

OTIMIZAÇÃO MULTIOBJETIVO DA TOPOLOGIA DE REDES DE SENSORES
SEM FIO HETEROGÊNEAS

Lucas Ferreira Pinheiro

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Ciência da Computação, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (Cefet/RJ), como parte dos requisitos necessários à obtenção do grau de mestre.

Orientadores:
Felipe da Rocha Henriques
Laura Silva de Assis

Rio de Janeiro,
Novembro de 2024

Otimização Multiobjetivo da Topologia de Redes de Sensores Sem Fio Heterogêneas

Dissertação de Mestrado em Ciência da Computação, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, Cefet/RJ.

Lucas Ferreira Pinheiro

Aprovada por:

FELIPE DA ROCHA HENRIQUES:08668257706  Assinado de forma digital por FELIPE DA ROCHA HENRIQUES:08668257706
Dados: 2024.11.11 10:58:08 -03'00'

Presidente, Felipe da Rocha Henriques, D.Sc. (orientador)

LAURA SILVA DE ASSIS:06571252619  Assinado de forma digital por LAURA SILVA DE ASSIS:06571252619
Dados: 2024.11.11 11:19:25 -03'00'

Laura Silva de Assis, D.Sc. (coorientadora)

 Documento assinado digitalmente
PEDRO HENRIQUE GONZALEZ SILVA
Data: 12/11/2024 09:44:58-0300
Verifique em <https://validar.iti.gov.br>

Pedro Henrique González Silva, D.Sc.

 Documento assinado digitalmente
FABIO LUIZ USBERTI
Data: 11/11/2024 11:22:38-0300
Verifique em <https://validar.iti.gov.br>

Fábio Luiz Usberti, D.Sc.

Rio de Janeiro,
Novembro de 2024

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

P654 Pinheiro, Lucas Ferreira
Otimização multiobjetivo da topologia de redes de sensores
sem fio heterogêneas / Lucas Ferreira Pinheiro. — 2024.
73f. : il. color. , enc.

Dissertação (Mestrado) Centro Federal de Educação
Tecnológica Celso Suckow da Fonseca, 2024.

Bibliografia : f. 68-73

Orientador: Felipe da Rocha Henriques

Coorientadora: Laura Silva de Assis

1. Sensoriamento remoto. 2. Otimização combinatória.
3. Programação linear. 4. Sistemas de comunicação sem fio. I.
Henriques, Felipe da Rocha (Orient.). II. Assis, Laura Silva de
(Coorient.). III. Título.

CDD 621.384196

Elaborada pela bibliotecária Tania Mello – CRB/7 nº 5507/04

DEDICATÓRIA

À minha família.

“Entrega o teu caminho ao Senhor,
confia nele, e o mais ele fará.”

(Salmos 37:5, ARA)

AGRADECIMENTOS

Agradeço primeiramente a Deus por me permitir a oportunidade de cursar o mestrado em uma instituição de tanto prestígio quanto o Cefet/RJ.

Agradeço pelo apoio fundamental de minha amada esposa Taiane, meu porto seguro, que sempre acreditou em meu potencial de alcançar degraus mais altos.

Agradeço a meus pais, Otoniel e Simone, meu irmão Leonardo, minha avó Nocy, e a todos os meus familiares mais próximos que me deram apoio durante minha trajetória acadêmica.

Agradeço aos meus orientadores Felipe Henriques e Laura Assis por guiar com maestria este aluno na busca do crescimento enquanto pesquisador. Não menos importante, agradeço ao professor Diego Brandão por todo apoio e por me introduzir de forma brilhante ao mundo da pesquisa científica.

Devo agradecer ainda ao meu amigo Roberto Pontes pelo apoio e companheirismo na vida e durante todo o trajeto acadêmico no Cefet/RJ, e aos demais professores e colegas do PPCIC por todo auxílio concedido.

Por fim, agradeço à FAPERJ, pelo fomento à esta pesquisa (Ref.:210.286/2019 - APQ1 2019).

RESUMO

Otimização Multiobjetivo da Topologia de Redes de Sensores Sem Fio Heterogêneas

Lucas Ferreira Pinheiro

Orientadores:

Felipe da Rocha Henriques

Laura Silva de Assis

Resumo da Dissertação submetida ao Programa de Pós-graduação em Ciência da Computação do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (Cefet/RJ) como parte dos requisitos necessários à obtenção do grau de mestre.

Redes de Sensores Sem Fio (RSSF) possuem grande potencial para aplicações nas mais diversas áreas, tais como indústria, segurança, saúde pública e agricultura. Em geral, o desempenho ótimo de uma RSSF depende do dimensionamento correto de parâmetros fundamentais, tais como área de cobertura, conectividade e consumo de energia. Neste trabalho, é proposto um modelo de Programação Linear Inteira (PLI) multiobjetivo para resolver o Problema de Alocação de Sensores (PAS), considerando uma RSSF heterogênea com posições candidatas à alocação de nós sensores predefinidas em uma região de interesse. O objetivo do modelo proposto é minimizar o consumo energético, ao passo que busca-se maximizar a cobertura da rede na região de monitoramento. A validação do modelo foi realizada através de 225 experimentos computacionais com instâncias de pequena e média escala, utilizando linguagem Python e o *solver* Gurobi®. Apesar da alta complexidade combinatória inerente ao PAS, o modelo proposto apresenta resultados factíveis e se mostra útil para auxiliar projetos de aplicações reais de RSSF. Os resultados obtidos servem como referência e podem ser utilizados para fins comparativos em desdobramentos deste estudo.

Palavras-chave:

Alocação de Nós Sensores, Otimização Combinatória, Programação Linear Inteira, Redes de Sensores Sem Fio.

Rio de Janeiro,

Novembro de 2024

ABSTRACT

Multi-objective Topology Optimization of Heterogeneous Wireless Sensor Networks

Lucas Ferreira Pinheiro

Advisors:

Felipe da Rocha Henriques

Laura Silva de Assis

Abstract of dissertation submitted to Postgraduate Program in Computer Science of Federal Center for Technological Education of Rio de Janeiro Celso Suckow da Fonseca (Cefet/RJ) as partial fulfillment of the requirements for the degree of master.

Wireless Sensor Networks (WSNs) have great potential for applications in a wide range of areas, such as industry, security, public health and agriculture. In general, the optimal performance of a WSN depends on the correct dimensioning of fundamental parameters, such as coverage area, connectivity and energy consumption. In this work, a multi-objective Integer Linear Programming (ILP) model is proposed to solve the Sensor Allocation Problem (SAP), considering a heterogeneous WSN with predefined candidate positions for the allocation of sensor nodes in a region of interest. The objective of the proposed model is to minimize energy consumption, whilst seeking to maximize network coverage in the monitoring region. The model was validated through 225 computational experiments with small and medium-scale instances, using Python language and the Gurobi[®] solver. Despite the high combinatorial complexity inherent to the SAP, the proposed model presents feasible results and shows to be useful for assisting real WSN application projects. The obtained results serve as reference and can be used for comparative purposes in developments of this study.

Key-words:

Sensor Node Allocation, Combinatorial Optimization, Integer Linear Programming, Wireless Sensor Networks.

