodos no conjunto N e é denotado como BO_{DEF} . Desta forma, a PANC terá, além de BO_{DEF} , um BO_{PRI} definido da seguinte forma:

$$BO_{PRI} = \left\lceil \log_2 \left[\left(\sum_{i=1}^n SD_i \right) / SD_{min} \right] \right\rceil \quad (12)$$

onde $\sum SD_i$ é a soma da duração do superframe de todos os nodos i no subconjunto $\mathcal{R}$, enquanto BO_{DEF} se torna o **BO** dos nodos subsequentes, dependendo do conceito de *gap* (espaço entre os nodos prioritários SD e o próximo *beacon* PANC). Aqui, definimos $\mathcal{G}$ como o *gap* dentro de cada *BI* e a porção **BI** onde os nodos não prioritários trocarão mensagens, que é obtido pela equação $\mathcal{G} = T_{BO_{PRI}} - T_{HOT}$, sendo $T_{BO_{PRI}}$ o tempo de um BO_{PRI} e T_{HOT} o tempo total de todos os nodos prioritários em $\mathcal{R}$ para transmitir dados. É possível deduzir T_{HOT} da soma de SO de cada **CH** em $\mathcal{R}$. Além disso, sendo N_G o número de lacunas para atender a todos os nodos não prioritários a partir da soma dos SO dos nodos em $\mathcal{B}$, definido aqui como T_{REG} (tempo dos nodos regulares), como segue:

$$N_G = \lceil T_{REG} / \mathcal{G} \rceil \quad (13)$$

que determinará a proporção de escalonamento de **BI** de $\mathcal{R}$ para $\mathcal{B}$ e o número de grupos de nodos não prioritários que transmitirão dados.

4.6 Exemplo de aplicação do mecanismo BRAZA

Para determinar a proporção de **BI**, o método proposto considera o valor de N_G para alocar a duração do superframe de nodos não prioritários simultaneamente aos nodos prioritários. Para isso, quando N_G é par, basicamente cada grupo alterna o **BO** entre múltiplos de BO_{PRI} e BO_{DEF} . No entanto, quando N_G é ímpar, cada grupo é atribuído com a função de módulo ($k \bmod N_G$), onde cada grupo alternará entre BO_{PRI} e BO_{DEF} corretamente com base no intervalo atual k , conforme ilustrado na Figura 18.




Figura 18: Reescalonamento para atender configurações com casos pares e ímpares.

Conforme observado, para $T_{REG} = 1,0$ temos $N_G = 2$ que consiste em $\mathcal{B}$ com $\{B_1, B_2\}$, onde para cada nodo b em B_1 o **BO** é BO_{PRI} e para cada nodo bb em B_2 o **BO** é BO_{DEF}

(respectivamente, 7 e 8), devido ao N_G par (conforme representado no topo da Figura 18). Por outro lado, na parte inferior da figura, quando $T_{REG} = 1,61$, temos $N_G = 3$, que consiste em $\mathcal{B}$ com $\{\mathcal{B}_1, \mathcal{B}_2, \mathcal{B}_3\}$. Para agrupar adequadamente os nodos nesses subconjuntos, usamos o algoritmo 3 conforme descrito.

Algoritmo 3 Agrupa os nodos não prioritários e lhes atribui aos respectivos BO.

```

1:  $SCHED_{\mathcal{B}} \leftarrow []$ 
2:  $k \leftarrow 0$ 
3:  $gap\_acc \leftarrow 0$ 
4: para each  $b$  in  $\mathcal{B}$  faça
5:    $gap\_acc \leftarrow gap\_acc + SD_b$ 
6:   se  $gap\_acc \leq \mathcal{G}$  então
7:      $SCHED_{\mathcal{B}}.append(k, b)$  ▷ stores node  $b$  in subset  $k$  from  $\mathcal{B}$ 
8:   senão
9:      $k \leftarrow k + 1$  ▷ increase index of  $\mathcal{B}$ 
10:   $gap\_acc \leftarrow 0$ 
11: return  $SCHED_{\mathcal{B}}$ 

```

O Algoritmo 5 aloca nodos não prioritários em $\mathcal{B}$ em uma estrutura $SCHED_{\mathcal{B}}$ que armazena a parte k para cada lacuna quando a gap_acc não sucede o valor G . Quando gap_acc é maior que G , o índice do subconjunto ($\mathcal{B}_k$) é incrementado e o valor acumulado tende a zero.

Considerando uma configuração de escalonamento onde o valor de N_G é ímpar (como o último exemplo na Figura 18), o BO_{DEF} deve ser definido como $BO_{PRI} + (N_G - 1)$ (por exemplo, nesse exemplo, 7 para $\mathcal{R}$ e 9 para $\mathcal{B}$). Assim, quando todos os nodos não prioritários estiverem agrupados, o mecanismo deve atribuir o deslocamento correto para cada nodo de cada grupo. Para isso, utiliza-se a seguinte equação:

$$offset_k = BO_{DEF} - (N_G + 1) \times \mathcal{G} - N_G \times T_{HOT} + (k \bmod N_G) \times BO_{PRI} \quad (14)$$

onde k , neste caso, representa o BI atual para conduzir adequadamente o escalonamento, conforme ilustrado em detalhes na Figura 19.




Figura 19: Reescalonamento dos *duty-cycles* para atender os nodos não prioritários.

Conforme ilustrado, aplicando a Equação 14 para $k = 0$, cada nodo b em $\mathcal{B}_1$ iniciará sua transmissão devidamente deslocado em 1,42s; para $k = 1$, cada nodo bb em $\mathcal{B}_2$ iniciará sua transmissão devidamente deslocado em 3,38s; e, para $k = 2$, cada nodo bbb em $\mathcal{B}_3$ iniciará sua transmissão devidamente deslocado em 5,35s. Isso encerra um período de ciclo de trabalho (CC) e, no próximo ciclo de trabalho, esse comportamento se repete

para $k = 3$, com deslocamento de 1,42s, $k = 4$, com deslocamento de 3,38s, $k = 5$, com deslocamento de 5,35s, e assim por diante.

Semelhante à abordagem TDBS, o mecanismo BRAZA implica a definição de um ciclo principal e um ciclo secundário. Neste caso, o ciclo secundário (MICY) definido aqui é usado para priorizar nodos com alta taxa de dados, enquanto o ciclo principal (MACY) é definido para cada nodo no grupo não priorizado. MICY e MACY são ilustrados na Figura 20, onde cada linha do tempo descreve o período de ativação de cada grupo de nodos. As três últimas linhas do tempo representam a linha do tempo de cada grupo não prioritário derivado do exemplo anterior (quando o valor de N_G é ímpar).




Figura 20: Reescalamento dos *duty-cycles* de cada grupo de nodos.

É importante observar que, em casos em que $\sum SD_i$ é igual a BI, podemos ter cenários sem o tempo de transmissão de nodos não prioritários. Para evitar esse tipo de problema, adicionamos uma condição para verificar: se $SD_i == BI$, então $BO_{PRI} = BO_{PRI} + 1$. Além disso, essa definição de dois BOs para PANC impacta diretamente a definição de BO e SO dos nodos não prioritários no subconjunto $\mathcal{B}$. Para lidar com esse problema, restringimos as seguintes condições:

$$BO_j = \begin{cases} BO_{PRI}, & \text{if } d_j \leq \lceil \max D(\mathcal{B})/2 \rceil \\ BO_{DEF}, & \text{otherwise} \end{cases} \quad (15)$$

sendo BO_j o *beacon order* para cada nodo j no subconjunto $\mathcal{B}$. Esse valor será usado para definir o deslocamento de cada j como:

$$offset_j = SD_j + \sum SD_i + offset_{j-1} \quad (16)$$

Desse modo, o mecanismo de escalonamento proposto não exige uma modificação da estrutura de superframe ou de excessivos ajustes de parâmetros do CSMA-CA padrão ou variáveis de enlace MAC, comumente encontrados na literatura. A abordagem descrita aqui considera a adição de um novo valor de BO para o coordenador PAN, intermediário ao BO padrão da rede, de modo a atender parte dos nodos em momentos

distintos. Esta abordagem, além de priorizar os nodos em regiões de atenção, não impacta negativamente no escalonamento dos demais (como ocorre em algumas propostas que modificam a estrutura de *superframe*). Estas propostas são avaliadas no próximo capítulo comparando as métricas de QoS e o impacto sobre os nodos prioritários.

4.7 Considerações sobre a Arquitetura

A arquitetura proposta neste capítulo visou estabelecer um mecanismo para a formação de redes *cluster-tree* orientada pelos dados monitorados pelos nodos, integrado a um processo de escalonamento capaz de priorizar o tráfego proveniente de regiões de atenção. Os módulos que compõem a arquitetura foram concebidos de forma flexível e modular, permitindo futuras substituições por componentes mais adequados a cenários ou aplicações específicas.

À medida que a literatura evolui nesses temas, novas abordagens podem ser incorporadas, ou mecanismos com a mesma finalidade podem substituir os aqui definidos. Por exemplo, caso surjam técnicas de aprendizagem voltadas à formação topológica com menor complexidade que o CALiPSO, mas capazes de alcançar níveis equivalentes de clusterização e QoS, tal módulo poderá ser substituído sem dificuldade. O mesmo raciocínio se aplica aos módulos de escalonamento de *beacons* da rede.

O capítulo seguinte apresenta os principais resultados obtidos por meio das avaliações realizadas em ambiente de simulação, bem como métricas coletadas em experimentos com plataformas reais, utilizadas para a validação prática dos mecanismos propostos.

5 Resultados do CALiPSO e do BRAZA na Arquitetura Orientada a Dados

Neste capítulo, são apresentados os resultados obtidos por meio de simulações e experimentos que avaliam os diferentes módulos da arquitetura proposta. A Seção 5.1 descreve o simulador, os *frameworks* e os cenários de larga escala utilizados no conjunto de simulações. A Seção 5.2 compara o uso de diferentes técnicas de clusterização. A Seção 5.3 apresenta os resultados sobre as abordagens de formação direcional, comparando estratégias *bottom-up* e *top-down* com métodos heurísticos e avaliando o impacto do uso do valor de RSSI. Em seguida, a Seção 5.4 discute os resultados do mecanismo de formação topológica otimizada baseado em PSO leve, comparado a abordagens heurísticas e à versão tradicional do PSO. A Seção 5.4.4 analisa a complexidade algorítmica do método proposto, enquanto a Seção 5.4.6 apresenta sua validação experimental em uma plataforma microcontrolada. Por fim, a Seção 5.5 discute os resultados do mecanismo de reescalonamento prioritário, comparado a diversas abordagens da literatura, incluindo técnicas de otimização, modificações no *superframe* do IEEE 802.15.4 e estratégias alternativas de priorização.

5.1 Cenários Usados para a Avaliação por Simulação

Todas as implementações desenvolvidas neste trabalho utilizam a ferramenta Castalia⁴, que é um simulador de RSSF, aplicações WBAN e dispositivos embarcados de baixo consumo, baseado na plataforma OMNeT++. O Castalia é amplamente reconhecido na literatura por sua alta precisão na modelagem da troca de mensagens entre nodos, considerando efeitos de obstáculos e variações do canal. Além disso, ao Castalia foi acoplado o CT-Sim, que é um conjunto de ferramentas desenvolvido para a construção eficiente de redes *cluster-tree*.

Para a avaliação, conforme ilustrado na Figura 21, foram utilizados dois cenários reais de monitoramento e controle em larga escala amplamente empregados na literatura: *Intel Lab Data* e *IEEE-test-feeder*. Com o objetivo de facilitar a visualização, os nodos destacados em vermelho representam aqueles identificados como pertencentes a regiões de atenção (nodos em *hotspots* – prioritários), enquanto os em azul correspondem aos demais nodos, de menor prioridade.

O cenário da esquerda na figura corresponde ao Intel Lab Data⁵, um ambiente *indoor* de 35×40 m com presença de obstáculos, onde nós-sensores coletam dados de temperatura, umidade e luminosidade, armazenados periodicamente (a cada hora) pela estação base. O segundo cenário, na direita, denominado IEEE-Test-Feeder⁶, representa um ambiente *outdoor* de 300×215 m voltado à distribuição de subestações elétricas, simulando comunicações industriais com cerca de 125 nodos que transmitem dados em diferentes periodicidades.

⁴<https://github.com/boulis/Castalia>

⁵<http://db.csail.mit.edu/labdata/labdata.html>

⁶<https://cmte.ieee.org/pes-testfeeders/resources/>




Figura 21: Cenários de simulação.

No Intel Lab, aproximadamente 54 nodos são monitorados pela estação base localizada no centro da área, representada pelo nodo 4. O cenário IEEE Test Feeder é comumente utilizado em simulações de *smart grids* com múltiplos *sinks*; entretanto, nas avaliações deste trabalho, consideram-se apenas redes com um único *sink*, sendo o nodo 39 — o mais centralizado — definido como estação base.

5.2 Avaliação de Técnicas de Clusterização de Dados

Ao longo da pesquisa, também foram investigados alguns algoritmos de clusterização amplamente utilizados em redes de larga escala para fins como fusão, filtragem, detecção de *outliers* e agregação. O objetivo foi avaliar de que forma as *Data Clustering Techniques* (DCTs) podem influenciar a QoS na arquitetura proposta. Para isso, foram realizadas simulações no cenário Intel Lab considerando a implementação das técnicas DBSCAN, *K-means*, *K-NN* e Fuzzy-C-means [65].

Na avaliação, foram executadas dez rodadas de simulação para o cenário das 10 horas, em que os nodos em regiões de atenção foram definidos conforme cada técnica. Os resultados apresentados na Figura 22 evidenciam como o desempenho varia levemente em função das regiões de atenção identificadas por cada algoritmo.




Figura 22: Métricas de QoS avaliadas sob a implementação de DCTs.

A Figura 23 destaca os valores obtidos com relação a taxa de entrega de pacotes ao

coordenador PAN em cada uma das dez rodadas de simulação.




Figura 23: Taxa de recebimento de pacotes ao longo de 10 rodadas.

Embora a técnica DBSCAN tenha apresentado um desempenho discretamente superior no conjunto de experimentos analisados e embora a abordagem $K-NN$, que constitui um método supervisionado, tenha exibido o pior resultado quanto à taxa de sucesso na entrega de pacotes, verificou-se que as diferenças observadas entre os algoritmos permaneceram, em termos gerais, relativamente modestas. Diante desse cenário, optou-se por dar continuidade ao emprego do método $K-means$ no desenvolvimento deste trabalho, sobretudo em razão de sua simplicidade operacional, de sua ampla difusão na literatura e de sua adequação aos objetivos propostos.

5.3 Mecanismos de Formação Direcional: BUF-pan e BUF-red

Nesta seção, são apresentados os resultados referentes às avaliações de diferentes heurísticas para o processo de formação de redes *cluster-tree* direcionais. Nas simulações iniciais, foram implementados métodos heurísticos para a formação da rede, comparando técnicas de seleção de CHs com orientação direcional (*bottom-up* e *top-down*). A abordagem proposta no início da pesquisa baseia-se em dados monitorados do ambiente para subsidiar o processo de tomada de decisão na formação da rede. Essa proposta, denominada **BUF** (*Bottom-Up Formation*), compreende dois mecanismos de formação que adotam um gerenciamento centralizado em modo *bottom-up*, no qual o coordenador PAN é responsável pela gestão dos nodos, pela formação dos *clusters* e pelo estabelecimento dos caminhos entre os ramos prioritários e o próprio coordenador PAN, partindo dos nodos mais distantes.

Os mecanismos denominados *BUF-pan* e *BUF-red* correspondem, respectivamente, a um método de seleção orientado à escolha de nodos com menor profundidade e a uma seleção baseada na vizinhança entre nodos pertencentes a um mesmo grupo. Ambas as abordagens têm suas heurísticas descritas pela máquina de estados apresentada na Figura 24.

Basicamente, cada abordagem toma decisões diferentes quando uma situação de incerteza é encontrada. Por exemplo, como os nodos prioritários são formados primeiro, a ideia é agrupar a maior quantidade de nodos possível do ramo vermelho; porém, quando não houver mais candidatos do grupo para selecionar, obrigatoriamente, o coordenador PAN deve selecionar um nodo de outra característica (azul) para criar a ponte entre os ramos homogêneos e a raiz. Assim, nessa situação, o *BUF-pan* seleciona os nodos




Figura 24: Máquina de estados dos mecanismos BUF.

heterogêneos (tanto vermelhos quanto azuis) mais próximos da raiz (com menor profundidade); enquanto o *BUF-red* seleciona nodos de forma a encontrar ramos de mesma característica (selecioneando nodos a partir de vizinhos do mesmo grupo).

Ambos os mecanismos foram comparados a uma abordagem da literatura, apresentada na Seção 3, denominada *DbCTF* (*Data-based Cluster Tree Formation*), que adota um método de seleção *top-down* baseado no valor de *RSSI*. As três abordagens são orientadas por dados e realizam o processo de clusterização antes da formação dos *clusters* prioritários. Em todas elas, emprega-se o algoritmo *K-means* com $k = 2$ para tal finalidade. O comportamento de cada abordagem foi avaliado com base nos dados reais de temperatura e umidade do ambiente de monitoramento *Intel Lab Data*, disponibilizados pela Universidade de Berkeley. Dessa forma, busca-se comparar diretamente as estratégias *bottom-up* e *top-down* de formação, que diferem tanto nas heurísticas de seleção de nodos quanto nos critérios de agrupamento.

É importante destacar que, como a proposta não considera o uso de *RSSI*, o algoritmo de descoberta de vizinhança utilizado é o algoritmo apresentado no Módulo 2 da Arquitetura da Seção 4.2. Em seguida, para todas as abordagens, o desempenho foi avaliado pelas principais métricas de rede, como: os atrasos de comunicação fim-a-fim, taxa de pacotes perdidos na troca de mensagens e a estimativa do consumo energético, e os parâmetros de simulação são descritos na Tabela 6.

Foram avaliados dois cenários distintos, correspondentes a diferentes horários do dia, de modo a garantir a ocorrência de variações nos dados de temperatura e umidade. Dessa forma, foram selecionados os horários das 10h e 16h para as simulações, cada uma executada por 996 minutos. Os resultados referentes às principais métricas de *QoS* são apresentados na Figura 25.

Observa-se que, em comparação ao *DbCTF*, ambas as propostas reduzem significativamente o atraso das mensagens (aproximadamente 57% menor no cenário das 10h e até 63% menor no das 16h), além de apresentarem taxas de perda de pacotes bastante baixas (entre 8% e 10% no primeiro cenário e entre 6% e 10% no segundo). A discreta diferença entre o *BUF-red* e o *BUF-pan* decorre das pequenas variações topológicas geradas durante a fase de tomada de decisão. Ademais, ambas as abordagens estenderam

Tabela 6: Parâmetros de simulação da avaliação de abordagens de formação direcional.

Parâmetros	Valores	Unidade
Rodadas de Simulação	5	sementes
Tempo de Simulação	59760	segundos
Intervalo de <i>Beacon</i>	15,72	segundos
Energia inicial	200	Joules
Número de membros do <i>cluster</i>	6	nodos
Número de CHs filhos	3	nodos
Periodicidade de Dados de Nodos Vermelhos	0,05	pacotes/segundo
Periodicidade de Dados de Nodos Azuis	0,01	pacotes/segundo

a vida útil dos dispositivos em cerca de três horas em relação ao DbCTF (Figura 25c). Esse resultado se deve ao fato de que, na seleção *bottom-up* dos CHs, ocorre um número menor de nodos modificados (aqueles que migram de azuis para vermelhos), conforme ilustrado na Figura 26b. (Notar que os nodos modificados que eram azuis passam a operar na periodicidade dos nodos vermelhos, aumentando suas taxas de geração de dados e, conseqüentemente, o gasto de energia.)

O esquema DbCTF modifica 5 nodos no cenário das 10h e 4 nodos no cenário das 16h; o *BUF-red* altera apenas um nodo em ambos os cenários; e o *BUF-pan* modifica 2 nodos no cenário das 10h e 1 nodo no das 16h. O efeito sobre atrasos e perdas torna-se ainda mais evidente ao se analisar o número de *clusters* gerados: o DbCTF alcança até 24 *clusters*, enquanto o *BUF-red* e o *BUF-pan* formam, no máximo, 17 *clusters* no cenário das 10h. No cenário das 16h, a média observada é de aproximadamente 20 *clusters* para o DbCTF e 17 para ambas as versões do *BUF*.

Como a formação dos grupos no DbCTF ocorre de maneira simultânea, nodos azuis podem ser selecionados antes dos nodos vermelhos, o que pode afastar a seleção inicial dos objetivos de priorização dos *clusters*. Nessa situação, priorizar um grupo vermelho que se tornou isolado devido a uma seleção inadequada de nodos azuis exigiria uma fase adicional de reconfiguração topológica pelo DbCTF. Assim, quando os ramos de maior prioridade não são alcançados nos primeiros passos da formação *top-down*, a busca posterior por ramos vermelhos pode criar caminhos contendo muitos nodos azuis anteriores, que precisariam ser posteriormente convertidos em vermelhos, aumentando a carga da rede e o consumo de recursos. Por esse motivo, o método de formação *bottom-up* torna-se uma alternativa mais adequada, pois cria os grupos vermelhos antes dos azuis, selecionando nodos descendentes até convergir para o coordenador PAN.

Para demonstrar o impacto dos métodos de seleção avaliados sobre as regiões de atenção, foram analisados especificamente os nodos vermelhos considerando os atrasos de comunicação fim-a-fim e taxa de sucesso na entrega de mensagens. Os resultados apresentados na Figura 27 demonstram que a diminuição dos atrasos obtidos em nodos com alto tráfego de dados impacta fortemente o atraso total da rede.

BUF-red e *BUF-pan* apresentaram reduções de atraso de 67% e 72%, respectivamente, para os nodos pertencentes às regiões de atenção. Além disso, as taxas de entrega para




Figura 25: Resultados referentes aos atrasos de comunicação e perda de pacotes das abordagens *bottom-up* e *top-down*.

esses nodos variaram de 94% a 99% no *BUF-red* e de 83% a 86% no *BUF-pan*.

Por fim, a quantidade de *clusters* por profundidade foi avaliada para cada abordagem, conforme ilustrado na Figura 28. Essa análise permite observar a distribuição e a densidade dos grupos ao longo dos diferentes níveis da árvore. Em ambos os cenários, a técnica *BUF-pan* apresenta, em média, um número menor de *clusters* do que o método *DbCTF*. Já a abordagem *BUF-red* exibe comportamento semelhante ao *DbCTF* no cenário das 16h, diferindo apenas no cenário das 10h, onde forma um número maior de grupos na profundidade 2. Contudo, nesse caso, a técnica compensa essa maior densidade ao produzir uma árvore com profundidade global menor. De forma análoga, embora o *BUF-red* apresente maior profundidade no cenário das 16h, a quantidade de *clusters* diminui progressivamente com o aumento da profundidade.

Considerando esses resultados, os mecanismos implementados nesta avaliação inicial tiveram como objetivo, primeiramente, analisar separadamente o comportamento das técnicas *BUF-pan* e *BUF-red* [64]. Com base nessa análise, buscou-se então combinar as vantagens de ambas, de modo a estabelecer uma sequência de ações adequada para a construção da árvore e para comparação com abordagens tradicionais da literatura, como o *DbCTF*. Esses resultados serviram, posteriormente, como referência para avaliar o método meta-heurístico proposto neste trabalho, a abordagem otimizada CALiPSO, que fornece um mecanismo mais leve e capaz de superar as métricas obtidas pelo *BUF-red* e pelo *BUF-pan*.




Figura 26: Resultados referentes à estrutura formada por cada abordagem direcional.




Figura 27: Resultados referentes às métricas da rede de cada abordagem direcional.

5.4 Resultados do Mecanismo de Formação Topológica CALiPSO

Nesta seção, são apresentados os resultados obtidos com a implementação do mecanismo de formação meta-heurístico denominado CALiPSO. Para fins de comparação, o desempenho do método proposto é confrontado com técnicas recentes da literatura que abordam problemas análogos, tanto no que se refere à identificação de regiões de atenção quanto ao uso de procedimentos de otimização baseados em PSO. Nesses cenários experimentais, os nodos classificados como de maior prioridade (isto é, aqueles pertencentes às regiões de atenção) são representados pela cor vermelha, ao passo que os nodos não prioritários são exibidos em azul.

Considerou-se que as abordagens gulosas (gananciosas) correspondem às heurísticas empregadas para a seleção de CH, as quais, em geral, realizam essa escolha com base em critérios como quantidade de vizinhos, profundidade mínima ou informações mantidas nas listas de vizinhança. Por outro lado, foram caracterizadas como abordagens baseadas em otimização aquelas que utilizam uma função objetivo com o propósito de maximizar ou minimizar métricas de interesse na definição dos CHs. A seguir, são descritos em maior detalhe os métodos incluídos nas comparações realizadas.

- **BUF-pan** [64]: abordagem gulosa baseada em heurística que seleciona quaisquer nodos como CH, considerando exclusivamente a profundidade. Nessa lógica, nodos mais próximos da BS apresentam maior probabilidade de serem escolhidos.
- **BUF-red** [64]: abordagem gulosa baseada em heurística que seleciona CHs levando




Figura 28: Número de *clusters* gerados por profundidade em cada abordagem.

em conta simultaneamente a profundidade e a prioridade. Dessa forma, em regiões de atenção, os CHs são escolhidos entre os nodos de maior prioridade; fora dessas regiões, a seleção recai sobre nodos de menor prioridade.

- **BPSO-A** [62]: abordagem de otimização baseada no algoritmo BPSO, voltada à seleção de CH e à redução do consumo energético. A técnica utiliza uma função multiobjetivo para maximizar a taxa de cobertura e o tempo de vida dos nodos. Nessa proposta, não há definição de regiões de atenção nem suposição de tráfego com diferentes níveis de prioridade.

As simulações foram conduzidas com o objetivo de analisar as estruturas *cluster-tree* resultantes de abordagens heurísticas (BUF-pan e BUF-red) e meta-heurísticas (BPSO-A e CALiPSO). A análise contemplou o número de *clusters* formados, a profundidade média da árvore e as métricas de QoS associadas aos atrasos de comunicação e às perdas de pacotes decorrentes da topologia produzida por cada método. As técnicas BUF-pan e BUF-red empregam um processo de seleção de CH baseado em uma estratégia *bottom-up*, embora seja fundamentado inteiramente em heurísticas. Em contraste, o BPSO-A constitui uma abordagem meta-heurística que define os CHs a partir da localização dos nodos, mantendo igualmente uma lógica de formação de caminhos no sentido *bottom-up*.

Conforme descrito na Seção 3.3.1, o BPSO-A utiliza três funções ($f1$, $f2$ e $f3$) destinadas, respectivamente, a otimizar o posicionamento dos nodos com base no desvio padrão médio da soma das distâncias entre cada nodo e seus vizinhos, a aumentar o tempo de inatividade para economizar energia e a melhorar a distribuição dos nodos entre os *clusters*. Para esta avaliação, a implementação do BPSO-A foi empregada considerando a localização dos nodos nas fases 1 e 3 do algoritmo.

Na fase 2, ajustou-se a geração de valores aleatórios de energia e tempo de inatividade de modo a torná-los consistentes com o cenário que contempla regiões de atenção. Como os nodos pertencentes a essas regiões possuem maior prioridade e apresentam uma taxa de geração de dados mais elevada, eles tendem a consumir mais energia e a apresentar menor tempo de inatividade. Essa adaptação é relevante, pois o BPSO-A, em sua formulação original, não considera explicitamente a existência de regiões de atenção nem diferencia nodos com base em padrões distintos de tráfego.

Desse modo, o algoritmo foi executado utilizando as equações de evolução das partículas definidas em Li, Cao [62] e seguindo os parâmetros de configuração apresentados

na Tabela 7.

Tabela 7: Detalhes de simulação para os mecanismos de formação com e sem PSO.

Parâmetros	Intel Lab	IEEE-test-feeder
Número de nodos	54	125
Área do ambiente	40x35 metros	300x215 metros
Nodos por <i>cluster</i> (CHs)	6 membros (até 3 CHs)	8 membros (até 4 CHs)
Nodo usado como BS (posição)	nodo 4 (centro)	nodo 39 (centro)
Número de nodos nos <i>hotspots</i>	16	19
Energia inicial	200 J	800 J
Tempo total de simulação	57960 s	128960 s
Intervalo de <i>beacon</i>	3932 ms	7864 ms
Potência de transmissão ¹	-5 dBm	0 dBm

¹CC 2420 com configuração de rádio baseada no modo beacon do IEEE 802.15.4.

A Figura 21 apresenta os cenários de larga escala utilizados neste trabalho. Os processos de seleção dos nodos prioritários em cada cenário foram distintos.

No cenário Intel Lab, o nodo 4 foi escolhido como nodo raiz, atuando como *sink* e coordenador PAN. Essa escolha decorreu do fato de esse nodo estar localizado mais próximo do centro da área monitorada, conforme indicado em trabalhos anteriores [9, 64]. A região de atenção, composta por nodos prioritários, foi definida por meio de um processo de clusterização de dados, sendo seus nodos representados em vermelho escuro na Figura 21. Os dados utilizados nessa etapa de detecção de regiões de atenção corresponderam a leituras reais de sensores coletadas ao longo de aproximadamente seis a dez horas consecutivas. Os nodos não prioritários são representados em azul claro.