Rio de Janeiro,

Novembro de 2024

Sumário

I	Introdução	8
I.1	Objetivos	9
I.2	Motivação	10
I.3	Justificativa	11
I.4	Metodologia	11
I.5	Organização do Trabalho	12
II	Referencial Teórico	13
II.1	Redes de Sensores Sem Fio (RSSF)	13
II.1.1	Nós sensores	14
II.1.2	Gestão de Energia	14
II.1.3	Arquitetura de Comunicação em RSSF	15
II.1.4	Topologias de RSSF	17
II.1.5	Categorização de Nós Sensores e Heterogeneidade	22
II.1.6	Principais Desafios da Área	23
II.2	Otimização	23
II.2.1	Programação Matemática	24
II.2.2	Métodos de Solução	25
II.2.3	Otimização Multiobjetivo	26
II.3	Conceitos de Teoria de Grafos	28
II.4	Contextualização da Pesquisa	30
III	Trabalhos Relacionados	31
III.1	Metodologia de Busca	31
III.2	Resultados da Busca	32
III.3	Análise comparativa	35
IV	Metodologia de Solução para o Problema de Alocação de Sensores	37
IV.1	Descrição do Problema de Alocação de Sensores	37
IV.2	Formulação Matemática	38

IV.2.1	Modelo de Programação Não Linear Inteira (PNLI)	39
IV.2.2	Modelo de Programação Linear Inteira (PLI) Multiobjetivo	46
IV.3	Geração das Instâncias e Validação do Modelo	47
V	Resultados e Discussões	51
V.1	Ilustrações de Rede e Solução	52
V.2	Experimentos Computacionais	56
VI	Conclusão	72
	Referências	75

Lista de Figuras

II.1	Pilha de protocolos de comunicação em RSSF, adaptado de Akyildiz et al. [2002].	16
II.2	Exemplo de topologia Barramento em RSSF, adaptado de Sharma et al. [2013].	20
II.3	Exemplo de topologia Estrela em RSSF, adaptado de Sharma et al. [2013].	20
II.4	Exemplo de topologia Árvore em RSSF, adaptado de Sharma et al. [2013].	20
II.5	Exemplo de topologia Anel em RSSF, adaptado de Sharma et al. [2013].	21
II.6	Exemplo de topologia Malha em RSSF, adaptado de Sharma et al. [2013].	21
II.7	Exemplo de topologia Circular em RSSF, adaptado de Sharma et al. [2013].	21
II.8	Exemplo de topologia Grade em RSSF, adaptado de Sharma et al. [2013].	22
II.9	Exemplo de fronteira de Pareto para duas Função Objetivo (FO) de maximização onde: (i) soluções não dominadas; (ii) soluções dominadas.	27
II.10	Ilustrações de diferentes tipos de grafos.	29
IV.1	Exemplo de instância de tamanho 10×10 e $D = 10\%$.	48
V.1	Exemplo de instância e solução do PAS com tamanho 10×10 , $D = 10\%$ e $\epsilon = 90$.	53
V.2	Exemplo de solução do PAS para dimensões 10×10 , $D = 10\%$ e variados valores de ϵ .	54
V.2	Exemplo de solução do PAS para instância de dimensões 10×10 , $D = 10\%$ e variados valores de ϵ .	55
V.3	Melhores resultados para instância de dimensões 10×10 e $D = 50\%$, para variados valores de ϵ .	59
V.3	Melhores resultados para instância de dimensões 10×10 e $D = 50\%$, para variados valores de ϵ .	60
V.4	Melhores resultados para instância de dimensões 15×15 e $D = 50\%$, para variados valores de ϵ .	61
V.4	Melhores resultados para instância de dimensões 15×15 e $D = 50\%$, para variados valores de ϵ .	62
V.5	Melhores resultados para instância de dimensões 20×20 e $D = 30\%$, para variados valores de ϵ .	63
V.5	Melhores resultados para instância de dimensões 20×20 e $D = 30\%$, para variados valores de ϵ .	64

V.6	Varição da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 10×10 e $D = 50\%$.	65
V.7	Varição da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 15×15 e $D = 50\%$.	66
V.8	Varição da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 20×20 e $D = 30\%$.	66
V.9	Quantidade de variáveis e restrições do modelo para instâncias de tamanho 10×10 .	68
V.10	Quantidade de variáveis e restrições do modelo para instâncias de tamanho 15×15 .	68
V.11	Quantidade de variáveis e restrições do modelo para instâncias de tamanho 20×20 .	69
V.12	Quantidade de variáveis e restrições para todas as instâncias.	69
V.13	Tempos de execução para cada ϵ da instância de tamanho 10×10 e $D = 50\%$.	70
V.14	Tempos de execução para cada ϵ da instância de tamanho 15×15 e $D = 50\%$.	70
V.15	Tempos de execução para cada ϵ da instância de tamanho 20×20 e $D = 30\%$.	71

Lista de Tabelas

II.1	Comparativo de diferentes topologias de RSSF, adaptado de Sharma et al. [2013].	17
III.1	Características dos principais trabalhos relacionados.	32
III.2	Análise comparativa entre esta pesquisa e seus principais trabalhos relacionados.	35
IV.1	Dados do problema, obtidos dos <i>datasheets</i> de transceptores comerciais [Digi International Inc., 2022].	38
IV.2	Valores das constantes usados nos experimentos.	45
V.1	Valores de ϵ para cada instância do PAS.	52
V.2	Parâmetros de configuração para os cenários de validação do modelo proposto.	56
V.3	Resultados numéricos para instância de tamanho 10×10 e densidade $D = 50\%$.	57
V.4	Resultados numéricos para instância de tamanho 15×15 e densidade $D = 50\%$.	57
V.5	Resultados numéricos para instância de tamanho 20×20 e densidade $D = 30\%$.	58

Lista de Abreviações

<i>D_C</i>	<i>Duty Cycle</i>	15, 45, 65
AG	Algoritmo Genético	31
CF	Colônia De Formigas	31
EB	Estação Base	8, 14
FO	Função Objetivo	24, 25, 26, 27, 28, 34, 38, 39, 40, 42, 43, 45, 46, 49, 73
IDC	Internet Das Coisas	8, 11, 37
PAS	Problema De Alocação De Sensores	9, 10, 11, 30, 31, 32, 34, 35, 36, 37, 38, 39, 40, 43, 47, 51, 52, 53, 54, 55, 67, 72, 73
PL	Programação Linear	24, 25, 26
PLI	Programação Linear Inteira	9, 11, 24, 25, 26, 30, 33, 34, 56, 67, 72
PLIM	Programação Linear Inteira Mista	24, 25, 28, 32, 33, 34
PNL	Programação Não Linear	24
PNLI	Programação Não Linear Inteira	24, 25, 40
PO	Pesquisa Operacional	23, 24
QOS	Qualidade De Serviço	14, 23
RSCSF	Rede De Sensores Corporais Sem Fio	13
RSSF	Redes De Sensores Sem Fio	8, 9, 10, 11, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 30, 31, 32, 33, 34, 35, 36, 37, 39, 43, 47, 54, 56, 65, 67, 72, 73, 74

Capítulo I Introdução

Nas últimas décadas, as áreas de pesquisa de Redes de Sensores Sem Fio (RSSF) e Internet das Coisas (IdC) têm se mostrado muito ativas devido ao vasto potencial de aplicações em múltiplas áreas desde monitoramento ambiental e de infraestrutura, até segurança e localização [Akyildiz et al., 2002]. RSSF consistem em uma distribuição de diversos nós sensores autônomos sobre uma região de interesse, usualmente com o objetivo de monitoramento de parâmetros dessa região [Akyildiz e Stuntebeck, 2006]. Cada nó sensor é um dispositivo eletrônico inteligente que possui capacidade limitada de processamento, memória e reserva de energia, o que representam restrições para seu tempo de vida total e consequentemente para a quantidade de dados que podem ser coletados em um determinado período. No entanto, por serem capazes de se intercomunicar através de transceptores, os nós sensores podem encaminhar os dados coletados ao longo da rede até uma Estação Base (EB), onde serão armazenados, processados e disponibilizados para análise [Osamy et al., 2021].