No cenário IEEE-test-feeder, por outro lado, existem duas regiões de atenção distintas, definidas aleatoriamente. O nodo 39, por ser o mais centralizado, foi selecionado como nodo raiz, atuando como *sink* e coordenador PAN. Alguns parâmetros de simulação apresentados na Tabela 7, como energia inicial, intervalo de *beacon* e tempo total de simulação, foram ajustados devido à maior área e ao maior número de nodos presentes nesse cenário.

5.4.1 Análise de desempenho dos algoritmos de formação topológica

Esta seção apresenta uma avaliação do comportamento de abordagens de formação de topologias (heurísticas e meta-heurísticas), considerando os seguintes aspectos: a profundidade máxima das árvores, o número de nodos modificados e o número de CHs prioritários na rede. Os resultados são apresentados nas figuras 29 e 30.

A profundidade máxima da rede indica o número máximo de saltos que uma mensagem de um nodo deve percorrer para chegar à BS. Os nodos modificados são aqueles identificados como azuis (não prioritários), que foram convertidos em vermelhos (nodos de maior prioridade) devido à necessidade de seleção para serem utilizados como uma ponte entre os nodos de uma região de atenção e a BS durante o processo de seleção de CHs. O número de CHs está associado ao total de *clusters* na rede.

Para os *clusters* formados pelo BPSO-A, como não há priorização de formação de nodos de uma região de atenção, é natural a ocorrência de nodos azuis (não prioritários)




Figura 29: Topologia resultante de cada abordagem no cenário IEEE-test-feeder.

conectados a *clusters* prioritários (nodos vermelhos). Além disso, algumas partículas BPSO-A podem gerar configurações com nodos órfãos não conectados a um CH próximo. Neste caso, o número de nodos modificados é contabilizado considerando o número de nodos de ponte entre CHs prioritários e a BS.

Esta configuração foi obtida a partir de uma população inicial de 10 partículas aleatórias e 10 partículas ordenadas por distância (de acordo com o valor $f1$ da função de aptidão, definida em [62], após 100 iterações). Dentre as partículas com melhor valor de fitness, foi selecionada aquela que apresenta configuração que não ultrapassa o número de CHs, o que torna o modelo não escalonável.

Conforme mostrado na Figura 29, quanto menor o número de CHs, mais homogênea é a rede (com menos ramificações). Entretanto, quanto menor a profundidade da rede e o número de nodos modificados, melhor desempenho pode ser obtido, pois reduz-se o número de saltos e de nodos que geram dados com maior frequência, respectivamente. Em ambos os cenários, o CALiPSO obteve o menor número de CHs e nodos modificados.

No que se refere às regiões de atenção do cenário de maior escala (IEEE-test-feeder) da subestação elétrica, as imagens (a–d) da Figura 30 ilustram as topologias resultantes para a primeira região de atenção em cada abordagem. Observa-se que BUF-red e BUF-pan formam oito CHs e modificam cinco nodos, enquanto o CALiPSO forma sete CHs e modifica quatro nodos.

Considerando as abordagens de otimização, o BPSO-A apresenta desempenho semelhante ao BUF-pan, alcançando, respectivamente, nove e sete CHs prioritários e modificando dois e dez nodos nos cenários avaliados. As profundidades máximas observadas nessas configurações foram seis e nove. O CALiPSO, por sua vez, seleciona apenas quatro CHs para gerenciar nodos de alta prioridade, em contraste com os sete e nove selecionados por BUF-red, BUF-pan e BPSO-A, respectivamente, o que corresponde a uma redução aproximada de 42% a 55% no número de CHs.

As imagens (e–h) apresentam as topologias obtidas para a segunda região de atenção. Nesse caso, BUF-red e BUF-pan geram quatro CHs prioritários, e o BPSO-A resulta em cinco, enquanto o CALiPSO obtém apenas dois CHs, reforçando sua capacidade de simplificar a estrutura mantendo a priorização adequada.

Embora esses resultados ofereçam uma visão inicial sobre o funcionamento das abordagens analisadas, é importante destacar que as topologias apresentadas na Figura 30 não devem ser interpretadas como representativas de todos os experimentos simulados. Elas ilustram apenas um exemplo específico da topologia resultante após o processo de




Figura 30: Topologia resultante de cada abordagem no cenário IEEE-test-feeder.

configuração, com o propósito de evidenciar a capacidade do CALiPSO de gerar árvores com profundidades menores.

5.4.2 Análise qualitativa das topologias formadas pelo CALiPSO

Nesta subseção, analisamos as variações topológicas da rede obtidas com o método proposto. Conforme ilustrado na Figura 31, a topologia apresentada à esquerda corresponde a uma *RSSF* em malha referente ao maior cenário avaliado, cuja formação inicial decorre de trocas de mensagens realizadas antes de o coordenador PAN aplicar o algoritmo *BPSO* e gerar as partículas correspondentes à fase de otimização. A topologia à direita, resultante da execução do CALiPSO, apresenta a rede estruturada em *clusters* mais homogêneos, com um número reduzido de *CHs* e com uma clara priorização das regiões de atenção.




Figura 31: Topologia resultante do CALiPSO no cenário IEEE-test-feeder.

Observa-se que, na rede sem a aplicação do CALiPSO, formam-se diversos *clusters* com densidades heterogêneas, além de múltiplas interconexões entre grupos com diferentes níveis de prioridade. Na ausência de um mecanismo explícito de priorização no fluxo

de mensagens, essa configuração tende a produzir gargalos, congestionamentos, perdas de pacotes e atrasos decorrentes de colisões no meio. A inexistência de uma estrutura de comunicação hierárquica evidencia um gerenciamento inadequado da rede, dificultando o estabelecimento de rotas eficientes entre as regiões de atenção e a BS. Ademais, uma rede com esse grau de complexidade implicaria, caso se conseguisse obter um escalonamento da rede IEEE 802.15.4 viável, em uma escala fragmentada e com grandes folgas (intervalos ociosos).

5.4.3 Avaliação de QoS das topologias formadas pelo CALiPSO

O desempenho das abordagens foi avaliado com base em métricas clássicas de redes, especificamente o atraso de comunicação fim a fim e a taxa de perda de pacotes. A Figura 32 apresenta os valores médios dessas métricas para cada abordagem, considerando ambos os cenários de simulação. Essa avaliação contempla cinco rodadas de execução, utilizando os parâmetros definidos na Tabela 7 e envolvendo a troca de mensagens por todos os nodos da rede.




Figura 32: Atraso fim a fim e perdas de pacotes nos dois cenários avaliados.

Observa-se que a taxa de perda de pacotes entre os nodos é diretamente influenciada pela estrutura topológica produzida por cada abordagem. No cenário Intel Lab, enquanto BUF-pan e BUF-red apresentam taxas de perda acima de 9%, o CALiPSO reduz esse valor para aproximadamente 7%. De maneira semelhante, no cenário IEEE-test-feeder, as perdas mantêm-se em torno de 14% para o CALiPSO, em comparação com os cerca de 15% obtidos pelas abordagens heurísticas. Além disso, nesse cenário mais amplo, o CALiPSO apresentou menores atrasos de comunicação quando comparado às demais alternativas avaliadas.

A menor taxa de perda de pacotes obtida pelo CALiPSO pode ser explicada pelo número reduzido de CHs selecionados, o que aumenta a densidade de nodos por *cluster* e promove maior homogeneidade nas regiões de atenção. *Clusters* mais densos tendem a equilibrar melhor o tráfego proveniente de nodos prioritários, o que não se verifica nas demais abordagens.

Quanto aos atrasos de comunicação, os valores obtidos em ambos os cenários são relativamente próximos, em grande parte devido ao número limitado de ramificações na estrutura da árvore. Esse aspecto decorre do número reduzido de nodos modificados, isto é, nodos originalmente não prioritários que passam a ser considerados prioritários para atuar como ponte entre as regiões de atenção e a BS.

Na avaliação do CALiPSO por simulação, também foi medido o número de pacotes recebidos pela BS. As figuras 33 e 34 apresentam os resultados de cinco execuções de simulação para cada abordagem.




Figura 33: Pacotes recebidos pela BS no cenário Intel Lab.

Pode-se observar que o CALiPSO atinge um número maior de pacotes entregues com sucesso, resultando em mais de 20 pacotes adicionais, em média, no cenário Intel Lab, e mais de 10 no cenário mais amplo. Além disso, verifica-se que o CALiPSO apresentou resultados superiores em 4 de 5 execuções no cenário Intel Lab e em 3 de 5 execuções no cenário mais amplo.




Figura 34: Pacotes recebidos pela BS no cenário IEEE-test-feeder.

Também foi avaliado o consumo de energia de toda a rede, a fim de analisar o impacto do processo de formação e da seleção de CHs na eficiência energética. Para essa análise, foi adotado o modelo energético padrão do Castalia. As Figuras 35 e 36 mostram que o CALiPSO apresentou valores de consumo inferiores aos obtidos pelos demais métodos avaliados. Considerando-se as médias (nos gráficos à esquerda de cada figura), observa-se um ganho modesto do CALiPSO em ambos os cenários.

Pode-se observar, também, que todos os métodos avaliados mantêm valores de consumo em torno de 93 a 96 J no cenário com dezenas de nodos e em torno de 230 J no cenário maior. Esse resultado demonstra que o CALiPSO, embora inclua um algoritmo de otimização que poderia, em princípio, aumentar o consumo energético, não impõe gasto adicional significativo quando comparado às abordagens heurísticas.

A última avaliação de QoS apresentada na Figura 37 considera apenas os nodos em uma região de atenção no cenário maior, a fim de demonstrar a redução do atraso na troca de mensagens em nodos localizados em regiões prioritárias. Os resultados destacam que o CALiPSO é capaz de atingir atrasos de cerca de 9,6 segundos, enquanto as outras abordagens tiveram cerca de 10 segundos em todas as execuções de simulação.




Figura 35: Energia consumida no cenário Intel Lab.




Figura 36: Energia consumida no cenário IEEE-test-feeder.

Também é possível comparar os resultados da Figura 37 com os da Figura 32. Enquanto a Figura 32 mostra o atraso médio das mensagens enviadas por todos os nodos da rede, na Figura 37 os valores referem-se apenas às mensagens dos nodos da região de atenção. No CALiPSO, os atrasos das mensagens desses nodos são sempre menores.

5.4.4 Análise de complexidade do CALiPSO

Esta seção analisa a complexidade computacional do CALiPSO e fornece comparações com outras abordagens. CALiPSO é uma abordagem baseada em meta-heurística, que pode ser caracterizada como eficiente e leve. Para conduzir a análise de complexidade, uma abordagem algorítmica gananciosa e uma implementação convencional de PSO também são analisadas para fins comparativos na seção 5.4.4. A análise do algoritmo CALiPSO é apresentada na Seção 5.4.5.




Figura 37: Atraso dos nodos prioritários no cenário IEEE-test-feeder.

Abordagem algorítmica gulosa para alocação de cluster

Para representar uma abordagem gulosa, uma implementação de formação de *cluster-tree* do tipo *bottom-up*, conforme discutido em [64], é apresentada no Algoritmo 4. Nesse processo de formação, inicialmente seleciona-se um nodo pertencente ao nível mais profundo da topologia (com base na profundidade máxima dos nodos, representada por $maxD$ na linha 3). Em seguida, realiza-se uma busca recursiva em cada vizinho alcançável que possua a menor profundidade (representada por $minD$ na linha 10).

Algoritmo 4 Algoritmo guloso

```
1: procedure SEEK-MAXDEPTH-NODE( $node\_list$ )
2:   para each  $n$  in  $node\_list$  faça
3:     se  $n.depth \geq maxD$  então                                 $\triangleright maxD$  is the maximum depth of hotspot nodes
4:       SELECTCH( $n$ )
5: procedure SELECTCH( $n$ )
6:   se  $n.depth == 1$  então
7:     return                                                     $\triangleright$  Reaches BS and completes the path
8:   senão
9:     para each  $m$  in  $n.neighbors$  faça
10:      se  $m.depth \leq minD$  então                                 $\triangleright minD$  is the minimum depth of hotspot nodes
11:        SELECTCH( $m$ )
12: SEEK-MAXDEPTH-NODE( $node\_list$ )
```

Este algoritmo recursivo percorre a lista de nodos vizinhos de cada **CH** selecionado, sendo que a condição de parada ocorre quando o nodo analisado apresenta profundidade igual a 1 (linha 6), o que indica que esse nodo encontrou um caminho que conecta os nodos prioritários à **BS**. Dessa forma, o tempo de execução depende do número de nodos n presentes na região de atenção e varia conforme o número de vizinhos m do nodo selecionado.

Inicialmente, toda a lista de nodos é examinada para identificar aquele com menor profundidade, o que requer um total de $n - 1$ comparações. Em seguida, a cada seleção, ocorre uma nova chamada recursiva, tornando a complexidade do algoritmo proporcional à profundidade máxima da rede. Assim, no pior caso, a complexidade pode ser expressa como $O(n + k \cdot m)$, em que k representa o número de chamadas recursivas, correspondente à profundidade ($depth - 1$).

Abordagem baseada em BPSO para alocação de cluster

Para ilustrar o comportamento de um algoritmo de otimização baseado em meta-heurísticas, um exemplo de **BPSO** é apresentado no Algoritmo 5. Conforme mencionado anteriormente, as etapas de um **PSO** convencional envolvem inicializar as partículas e, em seguida, atualizá-las por meio da alteração de suas posições e velocidades, além do cálculo e atualização dos valores de P_b (melhor posição individual) e de G_b (melhor posição global do enxame). Com isso, as partículas evoluem iterativamente em busca de valores mais adequados para a função de aptidão, que, neste caso, consiste na sua minimização (linhas 7 a 11).

Algoritmo 5 Algoritmo BPSO convencional

```
1: procedure PARTICLE-INITIALIZATION
2:   generate particle with RANDOMISE()
3:   update vector with particle
4: procedure UPDATE-PSO(particle)
5:   old  $\leftarrow$  FITNESS-FUNC(vector[len(vector) - 1])
6:   new  $\leftarrow$  FITNESS-FUNC(particle)
7:   se new  $\leq$  old então
8:     Pb  $\leftarrow$  new
9:   para each p in vector faça
10:    se new  $\leq$  p então
11:      Gb  $\leftarrow$  new
12: procedure PARTICLE-EVOLUTION(particle)
13:   para each i in particle faça
14:     r  $\leftarrow$  RANDOMISE()
15:     s  $\leftarrow$  SIGMOID(i)
16:     se s  $\geq$  r então
17:       particle[i]  $\leftarrow$  1
18:     senão
19:       particle[i]  $\leftarrow$  0
20:     store new particle
21:     UPDATE-PSO(particle)
22: vector  $\leftarrow$  [ ]
23: PARTICLE-INITIALIZATION
24: para each p in vector faça
25:   FITNESS-FUNCT(p)
26: enquanto stop criterion is not reached faça
27:   para each p in vector faça
28:     PARTICLE-EVOLUTION(p)
```

No algoritmo **BPSO**, uma forma frequentemente utilizada de normalizar dados e torná-los discretos é gerar números aleatórios com o valor de cada posição de uma partícula e compará-los com um valor de função de normalização, como o sigmóide (usada nas linhas 14-19). Assim, as partículas evoluem para novas sequências binárias (representadas pelas linhas 20-21) que irão compor as soluções futuras.