Existem diversos modelos de transceptores em RSSF que podem operar a diferentes potências e configurações de faixa de transmissão, cada qual com um respectivo consumo de energia, o que possibilita múltiplas configurações de topologia de rede para um mesmo cenário de monitoramento. Usualmente é preferível implementar topologias que garantam alta redundância na rede tal como uma rede em malha (*Mesh*) [Jafarian e Jaseemuddin, 2008] onde, caso qualquer dispositivo venha a falhar, os transceptores consigam encontrar automaticamente outras rotas viáveis para que os dados alcancem a EB.

Por conta dessa flexibilidade de projeto, as RSSF mostram-se bastante úteis, principalmente em ambientes onde a intervenção humana direta para realizar aferições seria impossível ou inviável, além de possibilitar escalar e automatizar a cobertura do monitoramento. Portanto, há um crescente potencial para aplicações nas mais diversas áreas tais como indústria [Majid et al., 2022], segurança [Xie et al., 2018], saúde pública [Saini et al., 2020], agricultura [Thakur et al., 2019] e até mesmo no militarismo [Ismail et al., 2018].

As RSSF podem ser classificadas como heterogêneas ou homogêneas. As RSSF homogêneas possuem em sua composição nós sensores com configurações idênticas de *hardware* e *software*. Por sua vez, as RSSF heterogêneas possibilitam mais de uma variação (ou tipo) de nó sensor presente na topologia [Wu e Chung, 2007]. Nessa categoria de rede pode haver diferenciação de funcionalidade, custo, capacidade de processamento e memória, consumo energético, alcance de transmissão ou

sensoriamento entre cada nó sensor. Projetos de RSSF heterogêneas possibilitam contornar de forma inteligente algumas restrições do ambiente monitorado – como obstáculos ou outras interferências – ao mesmo tempo que permitem alcançar um melhor compromisso entre consumo de energia, área de cobertura e custo final da rede, quando comparados com implementações de RSSF homogêneas. No entanto, a busca pelo desempenho ótimo em implementações de RSSF heterogêneas torna-se consideravelmente mais complexa.

Uma RSSF ainda pode ser classificada de acordo com a forma como sua topologia física é organizada. A depender do tipo de aplicação, pode-se ter distribuições aleatórias ou pré-determinadas de nós sensores na região de monitoramento. O posicionamento pré-determinado de sensores em cenários controláveis é geralmente preferido, dado que possibilita maior domínio sobre a região monitorada, além de facilitar a localização e manutenção de cada dispositivo individualmente [Akyildiz et al., 2002]. Por sua vez, a distribuição aleatória é geralmente aplicável em áreas de perigo ou de difícil acesso [Bhondekar et al., 2009]. Nesses casos, os dispositivos normalmente não podem ser recuperados após a implantação. No entanto, de modo geral, uma grande vantagem de um projeto de RSSF com alocação pré-determinada em relação a aleatória é o uso de um número menor de nós sensores para executar uma mesma tarefa, o que significa, na prática, um menor custo final da rede.

Dadas essas definições, é importante denotar que, em geral, o sucesso de uma implementação prática de RSSF requer que alguns critérios sejam levados em consideração simultaneamente, tais como eficiência energética dos nós sensores, balanceamento de carga na transmissão das mensagens, área de cobertura, latência de comunicação, entre outros. Portanto, considerando especificamente uma implantação de uma RSSF com nós sensores heterogêneos em posições pré-determinadas em uma região de interesse, existe uma necessidade ainda maior de gerenciamento desses critérios, a fim de se obter uma alocação ótima para os dispositivos com o objetivo de garantir o melhor desempenho possível da rede a um custo mínimo [Srivastava e Mishra, 2021]. Esta é, por definição, uma variação do Problema de Alocação de Sensores (PAS) [Kendler e Fishbain, 2022], que é um problema de otimização combinatória cujo enunciado original generalizado pode ser definido como: “Dada uma região de interesse, deseja-se determinar a quantidade, o tipo e o posicionamento ótimos de nós sensores nessa região, a fim de alcançar critérios específicos de eficiência energética, balanceamento de carga, área de cobertura, latência de comunicação, dentre outros parâmetros”.

I.1 Objetivos

O objetivo geral do presente trabalho é propor um modelo de Programação Linear Inteira (PLI) multiobjetivo capaz de resolver a variação do PAS em estudo, considerando RSSF heterogêneas. Deseja-se minimizar o consumo de energia da rede, ao passo que busca-se maximizar a área de

cobertura dos nós sensores na região de interesse. Sendo assim, os objetivos específicos desta pesquisa podem ser definidos da seguinte forma:

- Realizar um estudo multiobjetivo do PAS proposto, considerando instâncias variadas do problema.
- Considerar como entrada do modelo instâncias de redes genéricas, *i.e.*, com quaisquer número de posições geográficas em uma região plana (\mathbb{R}^2) nas quais seria possível alocar nós sensores.
- Considerar diferentes tipos de nós sensores na solução do PAS, de forma que o modelo seja escalável e aplicável a diversos cenários de RSSF heterogêneas.
- Possibilitar que dados reais de transceptores sejam inseridos como entrada no modelo, a fim de que as soluções possam ser utilizadas como referência para implementações de RSSF em campo.

I.2 Motivação

Por conta de sua relevância na literatura e para a sociedade em campos multidisciplinares, a otimização em RSSF é um tema muito interessante e atual, com múltiplas aplicações práticas [Ko et al., 2015; Ayedi et al., 2021; Peng et al., 2009; Pinheiro et al., 2013; Guedes et al., 2021]. Diversos trabalhos na literatura apresentam soluções para variações distintas do PAS. No entanto, a grande maioria dos trabalhos encontrados propõem soluções heurísticas ou meta-heurísticas [Bhondekar et al., 2009; de Brito et al., 2019, 2022] – *i.e.* que não garantem a otimalidade global – ou consideram instâncias de pequena escala [Pinheiro et al., 2013; Alduraibi et al., 2016; Fella e Kechar, 2017], devido à alta complexidade combinatória inerente ao problema. De forma a expandir os estudos presentes na literatura, e a fim de possibilitar atingir as melhores soluções em cenários diversos, foi escolhida uma abordagem de otimização exata para o desenvolvimento desta pesquisa. Deseja-se determinar um modelo que represente de forma adequada o PAS em estudo e alcance a otimalidade, de preferência para instâncias que remetam a redes reais, o que seria um grande diferencial perante os demais trabalhos encontrados na literatura.

No mais, um modelo matemático capaz de resolver instâncias do PAS de forma eficiente pode ser de grande valia para implementações reais de RSSF, pois permite ao projetista da rede avaliar variações de cenários e seus respectivos custos antes de efetivamente iniciar a implantação da rede. Assim, não somente é garantida a redução de custo total do projeto, como também a possibilidade de analisar diferentes topologias que não foram percebidas inicialmente pelo projetista, auxiliando assim na tomada de decisão.

I.3 Justificativa

Dentre os trabalhos da literatura que propõem soluções para o PAS, alguns autores consideram RSSF homogêneas ou com distribuição em grade dos nós sensores na região de monitoramento [Bhondekar et al., 2009; de Brito et al., 2019, 2022]. Outros trabalhos apresentam a validação do modelo com dados de nós sensores genéricos, isto é, sem considerar parâmetros como alcance ou custo que remetam a nós sensores reais, por exemplo [Pinheiro et al., 2013; Balesdent e Piet-Lahanier, 2015; Nguyen et al., 2019; Tam et al., 2019; Azevedo et al., 2021]. Este estudo se diferencia dos demais ao considerar RSSF heterogêneas com posições candidatas a alocação de nós sensores pré-determinadas em uma região de monitoramento. Os nós sensores são modelados de forma a possibilitar a representação de características reais de IdC, podendo ainda, cada qual, assumir configurações distintas, o que confere a heterogeneidade da rede. Além disso, o modelo possibilita o posicionamento de nós sensores em uma região plana sem que estejam necessariamente distribuídos em grade.