É impreciso calcular a complexidade deste tipo de algoritmo devido a inteira dependência da fase de inicialização das partículas, o que pode envolver a iteração entre listas ou o particionamento de *strings*. No entanto, a complexidade de tempo do **PSO** é normalmente determinada pelo custo computacional de avaliação da função de aptidão, que aumenta de acordo com o tamanho do problema. Portanto, a complexidade de tempo de um **PSO** tradicional é determinada por $O(s * d * i)$, onde s é o tamanho do enxame, d é a dimensionalidade do problema e i as iterações. O **BPSO** é semelhante, mas com um custo adicional de conversão de valores de posição contínua em binários usando o sigmóide. A complexidade de tempo da função sigmóide é $O(d)$. Supondo que $s * d$ seja o custo das avaliações da função sigmóide, o tempo total do BPSO seria $O((s * d * i) + (s * d))$.

5.4.5 Algoritmo do CALiPSO

A base do CALiPSO consiste em desenvolver um mecanismo capaz de incorporar a eficiência da abordagem [PSO](#), preferencialmente com um número reduzido de comparações, em consonância com os bons resultados obtidos pelas variantes binária e combinatória do [PSO](#) ([BPSO](#) e [CPSO](#)), de modo a diminuir a complexidade computacional. Além disso, é fundamental lidar adequadamente com o dilema entre exploração e exploração presente nos algoritmos de otimização convencionais, mitigando as limitações típicas das abordagens heurísticas — caracterizadas por uma fase de exploração reduzida — e evitando a convergência prematura para soluções localmente ótimas, problema recorrente em técnicas cuja fase de exploração é restrita. O Algoritmo 6 descreve o método [BPSO](#) especializado empregado pelo CALiPSO.

Algoritmo 6 Algoritmo do CALiPSO

```

1: procedure PARTICLE-INITIALIZATION
2:    $minD \leftarrow 1$ 
3:    $i \leftarrow 0$ 
4:   para each node in depth_list faça    ▷ depth_list contains the hotspot nodes sorted by depth
5:     se node.depth ==  $minD + +$  então
6:       particle[i]  $\leftarrow 1$           ▷ CH
7:     senão
8:       particle[i]  $\leftarrow 0$           ▷ regular node
9:      $i + +$ 
10:  update vector with particle
11: procedure PARTICLE-EVOLUTION(particle)
12:   $x \leftarrow particle[0]$ 
13:   $particle \leftarrow particle[1:] + x$     ▷ particle rotation
14:  store new particle
15:  UPDATE-PSO(particle)
16:  vector  $\leftarrow []$ 
17:  PARTICLE-INITIALIZATION
18:  para each p in vector faça
19:    FITNESS-FUNCT(p)
20: enquanto stop criterion is not reached faça
21:   para each p in vector faça
22:    PARTICLE-EVOLUTION(p)

```

As linhas 1 a 10 do Algoritmo 6 descrevem a inicialização da partícula. Como em qualquer *cluster-tree* deve existir pelo menos um [CH](#) por nível de árvore, a técnica proposta garante que, na partícula inicial, entre os nodos em uma região de atenção, exista um e apenas um [CH](#) para cada nível da árvore. Esta é uma condição necessária, mas não suficiente. No entanto, a fase subsequente de evolução da partícula aplicada a esta partícula inicial retornará soluções viáveis e eficientes.

No mecanismo CALiPSO, diferentes técnicas de inicialização de partículas podem ser utilizadas, evoluindo simultaneamente, e o melhor resultado é escolhido ao final da evolução. Deste modo, conforme apresenta a Seção 5.1, a implementação da simulação CALiPSO utiliza quatro técnicas de inicialização. A primeira técnica de inicialização é exatamente a mostrada no Algoritmo 6. A segunda técnica é semelhante, mas cria

a partícula percorrendo a lista de nodos no sentido inverso, pois essa lista depende do recebimento de dados pelo coordenador PAN durante a inicialização da rede. Por fim, a terceira e a quarta técnicas baseiam-se no número médio de vizinhos dos nodos. Ao inicializar uma rede, o coordenador PAN determina o número médio de nodos vizinhos prioritários e não prioritários para cada nó. Usando esta informação, a terceira técnica atribui um nodo como **CH** se ele tiver mais vizinhos prioritários que a média da rede. A quarta técnica é o oposto e atribui um nodo como **CH** se ele tiver um número maior que a média de vizinhos não prioritários.

A técnica de inicialização de partículas obtém um ganho computacional sem chamadas *randomise()*, promovendo menor complexidade e fácil combinação na busca por partículas viáveis. Além disso, o processo de evolução de partículas também traz benefícios potenciais ao algoritmo. Enquanto no **PSO** tradicional são utilizadas diferentes funções de normalização em conjunto com chamadas de rotina para geração aleatória, o CALiPSO adota a modificação de posições com base na rotação. Os movimentos de rotação têm um custo computacional muito baixo, uma vez que as chamadas *randomise()* e a comparação posição a posição da partícula são eliminadas. Além disso, o critério de parada gerencia a busca por soluções ótimas na fase de evolução (linhas 20-22) com base no tamanho das partículas.

Em nossos experimentos (apresentados na Seção 5.1), o CALiPSO sempre convergiu para uma solução global resultando em uma partícula que define a configuração adequada dos **CHs** prioritários. Dos 1.277 movimentos possíveis de partículas, foram utilizadas 92 iterações. Consequentemente, foi alcançada uma taxa de convergência de aproximadamente 0,07 na busca da solução ótima, contabilizando partículas com tamanhos de 8 e 10, respectivamente. Assim, à medida que o custo de $s * d$ é removido, o CALiPSO tem uma complexidade reduzida que é proporcional ao tamanho da partícula e ao número de iterações. Como o tamanho da partícula nunca é maior que o número de nodos do problema, é possível afirmar que a complexidade do CALiPSO é $O(n * i)$.

Tabela 8: Comparação de complexidade algorítmica.

Algoritmos gananciosos	BPSO	CALiPSO
$O(n + (k * m))$	$O((s * d * i) + (s * d))$	$O(n * i)$
onde n é o número de nodos, k a profundidade da árvore, m o número de vizinhos, s o tamanho do enxame, d a dimensionalidade do problema, i o número de iterações.		

A Tabela 8 resume a análise de complexidade das abordagens. Observe que outra vantagem observada no CALiPSO é a redução do *overhead* para reconfigurar a rede, uma vez que a função objetivo envolve apenas a profundidade de cada nó. Essa simplificação não só se destaca nas abordagens multiobjetivo, mas também evita, por exemplo, a troca de outros dados de controle, como os referentes ao nível de energia atual dos nodos.

5.4.6 Avaliação experimental do CALiPSO

Para avaliar a viabilidade de implementação do CALiPSO e examinar experimentalmente o seu desempenho, foi conduzido um teste de benchmark utilizando uma placa

ESP32⁷. Esse dispositivo é amplamente empregado em aplicações de IoT, em razão de seu baixo custo e reduzido consumo energético. O modelo utilizado neste trabalho é o Node-MCU, equipado com um microcontrolador ESP8266, arquitetura de 32 bits e frequência de operação de 160 MHz.

Para esta avaliação foi realizada uma implementação CALiPSO com quatro partículas e quatro subpartículas. A inicialização da partícula requer a definição de um CH por profundidade desde o início da string, final da *string* e duas profundidades abaixo (conforme mencionado na Seção 4). A implementação foi simples, sem otimização de código e sem fazer uso de recursos *multicore*. Os códigos-fonte podem ser acessados em um repositório git⁸.

FreeRTOS é um sistema popular em tempo real disponível nativamente em placas ESP32 que permite explicitamente aos usuários ativar os dois núcleos do processador do ESP8266 para otimizar seu desempenho. Porém, tal solução não foi explorada, pois a ideia principal era realizar um teste de estresse para verificar se os mecanismos desenvolvidos eram capazes de processar eficientemente cada fase. Cada fase da abordagem foi analisada separadamente. Os resultados estão ilustrados na Figura 38, onde foram utilizadas as seguintes siglas:

- *TINC* – Time to Initialize Complete particles;
- *TINS* – Time to Initialize Sub-particles;
- *TSC* – Time to Sum the the Complete particles depth;
- *TSS* – Time to Sum the Sub-particles depth;
- *TTC* – Time to run feasibility Tests in Complete particles;
- *TTS* – Time to run feasibility Tests in Sub-particles;
- *TEC* – Time to Evolve Complete particles;
- *TSEC* – Time to Sum Evolved Complete particles;
- *TES* – Time to Evolve Sub-particles; and
- *TSES* – Time to Sum Evolved Sub-particles.

Conforme mostrado na Figura 38, o tempo total que o CALiPSO leva para encontrar uma solução adequada e reconfigurar a rede é de cerca de 36,4 ms no Intel Lab e 40,3 ms no cenário IEEE-test-feeder. Assumindo a maior frequência da rede, esses valores são inferiores a três intervalos de beacon, pois o valor *aBaseSuperframeDuration* em uma rede IEEE 802.15.4 é 15,36 ms (considerando uma banda de frequência de 2,4 GHz com uma taxa de dados de 250 kbps). Para ambos os cenários, a fase de cálculo da soma das partículas evoluídas para o CALiPSO foi a mais demorada (os tempos de resposta foram, em média, 12,4 ms na Intel e 14,9 ms no IEEE-feeder); enquanto o menor tempo foi gasto na inicialização das subpartículas (tempos de resposta em torno de 0,3 ms e 0,4 ms). A seção seguinte destaca os resultados obtidos para o mecanismo de escalonamento.

⁷<https://www.espressif.com/en/products/socs/esp8266>

⁸<https://github.com/miguelneto0/CT-Sim-Castalia>




Figura 38: Tempos de execução do CALiPSO nos cenários Intel Lab e IEEE-test-feeder.

5.4.7 Considerações sobre o CALiPSO

Os resultados obtidos por simulação indicam que os benefícios do CALiPSO são perceptíveis tanto em termos de configuração topológica (Seção 5.4.2) quanto na QoS alcançada (Seção 5.4.3) — especialmente considerando que as abordagens BUF, usadas para comparação, já incorporam melhorias em relação a outras heurísticas, conforme descrito em [64].

Contudo, observa-se que os ganhos topológicos obtidos pelo CALiPSO não se refletem integralmente na QoS. De fato, os resultados de QoS podem ser considerados modestos. Isso ocorre porque não basta formar uma *cluster-tree* mais eficiente; é necessário também ajustar o escalonamento da rede IEEE 802.15.4, de modo que os nodos prioritários das regiões de atenção possam se beneficiar da nova topologia. Essa nova abordagem de escalonamento, denominada BRAZA e descrita na Seção 4.5, tem seus resultados apresentados na seção a seguir.

5.5 Resultados do Mecanismo de Reescalonamento Prioritário BRAZA

Para as simulações deste estudo, o BRAZA foi implementado no Castalia com o objetivo de definir o mecanismo de escalonamento e a abordagem multi-BO do coordenador PAN, de modo a atender de forma diferenciada os nodos localizados nas regiões de atenção. A associação de nodos e a formação da rede utilizadas foram fornecidas pelo método de otimização do CALiPSO, descrito anteriormente, e o cenário avaliado corresponde ao IEEE-test-feeder.

Para fins de comparação, foram considerados os principais trabalhos da literatura que propõem esquemas de escalonamento de *beacons* voltados para métricas de QoS ou para a priorização de nodos com características distintas. São eles:

- **SDA+TDCS** [66]: um escalonamento *bottom-up* otimizado que utiliza alocação de duração de *superframe* (SDA) com base em dados de carga de nodos CH, que é usado pelo mecanismo de formação de topologia definido no CALiPSO. Tal mecanismo é combinado com a hierarquia definida em TDCS [88]. Por isso, simplificamos a sigla adequadamente:

- **TPLBS** [86]: um esquema de escalonamento de *beacons* baseado em carga para atribuir *superframes* a nodos em regiões de atenção com base em filas de prioridade e atribuição probabilística de prioridade, semelhante a algoritmos de otimização usando parâmetros de decisão aleatórios; neste caso, são atribuídos às filas correspondentes Q_L e Q_R , os nodos prioritários (vermelho), enquanto os nodos regulares (azul) têm filas reduzidas;
- **NovelSuperf** [48]: uma nova modelagem de *superframe* IEEE 802.15.4 para atender nodos com maior periodicidade. Tais nodos solicitam periodicamente *slots* **GTS** e, para isso, o esquema adiciona dois períodos **CAP** (obrigatório e opcional), que são precedidos por um período **CFP** fixo para atender nodos prioritários no início do *superframe*. A alocação de **GTS** é tratada para nodos em uma região de atenção, onde os nodos prioritários são escalonados no **CFP** antes dos nodos regulares de acordo o método proposto. Aqui, é usado o termo *NovelSuperf* por conveniência, visto que o artigo não define uma sigla para tal;
- **SPRF** [90]: um esquema de escalonamento que busca priorizar nodos com maior periodicidade, sendo essa prioridade definida a partir do *deadline* e da profundidade de cada nodo. O processo de formação topológica e a atribuição de *superframes* apresentam semelhanças com os empregados no CALiPSO, uma vez que também consideram a profundidade e o **SD** de cada **CH** durante a seleção. A etapa específica de atribuição de *slots* de canal por meio de um algoritmo de coloração de grafos não é tratada neste trabalho e, por essa razão, é indicada como SPRF*. Ademais, uma versão de agendamento de *slots* é empregada na simulação inicial para todos os nodos, com o objetivo de avaliar a configuração resultante da sequência produzida pela alocação de *slots*. Essa variante é denominada $SPRF^{slot}$.

Inicialmente, o BRAZA foi comparado com os esquemas descritos, avaliando-se as métricas de **QoS** de atraso fim-a-fim, taxa de perda de pacotes e consumo médio de energia, considerando toda a rede. Em seguida, ele foi comparado com TPLBS, SPRF* e NovelSuperf considerando apenas os nodos prioritários, excluindo-se a variante $SPRF^{slot}$ por apresentar desempenho inferior e por utilizar atribuição de *slots* de canal, o que destoia da maioria das abordagens avaliadas.

A Tabela 9 complementa os parâmetros apresentados na Tabela 7 e descreve os valores específicos considerados nesta etapa da avaliação. Em particular, são detalhadas a periodicidade alta e baixa, bem como os valores de **BO** empregados pelo BRAZA para cada grupo de nodos.

Tabela 9: Parâmetros adicionais do cenário IEEE-test-feeder para avaliação do BRAZA.

Parâmetro	Valor
Beacon Order (BO)	$BO_{PRI}=7$, $BO_{DEF}=9$
Periodicidade dos nodos	0,05 pacotes/segundos (T_{HOT}), 0,01 pacotes/segundos (T_{REG})

5.5.1 Resultados do BRAZA sobre toda a rede

Nesta primeira avaliação, o escalonamento produzido pelo BRAZA apresenta uma configuração que beneficia significativamente todos os nodos da rede. Conforme ilustrado na Figura 39, o BRAZA obtém um ganho de 40% a 72% em relação a abordagens de escalonamento relevantes da literatura, considerando os atrasos de comunicação fim-a-fim. Esse resultado decorre do fato de o BRAZA permitir que o coordenador PAN atenda todos os nodos de alta prioridade dentro do intervalo de *beacon* definido pelo BO prioritário (BO_{PRI}). Em seguida, os nodos regulares remanescentes são atendidos de forma satisfatória no intervalo de *beacon* padrão (BO_{DEF}).




Figura 39: Atrasos fim a fim de todos os nodos da rede.

Dentre as abordagens da literatura, o *SPRF** apresenta melhor desempenho que o *TPLBS*, pois emprega um esquema de otimização estatística para definir a sequência de atividade dos nodos, enquanto o *TPLBS* se baseia apenas em uma heurística de filas de prioridade. O mecanismo *NovelSuperf* também se destaca por priorizar o escalonamento dos nodos de maior importância, assim como o *BRAZA*. No entanto, ao modificar a estrutura do *superframe* — introduzindo um período inativo que divide o CFP e o CAP — essa abordagem acaba prejudicando os demais nodos.

O escalonamento *bottom-up* empregado em *SDA+TDCS* apresenta desempenho superior aos anteriores, pois segue o fluxo natural dos nodos mais profundos até a estação base. Entretanto, como há nodos não prioritários ao longo desse caminho e o escalonamento *bottom-up* não é aplicado separadamente por grupo, essa abordagem também acaba sendo superada pela proposta *BRAZA*. Na abordagem *BRAZA*, todos os nodos prioritários e parte dos nodos não prioritários são atendidos dentro do mesmo intervalo de *beacon* (BO_{PRI}).

Em relação à perda de pacotes, a Figura 40 mostra que as abordagens encontradas na literatura apresentam uma taxa média de perdas entre 11% e 14%, enquanto a abordagem *BRAZA* resulta em aproximadamente 12%. Considerando a variação do intervalo de confiança — por volta de 4% a 5% — os resultados indicam um empate técnico entre as abordagens comparadas, embora a *BRAZA* atinja menores taxas de perdas em algumas rodadas de simulação (limite inferior no intervalo de confiança). As abordagens *TPLBS*

e $SPRF^{slot}$ apresentam a maior variabilidade, devido ao fato de possuírem nodos não prioritários intermediando o caminho dos dados e o escalonamento, diferentemente do que ocorre no mecanismo de reescalonamento proposto.




Figura 40: Taxa média de pacotes de todos os nodos da rede.

Como demonstrado, o BRAZA é eficaz ao lidar com problemas de desempenho em redes com regiões de atenção e priorização de nodos. No entanto, como ilustra a Figura 41, esse desempenho aprimorado apresenta um custo no consumo médio de energia — aproximadamente 32% maior em comparação com as demais. Esse aumento se deve à estratégia multi-BO implementada, em que o coordenador PAN desperta antes do Beacon Order padrão (BO_{DEF}) para atender os nodos prioritários durante BO_{PRI} . Como resultado, esses nodos despertam com mais frequência, resultando em maior consumo de energia.




Figura 41: Energia consumida de todos os nodos da rede.

Este resultado destaca que, como em muitos sistemas de controle e monitoramento, deve se considerar um trade-off para atingir o desempenho ideal em aplicações sensíveis a temporização, consumo de energia e capacidades de processamento do dispositivo. Nesse contexto, o consumo adicional de energia pela abordagem BRAZA para atingir alto nível de desempenho não é considerado significativo — especialmente quando comparado aos ganhos de desempenho obtidos. Além disso, como o mecanismo não introduz complexidade significativa (por exemplo, não modifica o padrão 802.15.4 nem exige maior

processamento computacional para escalar a rede), a proposta se mostra uma solução viável.

5.5.2 Resultados do BRAZA sobre as regiões de atenção

Para ilustrar o impacto nos nodos de regiões de atenção, as Figuras 42 e 43 detalham os valores de atraso para cada nodo avaliado ao final de uma das rodadas de simulação. Aqui, os valores de $SPRF^{slot}$ e $TPLBS$ não foram ilustrados por serem piores que os demais. Assim, comparando os dados apresentados na Figura 42, é possível observar uma maior concentração de nodos prioritários na parte inferior do gráfico tridimensional, o que reflete os menores valores de $NovelSuperf$ em relação a $SPRF^*$, embora ambas apresentem certa quantidade de nodos com atrasos na faixa entre 40 e 60s.






Figura 42: Atraso (em segundos) dos nodos no SPRF* e NovelSuperf.

Agora, quando avaliamos as abordagens de escalonamento SDA+TDCS e BRAZA, é possível notar uma redução significativa em todos os nodos afetados por atrasos, em comparação às anteriores. Como visto, os valores de atraso se concentram abaixo de 40s, com o BRAZA obtendo melhores resultados. Isso é ilustrado abaixo com a comparação considerando apenas os nodos prioritários. Embora a visualização na Figura 43 não seja muito precisa para os nodos em regiões de atenção, no SDA+TDCS o atraso máximo fica em torno de 10s, enquanto no BRAZA tais nodos têm um atraso máximo de 3,5s (detalhado na Tabela 10). Nessa comparação, também é possível identificar o impacto que o BRAZA causa nos nodos não prioritários, de modo que na comparação com a abordagem SDA+TDCS, todos os nodos apresentam atrasos abaixo de 30 segundos durante todo o tempo de monitoramento, enquanto sem esse escalonamento, o resultado apresenta vários nodos na faixa de 30 a 40s.

Além disso, a taxa de perda de pacotes foi avaliada para ambas as abordagens para avaliar o impacto em nodos prioritários e não prioritários. Conforme mostrado na Figura 44, os nodos não prioritários (nodos azuis) localizados mais ao centro do ambiente apresentam as maiores taxas de perda na abordagem BRAZA, variando entre 30% e 40%.



a. Atrasos para nodos do CALiPSO.



b. Atrasos para nodos do BRAZA.


Figura 43: Atraso (em segundos) dos nodos no CALiPSO e no BRAZA.

Em contraste, os nodos prioritários (vermelhos) apresentam uma taxa máxima de perda de cerca de 10%, com exceção de um único nodo (o CH 13), que atinge aproximadamente 25%. Para a abordagem SDA+TDCS, o cluster-head 13 — juntamente com os CH 7 e CH 2 — sofre com maior perda de pacotes, com valores variando de 30% a 45%. Além disso, os CH de hotspot mais centralizados e mais próximos do coordenador PAN (por exemplo, CH 53 e CH 57) apresentam desempenho pior em comparação ao BRAZA, conforme ilustrado no lado esquerdo da Figura 44-a.

Tabela 10: Resultados de atrasos e perdas de pacote para nodos em *hotspots* e demais nodos.

Abordagem	Nodos em <i>hotspots</i>				Nodos regulares				Rede inteira			
	Atraso		Perda		Atraso		Perda		Atraso		Perda	
	avg	stddev	avg	stddev	avg	stddev	avg	stddev	avg	stddev	avg	stddev
SPRF	28,08 s	4,86 s	7,52 %	3,92 %	43,59 s	8,04 s	12,62 %	2,13 %	40,63 s	7,15 s	11,68 %	1,63 %
NovelSuperf	10,57 s	2,57 s	9,87 %	4,65 %	29,63 s	5,67 s	11,60 %	1,99 %	25,92 s	5,08 s	11,08 %	1,54 %
SDA+TDCS	9,14 s	0,09 s	8,07 %	3,92 %	22,59 s	2,56 s	13,29 %	2,50 %	19,98 s	2,06 s	12,34 %	1,85 %
BRAZA	2,96 s	0,67 s	8,23 %	2,36 %	13,96 s	1,05 s	13,49 %	5,68 %	11,82 s	0,82 s	12,53 %	4,59 %

A avaliação precisa de cada nodo no gráfico tridimensional fornece uma melhor interpretação dos resultados obtidos em relação ao consumo de energia, perda de pacotes e atrasos. De acordo com a Figura 45, os nodos prioritários na abordagem BRAZA apresentam um consumo de energia maior do que na proposta SDA+TDCS e, consequentemente, das demais abordagens da literatura que, em média, se aproximaram mais de SDA+TDCS. Isso se deve ao fato de que, no modelo multi-BO implementado, os nodos em regiões de atenção despertam com mais frequência e acabam adicionando mais tempo de atividade. No entanto, esse aumento é observado em nodos em regiões de atenção de diferentes profundidades (como os nós 13, 62, 105, 38), pelo desgaste de repetidas operações *on-off*, embora isso permita que eles esvaziem suas filas e entreguem um número maior de mensagens no intervalo de *beacon* atual.



a. Perda de pacotes para os nodos do CALiPSO. b. Perda de pacotes para os nodos do BRAZA.

Figura 44: Perdas de pacotes (em percentuais) de nodos no CALiPSO e no BRAZA.


Neste caso, o consumo médio de energia da abordagem de formação PSO otimizada com a estratégia tradicional bottom-up é menor do que o da abordagem que utiliza um multi-BO para atender nodos prioritários. No entanto, é importante considerar até que ponto tal mecanismo pode ser aplicado para atingir o desempenho, a fim de compensar uma perda de até 32% de energia para nodos de regiões de atenção (aproximadamente 15% da rede), enquanto os nodos regulares mantêm aproximadamente o mesmo consumo de energia. Para nodos de regiões de atenção em SDA+TDCS, o consumo de energia é de aproximadamente 400 J, em comparação com uma média de 600 J para CHs de regiões de atenção em BRAZA. Mais detalhes são apresentados na Tabela 11.

O acúmulo gerado pelo BRAZA também se reflete em alguns nodos do primeiro grupo não prioritário (B1), onde alguns deles estão escalonados no mesmo *beacon* dos nodos prioritários (BO_{PRI}), conforme mostrado na Figura 45-b. Embora um aumento seja perceptível nesses nodos, isso não impacta negativamente o desempenho (atraso e perda de pacotes), pois atende cada porção (MACY de B1, B2 e B3) dentro do mesmo intervalo de beacon padrão (BO_{DEF}) que também era atendido antes da reconfiguração proposta pelo mecanismo BRAZA.


Tabela 11: Energia consumida pelo SDA+TDCS e pelo BRAZA.

Proposta	Hotspot		Nodos regulares		Rede inteira	
	avg	stddev	avg	stddev	avg	stddev
SPRF	270,94 J	8,10 J	219,81 J	2,50 J	227,59 J	2,58 J
NovelSuperf	268,59 J	10,95 J	220,14 J	2,30 J	227,39 J	2,86 J
SDA+TDCS	270,74 J	8,13 J	219,18 J	3,21 J	227,05 J	3,25 J
BRAZA	601,78 J	51,76 J	224,84 J	25,26 J	304,16 J	27,68 J

Por fim, os dados obtidos para a avaliação considerando apenas os nodos em regiões de atenção, demonstram que, em relação aos atrasos de comunicação, o BRAZA entrega mensagens em menos tempo, com ganhos variando de 67% a 89% em relação as demais




a. Energia para dos nodos em SDA+TDCS.




b. Energia dos nodos em BRAZA.

Figura 45: Energia consumida (em Joules) pelo SDA+TDCS e pelo BRAZA.



a. Atrasos para hotspot.



b. Perda de pacotes para hotspot.

Figura 46: Atrasos e perdas de pacotes no BRAZA e em outras abordagens da literatura.

abordagens. Considerando a perda de pacotes, observa-se que o mecanismo proposto mantém uma taxa de perda semelhante às demais abordagens (Figura 46b, detalhada na Tabela 10), e a energia é aumentada para 15% dos nodos da rede (dados detalhados na Tabela 11).

6 Conclusão

Este capítulo destaca as conclusões do trabalho de doutoramento. Primeiro, a visão geral apresentada na Seção 6.1, enquanto as respostas para as perguntas levantadas no capítulo introdutório são respondidas na Seção 6.2. A Seção 6.3 apresenta as contribuições resultantes do trabalho de pesquisa, e a Seção 6.4 descreve os trabalhos futuros.

6.1 Visão Geral do Trabalho

As [RSSF](#) baseadas no padrão IEEE 802.15.4 têm se consolidado como uma tecnologia fundamental para aplicações de monitoramento e controle em larga escala, oferecendo topologias robustas e eficientes em termos energéticos e de desempenho. Ambientes de [IoT](#) que utilizam essa tecnologia como solução de última milha dependem de mecanismos resilientes de reconfiguração da rede, sobretudo em cenários dinâmicos e compostos por dispositivos instalados em áreas críticas de monitoramento. Neste contexto, este trabalho investigou estratégias para lidar com tais desafios e propôs uma arquitetura computacional capaz de enfrentá-los de forma eficaz, flexível e modularizada.

A partir dos dados coletados pelos sensores, a rede passa por uma reconfiguração estrutural conduzida pelos mecanismos da arquitetura, que determinam uma formação topológica adequada e um escalonamento capaz de priorizar nodos situados em áreas de maior atenção (*hotspots*). Os resultados demonstram que a proposta permite formar redes mais homogêneas e estabelecer políticas de escalonamento que favorecem dispositivos localizados em regiões mais críticas da topologia, alcançando ganhos significativos de desempenho, especialmente na redução de atrasos e no aumento das taxas de entrega.

O desenvolvimento de mecanismos adaptativos voltados à reconfiguração de [RSSF](#) orientadas a dados constitui um desafio central para garantir desempenho eficiente em aplicações sensíveis a eventos, como monitoramento ambiental, industrial e urbano. Motivado por essa necessidade, este trabalho propôs uma arquitetura capaz de ajustar dinamicamente a estrutura de [RSSF](#) sujeitas à ocorrência de regiões de atenção, explorando dados coletados pela própria rede para orientar decisões de configuração.