O modelo proposto foi validado mediante estudos de caso utilizando linguagem Python e o *solver* Gurobi[®] ¹, o que permitiu observar a capacidade de se obter soluções ótimas para diferentes formatos e tamanhos de instâncias do PAS em estudo e fornecer assim um diferencial em relação aos métodos de solução heurísticos geralmente encontrados na literatura. No mais, o modelo é escalável, podendo ser utilizado como base para implementações distintas e mais complexas de RSSF, tais como RSSF em terrenos de aclave ou declive [Shutimarrungson e Wuttidittachotti, 2019], RSSF subterrâneas [Sun e Akyildiz, 2010], RSSF subaquáticas [Akyildiz, 2014] ou em ambientes com variados obstáculos presentes [Balesdent e Piet-Lahanier, 2015], por exemplo, o que potencialmente contribuiu para a otimização de diferentes aplicações práticas.

I.4 Metodologia

De forma a alcançar os objetivos elencados, as seguintes etapas foram definidas para este trabalho:

- Desenvolver um modelo PLI para resolver o PAS em estudo.
- Coletar dados sobre nós sensores e transceptores reais, de forma a utilizar como dados de entrada na validação do modelo proposto.
- Resolver o PAS multiobjetivo.
- Validar o modelo matemático através de estudos de caso, considerando instâncias do PAS de formato e tamanho variados.

¹<https://www.gurobi.com>

I.5 Organização do Trabalho

O restante do trabalho está organizado da seguinte maneira: no Capítulo II é apresentada a base teórica para a compreensão do estudo realizado. No Capítulo III uma breve revisão da literatura é apresentada, destacando os principais trabalhos relacionados ao problema de otimização abordado nesta pesquisa. No Capítulo IV é apresentada a formulação matemática proposta, assim como a relação dos dados de entrada requeridos e as saídas esperadas. O Capítulo V mostra os experimentos e resultados obtidos a partir do estudo de caso multiobjetivo realizado para a validação do modelo, além de realizar discussões pertinentes a esses tópicos. Por fim, no Capítulo VI as considerações finais desta pesquisa são apresentadas, destacando propostas de trabalhos futuros.

Capítulo II Referencial Teórico

Neste capítulo são abordados, de forma objetiva, os principais conceitos cuja compreensão é necessária para o entendimento completo deste trabalho. Dentre os tópicos elencados, destacam-se definições importantes acerca de RSSF, Otimização e Teoria de Grafos. Por fim, o presente trabalho é contextualizado mediante toda a fundamentação teórica apresentada.

II.1 Redes de Sensores Sem Fio (RSSF)

As RSSF constituem-se por uma distribuição de diversos dispositivos autônomos e capazes de se intercomunicar, conhecidos como nós sensores, em uma determinada região de interesse para fins de monitoramento [Akyildiz et al., 2002]. Os nós de uma RSSF podem comportar diferentes tipos de sensores, tais como sísmicos, termais, visuais, infravermelhos, acústicos ou de radar, capazes de monitorar aspectos do ambiente como temperatura, umidade, movimento, iluminação, pressão, ruído, ou características de determinados objetos (como presença, forma ou tamanho). A grande variedade de nós sensores permite às RSSF uma vasta gama de aplicações, seja nas áreas militar [Ali et al., 2020], ambiental [García et al., 2021; Azevedo et al., 2021], de saúde [Da Rocha Henriques et al., 2021], doméstica [Ranganathan, 2015] ou comercial [Kim e Tran-Dang, 2019].

A título de exemplificação, na área da saúde, uma Rede de Sensores Corporais Sem Fio (RSCSF) pode ser implantada em pacientes e utilizada pelo médico para monitoramento remoto de dados biométricos, possibilitando acompanhamento em tempo real de seus estados de saúde [Da Rocha Henriques et al., 2021]. Nessa situação, apenas alguns nós sensores podem ser suficientes para monitorar parâmetros específicos. Por outro lado, na área ambiental, RSSF podem ser implantadas para monitorar campos a fim de auxiliar na programação de processos de irrigação automática [García et al., 2021], assim como podem ser utilizadas em florestas para identificação de focos de incêndio [Azevedo et al., 2021], dentre outras aplicações. Nesses dois últimos exemplos citados, dependendo do tamanho do terreno, pode ser necessária a implantação de centenas ou milhares de nós sensores.

A quantidade total de nós sensores em uma implementação de RSSF pode ser muitas ordens de magnitude maior que a quantidade de *hosts* em tradicionais redes locais de computadores (LANs), dependendo da aplicação. Essa característica no geral pode tornar a manutenção

individual desses dispositivos impraticável. Além disso, ao passo que protocolos de redes tradicionais buscam otimizar a Qualidade de Serviço (QoS), mecanismos de RSSF devem buscar primariamente a maximização do tempo de vida da rede, ainda que seja necessário sacrificar desempenho em termos de parâmetros como vazão (*throughput*) ou latência (*delay*) [Akyildiz et al., 2002]. Mesmo com todas essas considerações, devido a limitações inerentes ao seu próprio *hardware*, os nós sensores são naturalmente dispositivos suscetíveis a falhas, o que exige que as RSSF sejam sistemas adaptáveis, isto é, capazes de reorganizar sua topologia de acordo com a necessidade, utilizando para isso algoritmos de roteamento inteligentes.

II.1.1 Nós sensores

Os nós sensores que compõem as RSSF são pequenos dispositivos eletrônicos compostos de limitada capacidade de energia, sensoriamento, processamento de dados, memória e comunicação [Srivastava e Mishra, 2021]. Usualmente esses dispositivos são alimentados individualmente por fontes fixas e limitadas de energia, como pilhas ou baterias, podendo também ser recarregados através de fontes renováveis, tais como energia solar ou hidráulica. Para isso, no entanto, essas fontes devem estar acessíveis dentro da região de interesse em que o monitoramento será realizado.

A depender da aplicação, os possíveis locais para posicionamento dos nós sensores podem ou não ser pré-determinados. De todo modo, ao efetuar alocação de uma grande quantidade de nós sensores em regiões de difícil acesso ou perigosas, é recomendável que a distribuição seja feita de forma aleatória para reduzir custos, dado que nesses cenários é muito improvável que os nós sensores sejam recuperados para manutenção após implantação [Bhondekar et al., 2009].

Por conta de suas limitações de capacidade de processamento e memória, os nós sensores de uma RSSF podem não ser capazes de armazenar ou processar muitos dados coletados em um mesmo intervalo de tempo. Por isso, uma RSSF permite que os dados trafeguem ao longo das redes por múltiplos saltos até alcançar uma EB ou sorvedouro, onde são armazenados e posteriormente disponibilizados para análise. Dependendo da necessidade – que pode variar de acordo com a aplicação – esse tráfego pode ocorrer em intervalos periódicos ou em tempo real. A EB pode ser uma estação de processamento de dados *in situ* ou apenas um nó raiz capaz de retransmitir os dados para uma infraestrutura em nuvem, onde de fato os dados serão armazenados e processados para então serem disponibilizados aos usuários.

II.1.2 Gestão de Energia

A eficiência energética em uma RSSF é muito importante, dado que os nós sensores que a compõem são usualmente limitados em termos de capacidade de energia. Por conta disso, falhas causadas por esgotamento de energia em alguns poucos nós sensores críticos pode prejudicar todo

o funcionamento da rede. Por mais que os nós sensores sejam dispositivos com baixo consumo energético, essa limitação individual de cada nó associada à necessidade de operação contínua da rede representam fortes restrições para o tempo de vida total das RSSF de modo geral, principalmente em aplicações nas quais as fontes de energia não podem ser trocadas ou recarregadas. Por isso, durante o projeto de uma RSSF para atender uma região específica, é importante considerar o consumo individual de energia dos nós sensores de acordo com suas funções desempenhadas na rede. Algoritmos e protocolos de comunicação empregados nessas redes devem ser capazes de gerenciar o estado de operação e a comunicação entre os nós a fim de garantir bom desempenho e o prolongamento de tempo de vida da RSSF, ou seja, a extensão de sua autonomia de monitoramento.

Dependendo da aplicação, os nós sensores podem possuir a capacidade de alterar seu estado de operação ativo para um estado de economia de energia (*sleep*) e vice-versa. Esse processo pode ser realizado ciclicamente – de forma síncrona ou assíncrona – durante todo o tempo de vida do dispositivo, de forma a proporcionar um menor consumo energético total. O período de tempo durante o qual o nó sensor está ativo, em relação a um ciclo total de operação é conhecido como *Duty Cycle* (D_C). Esse parâmetro, representado matematicamente através da Equação II.1, indica a razão – em termos percentuais – entre o tempo durante o qual o nó sensor está ativo (T_{ativo}) e o tempo de seu ciclo de operação completo (T_{ciclo}). Dessa forma, quanto maior o D_C , maior será o consumo de energia do nó.

$$D_C (\%) = \frac{T_{ativo}}{T_{ciclo}} \times 100. \quad (II.1)$$

A fim de reduzir o consumo energético e manter algumas funcionalidades da rede, uma opção interessante consiste em desenergizar temporariamente apenas alguns componentes do nó sensor, tais como os sensores ou o transceptor, por exemplo. Algoritmos e protocolos de rede podem considerar essa possibilidade como uma forma de prolongar o tempo de vida de uma RSSF. No entanto, é preciso haver uma coordenação entre os nós sensores e seus vizinhos de forma que não haja dessincronização entre pares que tentam se comunicar em um dado intervalo de tempo, o que causaria desperdício de energia [Sharma et al., 2013].

II.1.3 Arquitetura de Comunicação em RSSF

Em uma implementação de RSSF, os nós sensores são usualmente espalhados sobre uma região de monitoramento de forma que os dados possam fluir através da rede mediante o uso de protocolos específicos de roteamento. O pleno funcionamento desse tipo de sistema tem como base um modelo de pilha de protocolos como apresentado na Figura II.1, que consiste em uma abstração baseada no Modelo OSI [Kannan e Chakravarthi, 2022], este que é aplicável a redes de computadores convencionais. A pilha é composta pela camada de aplicação, camada de

transporte, camada de rede, camada de enlace e camada física, ao passo que existem também os planos de gerenciamento de energia, gerenciamento de mobilidade e gerenciamento de tarefas, que perpassam por todas as camadas da pilha [Akyildiz et al., 2002].

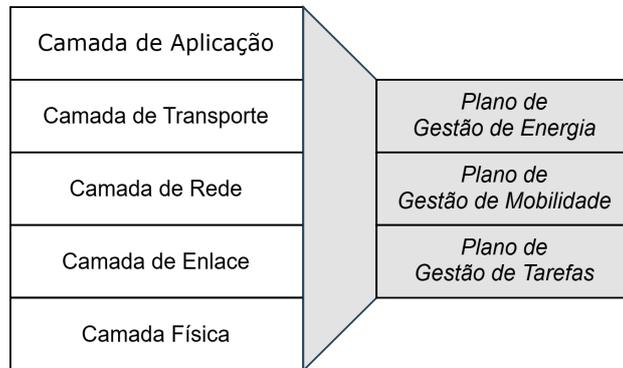


Figura II.1: Pilha de protocolos de comunicação em RSSF, adaptado de Akyildiz et al. [2002].

Dependendo das tarefas de sensoriamento, a camada de aplicação pode incluir tanto as etapas de pós-processamento quanto de apresentação dos dados coletados. A camada de transporte, por sua vez, garante o fluxo de dados de acordo com os requerimentos da aplicação. A camada de rede assume a função de roteamento dos dados providos pela camada de transporte. A camada de enlace opera a fim de coordenar a comunicação, reduzir ruído e evitar colisão e congestionamento na rede. Por fim, a camada física é responsável por prover as necessidades básicas de transmissão e recepção de dados, assim como a modulação ideal para cada cenário de transmissão [Fahmy, 2016].

Paralelamente, os planos de gestão de energia, mobilidade e tarefas operam de forma a coordenar a operação de todos os sensores como um conjunto, cooperando para reduzir o consumo de energia total da RSSF. O plano de gerenciamento de energia é responsável por gerenciar como um nó sensor utiliza sua energia disponível. Um nó pode, por exemplo, entrar em modo de economia de energia após receber uma mensagem de um vizinho, ou mesmo enviar uma mensagem em difusão (*broadcast*) para avisar que sua capacidade de energia está muito baixa e que por isso ele não pode mais operar nas funções de roteamento. O plano de mobilidade detecta e registra a localização e movimentação dos nós e seus vizinhos, garantindo que sempre existirá uma rota para o sorvedouro e possibilitando balancear o uso de energia e atribuição de tarefas. Por fim, o plano de tarefas coordena a atribuição das atividades de sensoriamento a cada grupo de nós sensores na região, o que possibilita que alguns nós sensores monitorem apenas parâmetros específicos enquanto outros operem em economia de energia durante um mesmo intervalo de tempo. Esses planos de gerenciamento são necessários pois possibilitam que os nós sensores operem em conjunto de forma mais eficiente, roteando dados e compartilhando recursos. Essa colaboração proporciona à RSSF um maior tempo de vida, de modo geral [Kochhar et al., 2018].

II.1.4 Topologias de RSSF

As RSSF podem ser organizadas de forma física ou lógica em diversas topologias, muitas delas baseadas em redes de computadores tradicionais. As possíveis topologias existentes são: Barramento (ou Linear), Estrela, Árvore (ou Estrela Estendida), Anel, Malha, Circular e Grade [Sharma et al., 2013]. Um comparativo entre cada uma dessas topologias é apresentado na Tabela II.1, na qual diversos critérios de desempenho são avaliados numa escala de 1 a 5, onde 1 representa pior desempenho, e 5 o melhor desempenho. Os critérios avaliados são: *(i)* Caminho (se possibilita ou não fluxo através de múltiplos caminhos a partir de um nó); *(ii)* Falha de nós (se é resiliente à falha de nós sensores); *(iii)* Balanceamento de carga (se possibilita distribuir fluxo através de caminhos distintos); *(iv)* Congestionamento (se é resistente a congestionamento de tráfego em nós críticos); *(v)* Confiabilidade (se possui resiliência a falhas na entrega de mensagens); *(vi)* Consumo de energia (se favorece a economia de energia em cada nó sensor individualmente); e *(vii)* Tempo de vida da rede (se favorece o alcance de maior tempo de vida global).

Tabela II.1: Comparativo de diferentes topologias de RSSF, adaptado de Sharma et al. [2013].

Desempenho	Barramento	Estrela	Árvore	Anel	Malha	Circular	Grade
Caminho	Único	Único	Único	Duplo (mesma direção)	Múltiplo (irregular)	Múltiplo	Múltiplo
Falha de nós	1	1	1	1	4	4	5
Balanceamento de carga	1	2	3	1	4	4	5
Congestionamento	1	1	1	1	4	4	5
Confiabilidade	1	1	1	1	4	4	5
Consumo de energia	1	1	1	1	4	4	5
Tempo de vida da rede	1	1	1	1	4	4	5

A partir da análise desses critérios, de modo geral, percebe-se que as topologias que proporcionam melhor desempenho a uma RSSF são, respectivamente, Grade, Circular e Malha, seguidas de Árvore e Estrela. No entanto, em um projeto de RSSF deve-se levar em consideração o contexto da aplicação para que a topologia selecionada seja adequada e proporcione funcionalidade à rede. Em um cenário de monitoramento de dutos e tubulações, por exemplo, uma topologia Barramento pode ser a mais aplicável [Wu et al., 2014]. A seguir serão apresentados detalhes de cada uma das topologias elencadas na Tabela II.1.