Um aspecto fundamental evidenciado ao longo do desenvolvimento desta pesquisa foi a necessidade de uma arquitetura integrada que contemplasse tanto a formação topológica quanto o mecanismo de escalonamento da rede. Embora o foco inicial estivesse concentrado no desenvolvimento do mecanismo de formação da *cluster-tree* — denominado CALiPSO — tornou-se claro, à medida que avançavam as análises da [QoS](#) obtida, que a eficácia global da rede dependia também de um módulo capaz de reescalonar os *beacons* de forma coerente com a nova configuração topológica. Essa constatação motivou a concepção e posterior integração do módulo BRAZA, resultando em uma arquitetura mais robusta, unificada, orientada a dados e adequada a cenários com regiões de atenção.

Todos os mecanismos propostos nesta pesquisa foram avaliados por meio de simulações extensivas utilizando o *framework* Castalia e o conjunto CT-Sim, ambos executados na plataforma OMNeT++. Essa abordagem permitiu analisar o comportamento das soluções em cenários realistas de monitoramento. Adicionalmente, o CALiPSO foi validado experimentalmente em placas de desenvolvimento [COTS](#) e teve sua complexidade computacional analisada de forma rigorosa.

Quanto à organização deste documento, no Capítulo 2 foram apresentados os fundamentos teóricos que embasaram este estudo, abrangendo as particularidades das RSSF, os protocolos adequados para cenários de larga escala e as principais abordagens de otimização e IA aplicáveis. O Capítulo 3 revisou os trabalhos mais relevantes da literatura, destacando seus méritos, limitações e relação com os objetivos desta pesquisa. O Capítulo 4 descreveu em detalhe a arquitetura desenvolvida, aprofundando-se nos módulos responsáveis pelo processo de reconfiguração topológica e pelo mecanismo de reescalonamento. Por fim, o Capítulo 5 apresentou e discutiu os resultados experimentais, comparando-os com abordagens da literatura e evidenciando os ganhos decorrentes das soluções propostas.

6.2 Revisão das Motivações do Trabalho

Tendo em vista os desafios associados à implementação de RSSF em ambientes de larga escala — especialmente no que se refere à presença de regiões críticas e às particularidades operacionais do padrão IEEE 802.15.4 — este trabalho buscou, inicialmente, atender a quatro requisitos delineados no Capítulo 1:

- R-1 **Quanto à garantia da cobertura e conectividade da rede:** esse requisito foi atendido pelos módulos 2 e 4 da arquitetura. Os mecanismos de associação dos nodos e os algoritmos de descoberta de vizinhança, complementados pelos de formação topológica do CALiPSO, buscam atuar de forma eficaz ao garantir ampla cobertura da rede e evitar a ocorrência de nodos órfãos;
- R-2 **Quanto à seleção adequada de *clusters* e *cluster-heads*:** esse requisito foi atendido pelos módulos 3 e 4 da arquitetura. Os nodos prioritários em regiões de atenção são devidamente classificados e servem de entrada para o algoritmo de formação topológica do CALiPSO que busca reduzir a quantidade de *clusters* formados. Complementarmente, a formação topológica gerada promove estruturas mais homogêneas, conectando ramos apenas com nodos prioritários diretamente à BS, favorecendo o posterior escalonamento do tráfego da rede;
- R-3 **Quanto à conformidade com o padrão IEEE 802.15.4:** esse critério foi atendido em toda a arquitetura. Primeiramente, adotou-se mecanismos de associação compatíveis com o formato de pacotes definido pela norma, sem modificar as variáveis de acesso ao meio — alteração comum em parte dos trabalhos correlatos. Contudo, o aspecto mais relevante é que o BRAZA estabelece valores de BO múltiplos do utilizado pelo coordenador PAN, permitindo definir escalonamentos da comunicação na rede que priorizam nodos em regiões de atenção sem violar a estrutura do *superframe*, preservando assim a conformidade com a norma;
- R-4 **Quanto à baixa complexidade algorítmica:** os mecanismos centrais da arquitetura — CALiPSO e BRAZA — foram concebidos para operar com baixo custo computacional, compatível com dispositivos de recursos restritos. No caso do CALiPSO, embora a formação ótima de estruturas *cluster-tree* seja um problema NP-difícil, sua

formulação heurística apresenta complexidade reduzida, comprovada por uma análise de complexidade do algoritmo e pela implementação em *hardware* COTS de baixa capacidade (ESP32), que demonstrou sua viabilidade em cenários dinâmicos nos quais a rede deve ser reconfigurada durante a operação.

Considerando os objetivos específicos citados no capítulo introdutório, as seguintes análises podem ser feitas a partir dos resultados obtidos pela arquitetura proposta, além da análise do impacto da eficiência energética dos mecanismos de reconfiguração propostos para a vida útil de toda a rede:

- **Quanto à definição dos melhores mecanismos de agrupamento de dados:** diversas técnicas consolidadas na literatura foram avaliadas, considerando-se seu impacto sobre os indicadores de QoS da rede, especialmente a taxa de entrega de pacotes e o consumo energético. Contudo, como os resultados obtidos entre as técnicas analisadas apresentaram diferenças pouco expressivas, optou-se pela adoção do método mais simples e de menor custo computacional, o *K-means*.
- **Quanto à formação de topologias com um número adequado de *clusters*, com dimensionamento apropriado de nodos por cluster e com a seleção dos nodos mais adequados para atuarem como CHs:** No CALiPSO, a seleção de CHs, *clusters* e ramificações segue uma abordagem *bottom-up*, em que os CHs são definidos com base na menor profundidade da árvore por meio de uma otimização BPSO de baixa complexidade. A função de aptidão desta otimização prioriza a redução do número de saltos até a estação base, limitando a explosão combinatória do espaço de busca. O histórico das partículas orienta as decisões rumo à melhor configuração e fornece a próxima solução ótima, contribuindo para a confiabilidade do processo. As avaliações comparativas e qualitativas demonstraram a efetividade dessa abordagem em relação às propostas da literatura.
- **Quanto à formação de topologias orientadas a dados e que priorizem os nodos nas regiões de atenção:** A organização topológica primeiro prioriza os nodos situados nas regiões de atenção, estendendo a formação aos demais nodos apenas após essa etapa inicial. As análises de desempenho evidenciaram ganhos para os nodos prioritários em termos de parâmetros de QoS.
- **Quanto à proposição de um escalonamento da rede em conformidade com o IEEE 802.15.4 e capaz de priorizar o tráfego dos nodos nas regiões de atenção:** Assim como na seleção de CHs, o escalonamento do BRAZA adota uma abordagem *bottom-up*, privilegiando o tráfego convergecast em direção à BS. Diferentemente de abordagens da literatura que utilizam GTS ou propõem alterações na estrutura de *superframe* do IEEE 802.15.4, esta proposta mantém total conformidade com a norma. Nela, os nodos prioritários são alocados primeiro nos BIs, no escalonamento dos SDs, e os demais são posicionados em seguida. Os resultados demonstraram a efetividade dessa estratégia, reduzindo os atrasos e as perdas de pacotes das regiões de atenção.

- **Quanto à integração dos mecanismos de detecção de regiões de atenção, formação topológica e escalonamento em uma arquitetura orientada a dados, adaptativa e capaz de responder dinamicamente às condições da rede:** A arquitetura proposta integra de forma consistente esses mecanismos, permitindo que os módulos de reconstrução topológica e de reescalonamento sejam acionados sempre que mudanças ambientais o justifiquem. Ademais, houve cuidado na adoção de técnicas leves e de baixa complexidade computacional, assegurando que a reconfiguração da rede possa ocorrer de maneira dinâmica e compatível com dispositivos de recursos restritos.
- **Quanto à modelagem dos mecanismos propostos em um simulador:** Foram utilizadas as ferramentas Castalia, baseada na plataforma OMNeT++, juntamente com o CT-Sim, um conjunto de módulos integrados ao Castalia para a construção eficiente de redes *cluster-tree*. Para as avaliações, dois cenários principais foram considerados: um ambiente *indoor*, o Intel Lab Data, composto por medições reais de uma [RSSF](#) instalada no laboratório da Intel Berkeley Research; e um ambiente *outdoor* de larga escala, o IEEE-test-feeder, que fornece configurações de redes de distribuição de energia elétrica. Através dos resultados obtidos pela simulação foi possível se analisar o desempenho dos mecanismos propostos por este trabalho.
- **Sobre a influência da estruturação dos nós sensores no desempenho e vida útil?** Quanto à vida útil, a implementação do algoritmo de reconfiguração demonstrou que é possível alcançar melhorias na qualidade de serviço sem exceder o consumo dos dispositivos. Na média obtida pela abordagem de otimização proposta, o valor gasto pelas baterias está próximo ao obtido por abordagens heurísticas, que possuem menor eficiência em desempenho. Portanto, o mecanismo de otimização para construção da estrutura chamado de CALiPSO se mostra uma abordagem eficiente para reconfiguração dinâmica, sem afetar o consumo energético. Em relação ao mecanismos de escalonamento prioritário (BRAZA), este consumo se apresenta mais elevado, porém, para tal caso deve ser considerado um trade-off, visto que se trata de uma abordagem que catalisa a entrega de mensagens de nós em regiões de hotspot, superando as taxas obtidas pela aplicação pura da formação topológica descrita pelo CALiPSO.

Como um todo, os resultados obtidos ao longo da pesquisa demonstraram que os objetivos propostos foram alcançados. A arquitetura mostrou-se eficaz na redução de atrasos e perdas de pacotes, especialmente nas regiões de atenção, mesmo em cenários de alta demanda. Um dos principais diferenciais observados foi a capacidade do sistema de reagir dinamicamente a mudanças no ambiente de rede, por meio de um mecanismo de otimização de baixa complexidade e em conformidade com o padrão IEEE 802.15.4.

A proposta apresentou ganhos consistentes na organização topológica da rede, resultando em clusters mais equilibrados e alinhados às exigências de cada cenário simulado. Essa característica contribuiu diretamente para uma comunicação mais estável e eficiente, especialmente em aplicações nas quais eventos críticos demandam aumento de periodi-

cidade em determinadas regiões, que se tornam prioritárias e passam a exigir menores atrasos e maior confiabilidade na entrega das mensagens provenientes desses pontos.

6.3 Contribuições e Escopos da Pesquisa

Dado o contexto no qual este trabalho se insere, as propostas desenvolvidas ao longo da pesquisa resultaram em contribuições relevantes para a comunidade dedicada ao estudo de [RSSF](#) e [IoT](#), escalonamento de nodos em redes IEEE 802.15.4 e priorização de regiões de monitoramento. As principais contribuições podem ser sintetizadas da seguinte forma:

- Uma arquitetura de reconfiguração topológica que prioriza nodos em regiões de atenção e otimiza o desempenho de [RSSF](#) para monitoramento em larga escala;
- Uma arquitetura flexível, composta por módulos intercambiáveis, permitindo a substituição dos mecanismos de formação e de escalonamento por alternativas compatíveis;
- Uma abordagem de formação de rede, orientada a dados e baseada em otimização [BPSO](#), caracterizada por baixa complexidade computacional e adequada a dispositivos com recursos restritos;
- Um mecanismo de escalonamento compatível com o padrão IEEE 802.15.4, capaz de priorizar fluxos provenientes de nodos situados em regiões de maior criticidade;
- Um mecanismo de descoberta de vizinhança que viabiliza a formação da rede sem depender de valores de RSSI — abordagem recorrente na literatura;
- Um mecanismo que permite identificar regiões de maior atenção e que agrupa os nodos de forma homogênea.

Tais contribuições se refletiram em publicações realizadas ao longo da pesquisa, nomeadamente:

1. Publicação derivada das técnicas de reconfiguração direcional da rede na fase inicial da pesquisa: *Dynamic Reconfiguration of Cluster-Tree Wireless Sensor Networks to Handle Communication Overloads in Disaster-Related Situations.*, Sensors MDPI, 2020 [[63](#)].
2. Publicação derivada das técnicas de reconfiguração direcional da rede integrada às técnicas de alocação de *superframe* encontradas na literatura: *Data-driven Bottom-up Cluster-tree Formation based on the IEEE 802.15.4/ZigBee Protocols.* 47th IECON, 2021 [[64](#)].
3. Publicação derivada das técnicas de clusterização de dados estudadas ao longo do trabalho envolvendo os estudos de abordagens *data-driven*: *Impact Analysis of Data Clustering Techniques for Data-Based Topological Formation in WSNs.* 20th INDIN, 2022 [[65](#)].

4. Publicação derivada das técnicas de formação topológica estudadas com as abordagens implementadas com IA e algoritmos de otimização bioinspirados: *A lightweight BPSO mechanism for topology reconfiguration in data-driven IIoT plants*. Elsevier Internet of Things Journal, 2024 [66].

A implementação para os mecanismos descritos neste trabalho estão disponíveis no repositório do autor nos seguintes links: [implementação inicial](#) – integração do CT-Sim à formação de rede direcionada e CALiPSO, e [integração final](#) – implementando o mecanismo de reconfiguração de *beacon* prioritário.

6.4 Trabalhos Futuros

Como continuidade deste trabalho, destaca-se a possibilidade de explorar novas abordagens de otimização baseadas em aprendizado de máquina ou algoritmos evolutivos, que poderiam ser incorporados ao mecanismo de reconfiguração para tornar as decisões ainda mais eficientes em cenários dinâmicos e imprevisíveis. Tais abordagens poderiam ser analisadas quanto ao custo em processamento e energia usada, visando obter soluções que melhoram as métricas atingidas nesta pesquisa.

Além disso, almeja-se aprimorar os mecanismos de formação topológica no que tange aos problemas de desconexão de nodos cluster-head, distribuindo a responsabilidade de tomada de decisão para se recuperar-se de falhas. Isto também impede que a configuração da rede retorne aos módulos iniciais da arquitetura para realizar a reconfiguração, tornando a atuação dos nodos mais pontual e eficiente.

Também se vislumbra a expansão dos experimentos, pretendendo-se utilizar placas microcontroladas acopladas com rádios IEEE 802.15.4 em um ambiente amplo, para implementar os algoritmos simulados. Além disso, como mencionado, outra linha de investigação futura é aprofundar nas abordagens de clusterização de dados mais eficientes explorando novos algoritmos de agregação, fusão e filtragem de dados em tempo real, para abordar a detecção robusto de *outliers* e detectar regiões de atenção.