Barramento

A topologia Barramento (ou Linear) opera como se todos os nós da rede estivessem conectados fisicamente a um mesmo enlace ou barramento contíguo linear. Quando um nó precisa encaminhar mensagem a outro nó do barramento, todos os demais nós recebem a mensagem, sendo que apenas o destinatário verdadeiro aceita e processa os dados recebidos. É uma topologia de simples instalação, porém com alto congestionamento de tráfego e comunicação em único sentido, funcionando bem

apenas para redes com um número menor que algumas dúzias de nós sensores, sendo assim pouco prática para implementações de RSSF [Sharma et al., 2013], exceto quando a aplicação exige uma distribuição física linear dos nós sensores, tal como no monitoramento de dutos e tubulações (Wu et al. [2014]). A Figura II.2 ilustra essa topologia.

Estrela

A topologia Estrela, conforme mostrado na Figura II.3, considera um nó central principal como sorvedouro, capaz de receber dados diretamente de todos os outros nós da rede. Dessa forma, os nós ou dispositivos finais (*end devices*) não podem se comunicar diretamente. Caso seja necessária a comunicação entre dois nós fim, os dados devem necessariamente fluir através do nó central.

O principal problema dessa topologia consiste em que, caso o nó central falhe, toda a rede se torna inoperante, portanto uma fonte de energia constante normalmente é considerada para esse dispositivo. Outro problema dessa topologia consiste na falta de escalabilidade da rede, dado que o nó central precisa estar dentro do alcance de transmissão de todos os nós fim [Sharma et al., 2013].

Árvore

Na topologia Árvore ou Estrela Estendida (Figura II.4), a rede possui um concentrador chamado raiz que opera como o principal sorvedouro da rede. Outros concentradores e nós filhos podem existir conectados diretamente ao nó raiz, e assim sucessivamente, proporcionando uma configuração hierárquica – o que garante maior escalabilidade da rede. Esses concentradores podem ser chamados cabeças de grupo (*cluster heads*), pois são responsáveis por repassar as mensagens de todos os nós filhos ao respectivo nó pai [Sharma et al., 2013].

Nesse tipo de configuração de RSSF, os caminhos podem ser de único salto ou múltiplos saltos, sendo importante encontrar caminhos ótimos mínimos para proporcionar maior tempo de vida da rede e menor latência. Semelhante à topologia Estrela, uma desvantagem da topologia Árvore consiste em que a falha de um *cluster head* impossibilita a comunicação entre as subárvores diretamente conectadas a esse nó, tornando-se necessária a adoção de técnicas para mitigar esses eventos como por exemplo eleição de novos *cluster heads* a partir de caminhos redundantes disponíveis [Li et al., 2018].

Anel

Uma topologia em anel possibilita que cada nó da rede tenha no máximo 2 vizinhos. Dessa forma, a comunicação pode fluir em sentido horário ou anti-horário, sendo de único salto ou múltiplos saltos, até alcançar o nó destino. A desvantagem dessa organização topológica é que a falha de um único nó é suficiente para quebrar o anel, gerando maior latência e congestionamento no tráfego multi-saltos.

Além disso, caso dois nós venham a falhar, a RSSF é seccionada em duas, o que pode inutilizar a operação de toda a rede [Sharma et al., 2013]. A Figura II.5 exemplifica esse tipo de topologia.

Malha

Uma topologia em malha permite que diversos caminhos sejam tomados para que a informação trafegue a partir de um nó origem a um nó destino. Nesses cenários, cada nó pode se comunicar diretamente com diversos vizinhos, estes que são capazes de repassar a informação à frente sempre que necessário até alcançar um sorvedouro. Redes em malha em que todos os nós conseguem se comunicar diretamente são chamadas de malhas completas (*Full Mesh*), enquanto que redes onde ao menos um par de nós não consegue se comunicar diretamente são chamadas de malhas parciais (*Partial Mesh*) [Sharma et al., 2013].

Essa topologia é muito utilizada em projetos de RSSF por conta da alta escalabilidade e fácil implementação, ao passo que possibilita que a rede continue operando mesmo que alguns nós venham a falhar durante o ciclo de vida da RSSF. No entanto, é importante considerar algoritmos de roteamento para evitar alta latência ao contornar falhas na rede, e também evitar a sobrecarga dos canais de comunicação por propagação de dados através de laços (*loops*). A Figura II.6 ilustra esse tipo de topologia.

Circular

Essa topologia considera o funcionamento lógico das RSSF em malha, porém com uma distribuição física em uma região de monitoramento circular. Dessa forma, o sorvedouro se localiza no centro da região e os nós sensores estão distribuídos ao longo do círculo, podendo se intercomunicar livremente. Essa organização permite que dados trafeguem em um único ou múltiplos saltos até alcançar o sorvedouro, dependendo da distância entre os nós sensores distribuídos. É uma configuração eficiente, sendo fácil de realizar a implementação e manutenção [Sharma et al., 2013]. A Figura II.7 exemplifica esse tipo de topologia.

Grade

Na topologia em Grade, a área de monitoramento é dividida em diversos quadrados não sobrepostos de mesmo tamanho. Dentro de cada subárea podem existir diversos nós sensores e, em um dado instante de tempo, apenas um deles opera enquanto os outros permanecem em estado de economia de energia. Dessa forma, os nós alternam seu funcionamento de forma coordenada, a fim de proporcionar um aumento no tempo de vida da rede como um todo. O nó atualmente eleito e ativo dentro de cada subárea é conhecido como nó mestre ou cabeça de grade (*grid head*), e é responsável por encaminhar as informações de roteamento e dados. Por sua vez, outros nós da

rede podem funcionar como retransmissores (*relays*) a fim de auxiliar os *grid heads* a estabelecer caminhos para que todo o tráfego da rede flua através da grade até alcançar o sorvedouro.

O roteamento é efetuado de subárea em subárea através da grade, e protocolos de múltiplos saltos devem ser empregados para rotear pacotes de forma rápida e evitar congestionamento. Devido a alta escalabilidade e alta disponibilidade garantidas, essa topologia é a mais eficiente para projetos de RSSF, apesar de não ser tão simples de implementar quanto as topologias em Malha ou Circular [Sharma et al., 2013]. A Figura II.8 fornece um exemplo desse tipo de topologia.

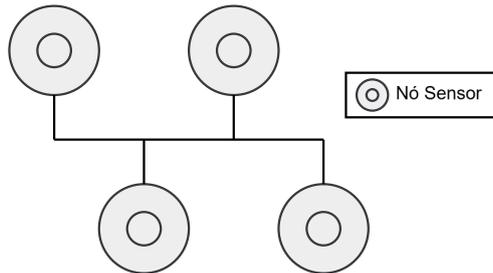


Figura II.2: Exemplo de topologia Barramento em RSSF, adaptado de Sharma et al. [2013].

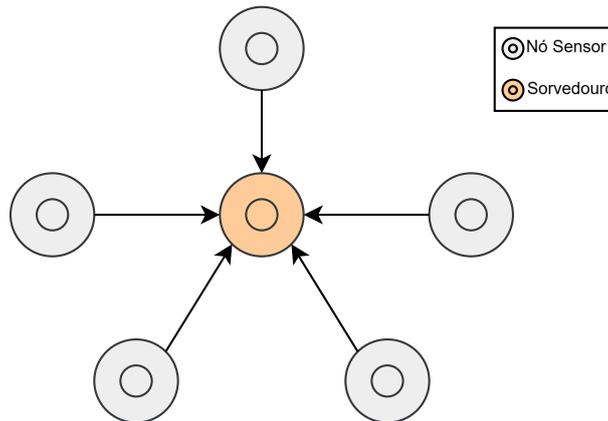


Figura II.3: Exemplo de topologia Estrela em RSSF, adaptado de Sharma et al. [2013].

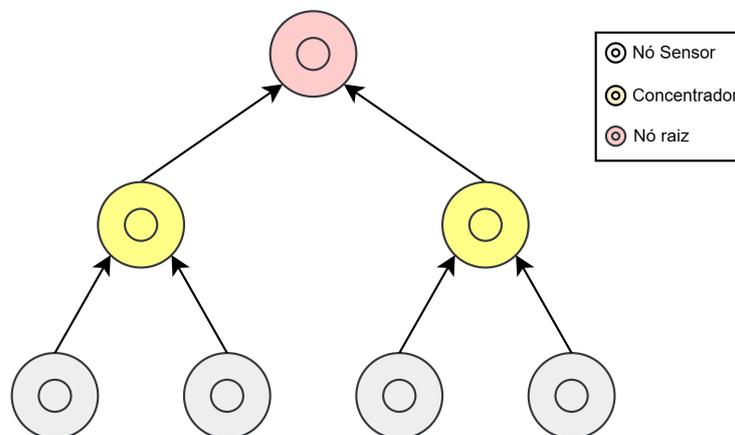


Figura II.4: Exemplo de topologia Árvore em RSSF, adaptado de Sharma et al. [2013].

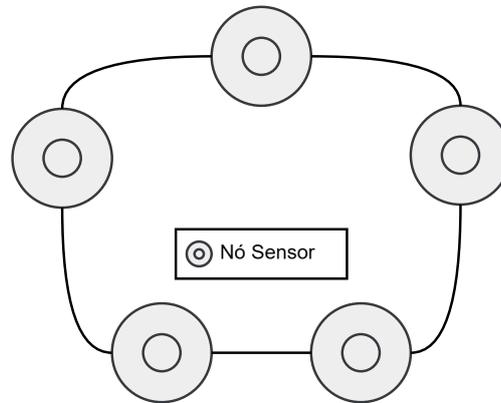


Figura II.5: Exemplo de topologia Anel em RSSF, adaptado de Sharma et al. [2013].

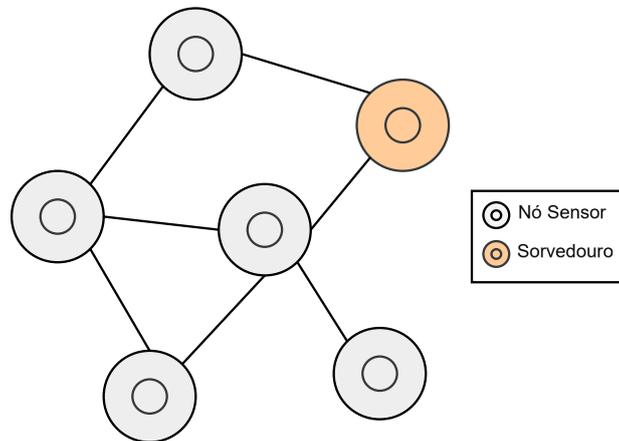


Figura II.6: Exemplo de topologia Malha em RSSF, adaptado de Sharma et al. [2013].

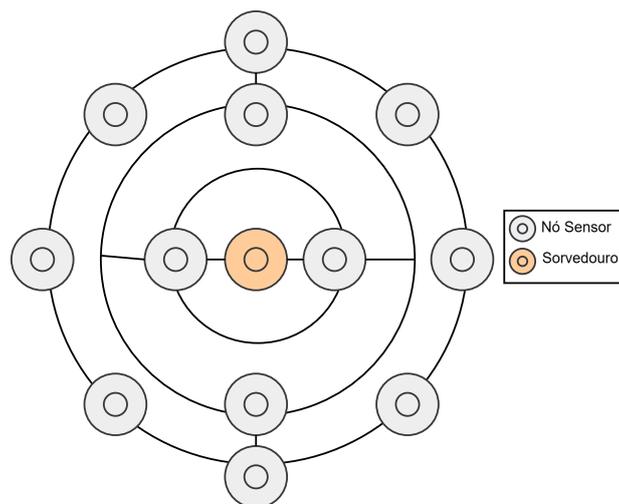


Figura II.7: Exemplo de topologia Circular em RSSF, adaptado de Sharma et al. [2013].

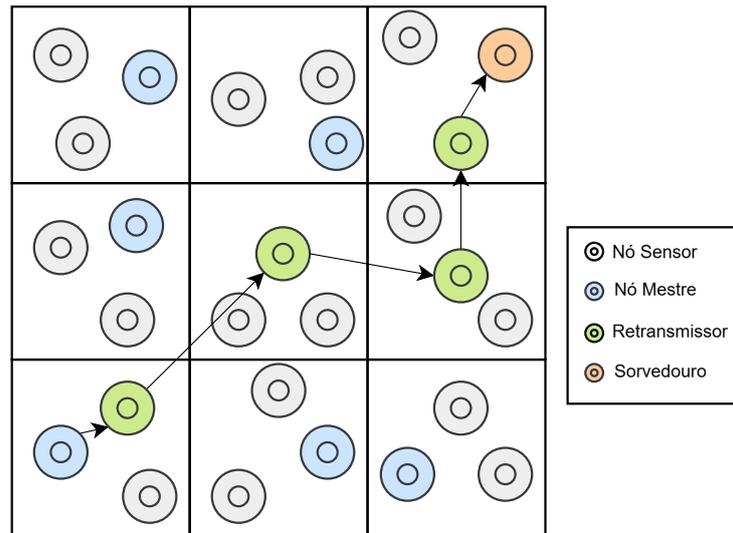


Figura II.8: Exemplo de topologia Grade em RSSF, adaptado de Sharma et al. [2013].

II.1.5 Categorização de Nós Sensores e Heterogeneidade

De acordo com a topologia selecionada, os nós sensores em RSSF podem desempenhar diferentes funcionalidades. Nas redes em *Árvore*, por exemplo, os *cluster heads* se diferem dos *end devices* por serem responsáveis por concentrar maior parte do tráfego de dados e por serem pontos críticos de roteamento até o sorvedouro. Essa diferenciação cria uma categorização hierárquica entre os nós sensores na qual o sorvedouro corresponde ao nó mais importante da rede, seguido dos *cluster heads*. Essa importância se dá pois, caso um desses nós sensores venham a falhar, toda ou grande parte da rede é prejudicada.

Nós sensores que desempenham papéis críticos normalmente têm maior gasto energético, por conta do maior tempo que precisam estar disponíveis em estado de operação para receber e encaminhar dados. Essa característica fomenta a necessidade de fornecer recursos adicionais para garantir que o tempo de vida desses nós seja maior que o dos *end devices*. Em algumas implementações de RSSF, algoritmos específicos podem ser utilizados para sincronizar a operação de todos os nós sensores na rede e prolongar o tempo de vida dos nós críticos. Em outros casos, é possível fornecer fontes de energia renováveis ou ininterruptas para esses nós. Quando essas opções não são viáveis, pode-se utilizar fontes de energia de maior capacidade para esses elementos.

Quando há variação nos componentes dos nós sensores presentes na rede, tais como sensores, transceptores, capacidade de energia, processamento e memória, ou mesmo fornecimento de capacidades adicionais a alguns nós sensores tais como a possibilidade de se movimentar, a RSSF é considerada heterogênea [Elfouly et al., 2021]. Esse tipo de rede é mais difícil de gerenciar e otimizar por conta de um escopo muito maior de variáveis existentes, mas pode fornecer vantagens dependendo do ambiente de monitoramento, da quantidade de nós sensores presentes e principalmente em termos do prolongamento do tempo de vida da rede [Wu e Chung, 2007]. Por

sua vez, quando a RSSF possui todos os nós sensores exatamente iguais, esta é considerada uma rede homogênea. Essa configuração é mais fácil de implementar e manter, além de ser mais simples para otimizar os recursos disponíveis, apesar de apresentar limitações inerentes ao *hardware*.