Referências

- [1] *Aalsalem Mohammed Y.* An effective hotspot mitigation system for Wireless Sensor Networks using hybridized prairie dog with Genetic Algorithm // PLOS ONE. 04 2024. 19, 4. 1–25. [19](#)
- [2] *Ahmad Aasem, Hanzálek Zdeněk.* An Energy Efficient Schedule for IEEE 802.15.4/ZigBee Cluster Tree WSN with Multiple Collision Domains and Period Crossing Constraint // IEEE Transactions on Industrial Informatics. 2018. 14, 1. 12–23. [67](#), [70](#)
- [3] *Ahmed Abbirah, Qazi Sameer.* Cluster head selection algorithm for mobile wireless sensor networks // 2013 International Conference on Open Source Systems and Technologies. 2013. 120–125. [50](#)
- [4] *Akyildiz Ian, WY Su, Sankarasubramaniam Y., Cayirci E.* Wireless Sensor Networks: A Survey // Computer Networks. 03 2002. 38. 393–422. [28](#)
- [5] *Alduais Nayef, Audah Lukman, Jamil A., Abdullah Jiwa.* Study the effect of number of nodes in large-scale Wireless Sensor Networks with design GUI support tools // Journal of Engineering and Applied Sciences. 11 2016. 11. 13259–13264. [20](#)
- [6] *Alhayali Shaymaa, Rahebi Javad, Ucan Osman, Bayat Oguz.* Increasing Energy Efficiency in Wireless Sensor Networks Using GA-ANFIS to Choose a Cluster Head and Assess Routing and Weighted Trusts to Demodulate Attacker Nodes // Foundations of Science. 12 2019. 25. [57](#), [61](#)
- [7] *Ali Haider, Tariq Umair Ullah, Hussain Mubashir, Lu Liu, Panneerselvam John, Zhai Xiaojun.* ARSH-FATI: A Novel Metaheuristic for Cluster Head Selection in Wireless Sensor Networks // IEEE Systems Journal. 2021. 15. 2386–2397. [64](#), [66](#)
- [8] *Ancillotti Emilio, Vallati Carlo, Bruno Raffaele, Mingozzi Enzo.* A Reinforcement Learning-based Link Quality Estimation Strategy for RPL and its Impact on Topology Management // Computer Communications. 08 2017. 112. [60](#), [61](#)
- [9] *Andrade A.T.C., Siedersberger D., Montez C., Moraes R., Leão E., Vasques F.* Data-Based Cluster-Tree Formation Scheme for Large-Scale Wireless Sensor Networks // 2018 IEEE 16th International Conference on Industrial Informatics (INDIN). 2018. 175–180. [53](#), [55](#), [102](#)
- [10] *Assis Laura Silva de, González José Federico Vizcaíno, Usberti Fábio Luiz, Lyra Christiano, Cavellucci Celso, Von Zuben Fernando J.* Switch Allocation Problems in Power Distribution Systems // IEEE Transactions on Power Systems. 2015. 30, 1. 246–253. [47](#)
- [11] *Bandara H. M. N., Jayasumana Anura P., Illangasekare Tissa H.* Cluster Tree Based Self Organization of Virtual Sensor Networks // 2008 IEEE Globecom Workshops. 2008. 1–6. [52](#), [55](#)

- [12] *Bandara H. M.N.Dilum, Jayasumana Anura P.* An enhanced top-down cluster and cluster tree formation algorithm for wireless sensor networks // ICIIS 2007 - 2nd Int. Conf. on Industrial and Information Systems 2007. 2007. 565–570. [52](#)
- [13] *Baradaran Amir Abbas, Navi Keivan.* HQCA-WSN: High-quality clustering algorithm and optimal cluster head selection using fuzzy logic in wireless sensor networks // Fuzzy Sets and Systems. 2020. 389. 114–144. Clustering. [56](#), [61](#)
- [14] *Borges Luís M., Velez Fernando J., Lebres António S.* Survey on the Characterization and Classification of Wireless Sensor Network Applications // IEEE Communications Surveys Tutorials. 2014. 16, 4. 1860–1890. [27](#)
- [15] *Carlos-Mancilla Miriam, López-Mellado Ernesto, Siller Mario.* Wireless sensor networks formation: Approaches and techniques // Journal of Sensors. 2016. 2016. [27](#), [52](#)
- [16] *Carlos-Mancilla Miriam, Olascuaga-Cabrera J. Guadalupe, López-Mellado Ernesto, Mendez-Vazquez Andres.* Design and implementation of a robust wireless sensor network // CONIELECOMP 2013, 23rd Int. Conf. on Electronics, Communications and Computing. 2013. 230–235. [52](#), [55](#)
- [17] *Chang Kuor-Hsin, Mason Bob.* The IEEE 802.15.4g standard for smart metering utility networks // 2012 IEEE Third International Conference on Smart Grid Communications (SmartGridComm). 2012. 476–480. [37](#)
- [18] *Chang Tengfei, Watteyne Thomas, Wang Qin, Vilajosana Xavier.* LLSF: Low Latency Scheduling Function for 6TiSCH Networks // 2016 International Conference on Distributed Computing in Sensor Systems (DCOSS). 2016. 93–95. [68](#), [70](#)
- [19] *Chhajed Suman, Sabir Mohammad, Singh Kiran P.* Wireless Sensor Network implementation using MiWi wireless protocol stack // 2014 IEEE International Advance Computing Conference (IACC). 2014. 239–244. [34](#)
- [20] *Choudhury Nikumani, Matam Rakesh, Mukherjee Mithun, Lloret Jaime.* LBS: A Beacon Synchronization Scheme With Higher Schedulability for IEEE 802.15.4 Cluster-Tree-Based IoT Applications // IEEE Internet of Things Journal. 2019. 6, 5. 8883–8896. [69](#)
- [21] *Choudhury Nikumani, Matam Rakesh, Mukherjee Mithun, Lloret Jaime.* A Beacon and GTS Scheduling Scheme for IEEE 802.15.4 DSME Networks // IEEE Internet of Things Journal. 2022. 9, 7. 5162–5172. [69](#), [70](#)
- [22] *Collotta Mario, Scatà Gianfranco, Pau Giovanni.* A Priority-Based CSMA/CA Mechanism to Support Deadline-Aware Scheduling in Home Automation Applications Using IEEE 802.15.4 // International Journal of Distributed Sensor Networks. 2013. 9, 5. 139804. [67](#), [70](#)

- [23] *Cuomo Francesca, Cipollone Emanuele, Abbagnale Anna.* Performance analysis of IEEE 802.15.4 wireless sensor networks: An insight into the topology formation process // *Computer Networks*. 2009. 53, 18. 3057–3075. [27](#)
- [24] *Deepa S, Marimuthu CN, Dhanvanthri V.* Enhanced Q-LEACH routing protocol for wireless sensor networks // *ARN J. Eng. Appl. Sci.* 2015. 10, 9. 4036–4041. [50](#), [51](#), [55](#)
- [25] *El-Shenhabi Alaa N., Abdelhay Ehab H., Mohamed Mohamed A., Moawad Ibrahim F.* A Reinforcement Learning-Based Dynamic Clustering of Sleep Scheduling Algorithm (RLDCSSA-CDG) for Compressive Data Gathering in Wireless Sensor Networks // *Technologies*. 2025. 13, 1. [64](#)
- [26] *Electrical Institute of, Engineers Electronics.* IEEE Standard for Telecommunications and Information Exchange Between Systems - LAN/MAN Specific Requirements - Part 15: Wireless Medium Access Control (MAC) and Physical Layer (PHY) Specifications for Low Rate Wireless Personal Area Networks (WPAN) // *IEEE Std 802.15.4-2003*. 2003. IEEE Std 802.15.4-2003. 1–680. [37](#)
- [27] *Electrical Institute of, (IEEE) Electronics Engineers.* IEEE Standard for Local and metropolitan area networks–Part 15.4: Low-Rate Wireless Personal Area Networks (LR-WPANs) // *IEEE Std 802.15.4-2011 (Revision of IEEE Std 802.15.4-2006)*. 2011. 1–314. [34](#), [37](#)
- [28] *Electrical Institute of, (IEEE) Electronics Engineers.* IEEE Standard for Local and metropolitan area networks–Part 15.4: Low-Rate Wireless Personal Area Networks (LR-WPANs) Amendment 1: MAC sublayer // *IEEE Std 802.15.4e-2012 (Amendment to IEEE Std 802.15.4-2011)*. 2012. 1–225. [36](#), [37](#)
- [29] *Electrical Institute of, (IEEE) Electronics Engineers.* IEEE Standard for Low-Rate Wireless Networks // *IEEE Std 802.15.4-2015 (Revision of IEEE Std 802.15.4-2011)*. 2016. 1–709. [37](#)
- [30] *Electrical Institute of, (IEEE) Electronics Engineers.* IEEE Standard for Low-Rate Wireless Networks // *IEEE Std 802.15.4-2020 (Revision of IEEE Std 802.15.4-2015)*. 2020. 1–800. [37](#)
- [31] *Elhabyan Riham S., Shi Wei, St-Hilaire Marc.* Coverage Protocols for Wireless Sensor Networks: Review and Future Directions // *CoRR*. 2019. abs/1901.00511. [27](#)
- [32] *Farahzadi Hamid, Langarizadeh Mostafa, Mirhosseini Mohammad, Aghda Seyed.* An improved cluster formation process in wireless sensor network to decrease energy consumption // *Wireless Networks*. 02 2021. 27. 1–11. [51](#)
- [33] *Förster Anna, Murphy Amy L.* Froms: A failure tolerant and mobility enabled multicast routing paradigm with reinforcement learning for WSNs // *Ad Hoc Networks*. 2011. 9, 5. 940–965. [59](#), [61](#)

- [34] *Hanzalek Zdeněk, Jurcik Petr.* Energy efficient scheduling for cluster-tree wireless sensor networks with time-bounded data flows: Application to IEEE 802.15.4/ZigBee // IEEE transactions on industrial informatics. 2010. 6, 3. 438–450. [32](#)
- [35] *Harun Al Rasyid M. Udin, Lee Bih-Hwang, Syarif Iwan, Arkham Mokhammad Muqoffi.* LEACH Partition Topology for Wireless Sensor Network // 2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW). 2018. 1–5. [51](#), [55](#)
- [36] *Hassan M. N., Murphy Liam, Stewart Robert.* Traffic differentiation and dynamic duty cycle adaptation in IEEE 802.15.4 beacon enabled WSN for real-time applications // Telecommunication Systems. 2016. [67](#), [70](#)
- [37] *Heidari Ehsan.* A novel energy-aware method for clustering and routing in IoT based on whale optimization algorithm & Harris Hawks optimization // Computing. 02 2024. 106. 1–33. [65](#), [67](#)
- [38] *Heinzelman W.R., Chandrakasan A., Balakrishnan H.* Energy-efficient communication protocol for wireless microsensor networks // Proceedings of the 33rd Annual Hawaii International Conference on System Sciences. 2000. 10 pp. vol.2–. [50](#)
- [39] *Huang Xianming.* Multi-node topology location model of smart city based on Internet of Things // Computer Communications. 2020. 152. 282–295. [19](#)
- [40] *IEEE Standards Association .* IEEE Std 802.15.4-2020: IEEE Standard for Low-Rate Wireless Networks. jul 2020. 1-886. [20](#)
- [41] *Institute of Electrical and Electronics Engineers .* IEEE Standard for Information technology– Local and metropolitan area networks– Specific requirements– Part 15.4: Wireless Medium Access Control (MAC) and Physical Layer (PHY) Specifications for Low Rate Wireless Personal Area Networks (WPANs) // IEEE Std 802.15.4-2006 (Revision of IEEE Std 802.15.4-2003). 2006. IEEE Std 802.15.4-2003. 1–320. [37](#)
- [42] *Institute of Electrical and Electronics Engineers (IEEE) .* IEEE Standard for Information technology– Local and metropolitan area networks– Specific requirements– Part 15.4: Wireless Medium Access Control (MAC) and Physical Layer (PHY) Specifications for Low-Rate Wireless Personal Area Networks (WPANs): Amendment 1: Add Alternate PHYs // IEEE Std 802.15.4a-2007 (Amendment to IEEE Std 802.15.4-2006). 2007. 1–210. [37](#)
- [43] *Jain Bindiya, Brar Gursewak, Malhotra Jyoteesh.* EKMT-k-Means Clustering Algorithmic Solution for Low Energy Consumption for Wireless Sensor Networks Based on Minimum Mean Distance from Base Station // Networking Communication and Data Knowledge Engineering. Singapore: Springer Singapore, 2018. 113–123. [57](#), [61](#)

- [44] *Jin Yichao, Kulkarni Parag, Wilcox James, Sooriyabandara Mahesh.* A centralized scheduling algorithm for IEEE 802.15.4e TSCH based industrial low power wireless networks // 2016 IEEE Wireless Communications and Networking Conference. 2016. 1–6. [68](#), [70](#)
- [45] *Karthikeyan V., Vinod A., Jeyakumar P.* An Energy Efficient Neighbour Node Discovery Method for Wireless Sensor Networks // ArXiv. 02 2014. [51](#)
- [46] *Karunanithy Kalaivanan, Bhanumathi V.* Cluster-Tree based Energy Efficient Data Gathering Protocol for Industrial Automation using WSNs and IoT // Journal of Industrial Information Integration. 06 2020. 19. 100156. [55](#)
- [47] *Kaushik A., Goswami M., Manuja M., Indu S., Gupta Daya.* A Binary PSO Approach for Improving the Performance of Wireless Sensor Networks // Wireless Pers Commun. 2020. 113. 263–297. [63](#), [64](#), [66](#)
- [48] *Khan Sangrez, Alvi Ahmad Naseem, Khan Mohammad Zubair, Javed Muhammad Awais, Alhazmi Omar H, Bouk Safdar Hussain.* A novel superframe structure and optimal time slot allocation algorithm for IEEE 802.15.4-based Internet of things // International Journal of Distributed Sensor Networks. 2020. 16, 12. 1550147720984645. [69](#), [70](#), [114](#)
- [49] *Kohvakka Mikko, Kuorilehto Mauri, Hännikäinen Marko, Hämäläinen Timo D.* Performance Analysis of IEEE 802.15.4 and ZigBee for Large-Scale Wireless Sensor Network Applications // Proceedings of the 3rd ACM International Workshop on Performance Evaluation of Wireless Ad Hoc, Sensor and Ubiquitous Networks. New York, NY, USA: Association for Computing Machinery, 2006. 48–57. (PE-WASUN '06). [79](#)
- [50] *Koubaa Anis, Cunha Andre, Alves Mario.* A Time Division Beacon Scheduling Mechanism for IEEE 802.15.4/Zigbee Cluster-Tree Wireless Sensor Networks // 19th Euromicro Conference on Real-Time Systems (ECRTS'07). 2007. 125–135. [32](#), [53](#), [54](#)
- [51] *Koubaa Anis, Cunha André, Alves Mário, Tovar Eduardo.* TDBS: A time division beacon scheduling mechanism for ZigBee cluster-tree wireless sensor networks // Real-Time Systems. 12 2008. 40. 321–354. [36](#), [53](#), [54](#)
- [52] *Kumar Ajay, Bawa Seema.* A comparative review of meta-heuristic approaches to optimize the SLA violation costs for dynamic execution of cloud services // Soft Computing. 03 2020. 24. [12](#), [44](#)
- [53] *Laurindo Suelen, Moraes Ricardo, Montez Carlos, Vasques Francisco.* Assessment of Different Algorithms to Solve the Set-Covering Problem in a Relay Selection Technique // 2020 25th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA). 2020. 206–213. [62](#)

- [54] *Lee YangMin*. Classification of node degree based on deep learning and routing method applied for virtual route assignment // *Ad Hoc Networks*. 2017. 58. 70–85. Hybrid Wireless Ad Hoc Networks. [59](#), [61](#)
- [55] *Leão Erico, Montez Carlos, Moraes Ricardo, Portugal Paulo, Vasques Francisco*. Superframe Duration Allocation Schemes to Improve the Throughput of Cluster-Tree Wireless Sensor Networks // *Sensors*. 2017. 17, 2. [54](#), [78](#)
- [56] *Leão Erico, Montez Carlos, Moraes Ricardo, Portugal Paulo, Vasques Francisco*. Superframe Duration Allocation Schemes to Improve the Throughput of Cluster-Tree Wireless Sensor Networks // *Sensors*. Jan 2017. 17, 2. 249. [68](#), [80](#)
- [57] *Leão Erico, Vasconcelos Vitor, Portugal Paulo, Montez Carlos, Moraes Ricardo*. A Hybrid Beacon Scheduling Scheme to Allow the Periodic Reconfiguration of Large-scale Cluster-tree WSNs // 2018 IEEE 16th International Conference on Industrial Informatics (INDIN). 2018. 169–174. [54](#)
- [58] *Leão Erico, Vasconcelos Vitor, Portugal Paulo, Montez Carlos, Moraes Ricardo*. A Hybrid Beacon Scheduling Scheme to Allow the Periodic Reconfiguration of Large-scale Cluster-tree WSNs // 2018 IEEE 16th International Conference on Industrial Informatics (INDIN). 2018. 169–174. [68](#)
- [59] *Li Changle, Zhang Hanxiao, Hao Binbin, Li Jiandong*. A Survey on Routing Protocols for Large-Scale Wireless Sensor Networks // *Sensors (Basel, Switzerland)*. 12 2011. 11. 3498–526. [29](#)
- [60] *Li Hui, Liu Jing*. Double Cluster Based Energy Efficient Routing Protocol for Wireless Sensor Network // *International Journal of Wireless Information Networks*. 03 2016. 23. [50](#), [51](#), [55](#)
- [61] *Li Mo, Li Zhenjiang, Vasilakos Athanasios V*. A Survey on Topology Control in Wireless Sensor Networks: Taxonomy, Comparative Study, and Open Issues // *Proceedings of the IEEE*. 2013. 101, 12. 2538–2557. [27](#)
- [62] *Li Yujiang, Cao Jinghua*. WSN Node Optimal Deployment Algorithm Based on Adaptive Binary Particle Swarm Optimization // *ASP Transactions on Internet of Things*. May 2021. 1, 1. 1–8. [64](#), [66](#), [101](#), [103](#)
- [63] *Lino Miguel, Leão Erico, Soares André, Montez Carlos, Vasques Francisco, Moraes Ricardo*. Dynamic Reconfiguration of Cluster-Tree Wireless Sensor Networks to Handle Communication Overloads in Disaster-Related Situations // *Sensors*. 2020. 20, 17. [19](#), [54](#), [79](#), [126](#)
- [64] *Lino Miguel, Montez Carlos, Leão Erico, Cavalca Andrade Aujor Tadeu*. Data-driven Bottom-up Cluster-tree Formation based on the IEEE 802.15.4/ZigBee Protocols // 47th IECON. 2021. 1–6. [82](#), [99](#), [100](#), [102](#), [108](#), [113](#), [126](#)

- [65] *Lino Miguel, Montez Carlos, Leão Erico, Lira Ricardo*. Impact Analysis of Data Clustering Techniques for Data-Based Topological Formation in WSNs // 2022 IEEE 20th International Conference on Industrial Informatics (INDIN). 2022. 636–641. [95](#), [126](#)
- [66] *Lino Miguel, Montez Carlos, Leão Erico, Rabelo Ricardo, Fayran Angelus, Vasques Francisco*. A lightweight BPSO mechanism for topology reconfiguration in data-driven IIoT plants // Internet of Things. 2024. 26. 101208. [113](#), [127](#)
- [67] *Liu Xuxun*. Atypical hierarchical routing protocols for wireless sensor networks: A review // IEEE Sensors Journal. 2015. 15, 10. 5372–5383. [29](#)
- [68] *Maddali M V M Kumar, Ch Aparna*. A hybrid BFO-FOA-based energy efficient cluster head selection in energy harvesting wireless sensor network // International Journal of Communication Networks and Distributed Systems. 05 2020. 25. 205. [63](#), [64](#), [66](#)
- [69] *Malek Sami A., Avanzi Francesco, Brun-Laguna Keoma, Maurer Tessa, Oroza Carlos A., Hartsough Peter C., Watteyne Thomas, Glaser Steven D*. Real-Time Alpine Measurement System Using Wireless Sensor Networks // Sensors. 2017. 17, 11. [29](#)
- [70] *Martalo Marco, Perri Simone, Verdano Gianmichele, Mola Francesco, Monica Francesco, Ferrari Gianluigi*. Improved UWB TDoA-based Positioning using a Single Hotspot for Industrial IoT Applications // IEEE Transactions on Industrial Informatics. 09 2021. PP. 1–1. [19](#)
- [71] *Mehmood Amjad, Lv Zhihan, Lloret Jaime, Umar Muhammad Muneer*. ELDC: An Artificial Neural Network Based Energy-Efficient and Robust Routing Scheme for Pollution Monitoring in WSNs // IEEE Transactions on Emerging Topics in Computing. 2020. 8, 1. 106–114. [59](#), [61](#)
- [72] *Mehta Deepak, Saxena Sharad*. MCH-EOR: Multi-objective Cluster Head Based Energy-aware Optimized Routing algorithm in Wireless Sensor Networks // Sustainable Computing: Informatics and Systems. 2020. 28. 100406. [63](#), [66](#)
- [73] *Mitchell Tom M*. Machine Learning. New York: McGraw-Hill, 1997. [39](#)
- [74] *Mohamed Reem E., Saleh Ahmed I., Abdelrazzak Maher, Samra Ahmed S*. Survey on Wireless Sensor Network Applications and Energy Efficient Routing Protocols // Wireless Personal Communications. 2018. [26](#)
- [75] *Nandan Aridaman Singh, Singh Samayveer, Kumar Rajeev, Kumar Neeraj*. An Optimized Genetic Algorithm for Cluster Head Election Based on Movable Sinks and Adjustable Sensing Ranges in IoT-Based HWSNs // IEEE Internet of Things Journal. 2022. 9, 7. 5027–5039. [65](#), [66](#)

- [76] *Patti Gaetano, Bello Lucia Lo.* A Priority-Aware Multichannel Adaptive Framework for the IEEE 802.15.4e-LLDN // IEEE Transactions on Industrial Electronics. 2016. 63. 6360–6370. [67](#), [70](#)
- [77] *Peng Song, Xiong Yonghua.* An Area Coverage and Energy Consumption Optimization Approach Based on Improved Adaptive Particle Swarm Optimization for Directional Sensor Networks // Sensors. 2019. 19, 5. [63](#), [66](#)
- [78] *Pinto A. R., Montez C., Araújo G., Vasques F., Portugal P.* An Approach to Implement Data Fusion Techniques in Wireless Sensor Networks Using Generic Machine Learning Algorithms // Information Fusion. 2014. 15. 90–101. [57](#), [61](#)
- [79] *Potthuri Sweta, Shankar T., Rajesh A.* Lifetime Improvement in Wireless Sensor Networks using Hybrid Differential Evolution and Simulated Annealing (DESA) // Ain Shams Engineering Journal. 2018. 9, 4. 655–663. [57](#), [61](#)
- [80] *Praveen Kumar D., Amgoth Tarachand, Annavarapu Chandra Sekhara Rao.* Machine learning algorithms for wireless sensor networks: A survey // Information Fusion. 2019. 49. 1–25. [43](#)
- [81] *Rao P. C.Srinivasa, Jana Prasanta K., Banka Haider.* A particle swarm optimization based energy efficient cluster head selection algorithm for wireless sensor networks // Wireless Networks. 10 2017. 23. 2005–2020. [62](#), [64](#), [66](#)
- [82] *Razaque Abdul, Abdulgader Musbah, Joshi Chaitrali, Amsaad Fathi, Chauhan Mrunal.* P-LEACH: Energy efficient routing protocol for Wireless Sensor Networks // 2016 IEEE Long Island Systems, Applications and Technology Conference (LI-SAT). 2016. 1–5. [51](#), [55](#)
- [83] *Renold A. Pravin, Chandrakala S.* MRL-SCSO: Multi-Agent Reinforcement Learning-Based Self-Configuration and Self-Optimization Protocol for Unattended Wireless Sensor Networks // Wirel. Pers. Commun. oct 2017. 96, 4. 5061–5079. [60](#), [61](#)
- [84] *Russell Stuart, Norvig Peter.* Artificial Intelligence: A Modern Approach. 2010. 3. [38](#)
- [85] *Saidi Ahmed, Benahmed Khelifa, Seddiki Nouredine.* Secure cluster head election algorithm and misbehavior detection approach based on trust management technique for clustered wireless sensor networks // Ad Hoc Networks. 2020. 106. 102215. [64](#), [66](#)
- [86] *Samal Tusharkanta, Kabat Manas Ranjan.* A prioritized traffic scheduling with load balancing in wireless body area networks // Journal of King Saud University - Computer and Information Sciences. 2022. 34, 8, Part A. 5448–5455. [69](#), [70](#), [114](#)
- [87] *Santos Ribeiro Nildo dos, Vieira Marcos A.M., Vieira Luiz F.M., Gnawali Omprakash.* SplitPath: High throughput using multipath routing in dual-radio Wireless Sensor Networks // Computer Networks. 2022. 207. 108832. [19](#)

- [88] *Severino Ricardo, Pereira Nuno, Tovar Eduardo.* Dynamic cluster scheduling for cluster-tree WSNs // SpringerPlus. 08 2014. 3. 493. [54](#), [67](#), [80](#), [113](#)
- [89] *Shankar T., Shanmugavel S., Rajesh A.* Hybrid HSA and PSO algorithm for energy efficient cluster head selection in wireless sensor networks // Swarm and Evolutionary Computation. 2016. 30. [62](#)
- [90] *Shi Ke, Zhang Lin, Qi Zhiying, Tong Kang, Chen Hongsheng.* Transmission Scheduling of Periodic Real-Time Traffic in IEEE 802.15.4e TSCH-Based Industrial Mesh Networks // Wireless Communications and Mobile Computing. 2019. [68](#), [70](#), [114](#)
- [91] *Siedersberger D., Montez Carlos, Leão Erico, Vasques F.* Hierarchical Topology Formation in Large-Scale IEEE 802.15.4 Wireless Sensor Networks // IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society. 1. 2019. 2837–2842. [53](#), [55](#)
- [92] *Signoretti Gabriel, Silva Marianne, Andrade Pedro, Silva Ivanovitch, Sisinni Emiliano, Ferrari Paolo.* An Evolving TinyML Compression Algorithm for IoT Environments Based on Data Eccentricity // Sensors. 2021. 21, 12. [41](#)
- [93] *Singh Buddha, Lobiyal D. K.* Traffic-Aware Density-Based Sleep Scheduling and Energy Modeling for Two Dimensional Gaussian Distributed Wireless Sensor Network // Wireless Personal Communications. 2013. [19](#)
- [94] *Sinha Ditipriya, Kumari Rina, Tripathi Sudhakar.* Semisupervised Classification Based Clustering Approach in WSN for Forest Fire Detection // Wireless Personal Communications. 12 2019. 109. [58](#), [61](#)
- [95] *Somula Ramasubbareddy, Cho Yongyun, Mohanta Bhabendu Kumar.* SWARAM: Osprey Optimization Algorithm-Based Energy-Efficient Cluster Head Selection for Wireless Sensor Network-Based Internet of Things // Sensors. 2024. 24, 2. [65](#), [66](#)
- [96] *Sundararaj Vinu, Muthukumar S., Kumar R. S.* An optimal cluster formation based energy efficient dynamic scheduling hybrid MAC protocol for heavy traffic load in wireless sensor networks // Comput. Secur. 2018. 77. 277–288. [54](#), [55](#)
- [97] *Thubert Pascal, Hui Jonathan.* Compression Format for IPv6 Datagrams over IEEE 802.15.4-Based Networks. IX 2011. [34](#)
- [98] *Valêncio Carlos Roberto, Medeiros Camila Alves, Neves Leandro Alves, Zafalon Geraldo Francisco Donegá, Gratão De Souza Rogéria Cristiane, Colombini Angelo Cesar.* CHSMST+: An Algorithm for Spatial Clustering // 2016 17th International Conference on Parallel and Distributed Computing, Applications and Technologies (PDCAT). 2016. 352–357. [53](#), [55](#)
- [99] *Verma Sandeep, Sood Neetu, Sharma Ajay Kumar.* Genetic Algorithm-based Optimized Cluster Head selection for single and multiple data sinks in Heterogeneous Wireless Sensor Network // Applied Soft Computing. 2019. 85. 105788. [66](#)

- [100] *Wazid Mohammad, Das Ashok Kumar*. An Efficient Hybrid Anomaly Detection Scheme Using K-Means Clustering for Wireless Sensor Networks // Wireless Personal Communications. 10 2016. 90. [58](#), [61](#)
- [101] *Wei Qian, Bai Ke, Zhou Lin*. An Improved Approach for Wireless Sensor Networks With Mobile Sink Using Dynamic Minimum Spanning Tree // IEEE sensors journal. 2022. 22, 11. 10918–10930. [65](#), [66](#)
- [102] *WirelessHART* . HART Field Communication Protocol Specification, Revision 7.8 // HART Communication Foundation. 2022. [34](#)
- [103] *Zand Pouria, Mathews Emi, Das Kallol, Dilo Arta, Havinga Paul*. ISA100.11a: The ISA100.11a extension for supporting energy-harvested I/O devices // Proceeding of IEEE International Symposium on a World of Wireless, Mobile and Multimedia Networks 2014. 2014. 1–8. [34](#)
- [104] *Zhang Ziran, Glaser Steven, Watteyne Thomas, Malek Sami*. Long-term Monitoring of the Sierra Nevada Snowpack Using Wireless Sensor Networks // IEEE Internet of Things Journal. 12 2016. PP. [29](#)
- [105] *ZigBee* . ZigBee Specification. IX 2012. [34](#)