II.1.6 Principais Desafios da Área

Na área de RSSF, existe uma preocupação constante sobre o prolongamento do tempo de vida da rede, independentemente da aplicação, dado que, caso alguns nós sensores falhem, a rede pode ser prejudicada por completo. O desenvolvimento de algoritmos para aprimorar o roteamento e a latência em RSSF, garantindo paralelamente um bom desempenho em termos de QoS, tem se mostrado como um desafio presente na literatura [Saeed et al., 2019; Mansourkiaie e Ahmed, 2016; Zungeru et al., 2016].

Além disso, o aprimoramento de *hardware* específico que garanta melhores condições de utilização dos nós sensores – tais como maior tempo de vida, processamento mais veloz, melhor taxa de transmissão, ou modulação que proporcione uma transmissão com menores perdas – é uma subárea de estudo também muito importante [Akyildiz et al., 2002]. Áreas derivadas como RSSF subterrâneas ou subaquáticas possuem muitos desafios em aberto oriundos de dificuldades de transmitir dados com confiabilidade através de um meio sem fio em ambientes mais hostis que o próprio ar, *i.e.* onde a atenuação do sinal é maior [Kanthavel e Dhaya, 2022; Akyildiz, 2014].

Ademais, a busca por alocação eficiente de nós sensores (sejam *end devices*, *cluster heads* ou sorvedouros) é um problema frequente em diversos cenários de monitoramento nos quais o posicionamento dos nós é fixo. Dependendo da topologia selecionada, do distanciamento entre os nós e das características intrínsecas aos dispositivos, uma implementação de RSSF pode ter um comportamento completamente distinto. A fim de superar obstáculos do ambiente, minimizar o custo da rede, e garantir um tempo de vida aceitável para a aplicação, diversos trabalhos têm considerado aplicar técnicas de otimização, seja através de métodos exatos, heurísticos ou meta-heurísticos, a fim de determinar a topologia ótima de RSSF [Azevedo et al., 2021; de Brito et al., 2019; Pinheiro et al., 2013].

II.2 Otimização

O processo de estudar, planejar e coordenar operações, assim como desenvolver e aplicar métodos analíticos para auxiliar na tomada de decisões é conhecido como aplicação da Pesquisa Operacional (PO). Tal área do conhecimento fornece técnicas que possibilitam investigar problemas que exigem otimização de parâmetros para alcançar determinado(s) objetivo(s) mediante um conjunto de restrições [Goldbarg e Luna, 2000].

Para a resolução de um problema, usualmente inicia-se pela observação e formulação cuidadosa

do mesmo, incluindo a coleta de dados relevantes. Essa definição deve remeter a uma clara percepção do desafio colocado, considerando elementos palpáveis como o objetivo que se deseja alcançar, as variáveis de decisão ou controle, e níveis de detalhamento do problema [Goldbarg e Luna, 2000]. Em seguida, a construção de uma abstração ou modelo científico (tipicamente matemático) é realizada e, partindo-se da hipótese que o modelo representa de forma fiel o problema real, experimentações são executadas para testar a hipótese e validar o modelo, isto é, determinar se a hipótese inicial é verdadeira. A partir desse ponto, estudos podem ser aplicados ao modelo abstrato a partir de um ponto de vista abrangente, a fim de simular cenários do problema real, possibilitando determinar quais decisões tomar a fim de alcançar uma solução ótima [Hillier e Lieberman, 2013].

A maior vantagem da aplicação de PO consiste na possibilidade de avaliação de múltiplos cenários do mesmo problema de otimização em um curto espaço de tempo e com um custo reduzido se comparado a implementação e testes em cenários reais. Por conseguinte, conhecer a configuração ótima para alcançar o objetivo desejado de antemão permite economizar muitos recursos que seriam gastos durante a implantação, teste e validação de cada possível solução.

II.2.1 Programação Matemática

Os modelos de PO são abstrações da realidade estruturados de forma lógica e arquitetados de acordo com ferramentas matemáticas precisas com o objetivo de determinar de forma clara as melhores condições de operação para os sistemas representados. Os principais modelos de PO são denominados Programação Matemática, e constituem uma das mais importantes variedades de modelos quantitativos [Goldbarg e Luna, 2000]. Usualmente os modelos matemáticos tomam dados como entrada e geram uma ou mais saídas que representam um aspecto da realidade de acordo com os valores selecionados para as variáveis estudadas, estas limitadas por restrições preestabelecidas.

As técnicas de solução de Programação Matemática podem ser categorizadas em diversas subáreas, tais como: Programação Linear (PL), Programação Não Linear (PNL), Programação Linear Inteira (PLI), Programação Não Linear Inteira (PNLI) e Programação Linear Inteira Mista (PLIM). Essa separação ocorre por conta de peculiaridades inerentes aos diversos contextos de planejamento, o que acarreta em especializações dos métodos de solução. É importante salientar no entanto que o processo de modelagem matemática em si tipicamente varia pouco para cada caso [Goldbarg e Luna, 2000].

A PL é um campo da Programação Matemática em que as variáveis de decisão são contínuas e apresentam comportamento linear em relação à FO e também às restrições. É uma subárea muito importante devido à eficiência dos algoritmos de solução existentes e à possibilidade de transformação de modelos de PNL em PL. Um modelo é considerado de PNL se possui qualquer tipo de não linearidade, seja na FO ou em quaisquer restrições. Esses modelos são tratáveis em casos de

problemas convexos, quando algoritmos eficientes também podem resolver grandes problemas reais. Por sua vez, PLI e PNLi consistem na representação de problemas de otimização nos quais todas as variáveis possuem domínio discreto, sendo PLI os modelos que possuem somente variáveis de decisão e restrições lineares, ao passo que PNLi permite alguma não linearidade. Por fim, na PLIM há tanto variáveis contínuas quanto discretas. No caso de modelos lineares inteiros (PLI ou PLIM), a existência de discretização implica em restrições adicionais, o que confere maior complexidade computacional quando comparados a modelos de PL [Hillier e Lieberman, 2013].

De forma geral, um modelo matemático PLI pode ser formalizado segundo as Equações (II.2)-(II.5), onde c' é um vetor de custo, e procura-se minimizar a função de custo $c'\mathbf{x}$ sobre todo o vetor de variáveis de decisão $\mathbf{x} \in \mathbb{Z}^n$, sujeito a um conjunto de restrições lineares, representadas pela Equação (II.3), onde M é um conjunto finito de índices i no qual, para cada i , é dado um vetor a_i e um escalar b_i que compõem a i -ésima restrição. Além disso, na Equação (II.4), o conjunto N determina quais variáveis de decisão \mathbf{x}_j estão restritas à não negatividade [Bertsimas e Tsitsiklis, 1997].

O conjunto de variáveis de decisão \mathbf{x} que satisfaz todas as restrições do problema é chamado conjunto de soluções factíveis, e a função $c'\mathbf{x}$ é chamada FO do problema. Em um problema de minimização, uma solução factível \mathbf{x}^* que minimiza a FO é chamada solução ótima. Por sua vez, em um problema de maximização, a solução ótima é aquela que maximiza o custo ou o valor da FO. Dessa forma pode-se compreender que existe uma relação de equivalência, dado que minimizar $c'\mathbf{x}$ é equivalente a maximizar $-c'\mathbf{x}$ [Bertsimas e Tsitsiklis, 1997].

$$\text{Minimizar} \quad c'\mathbf{x} \tag{II.2}$$

Sujeito a :

$$a_i\mathbf{x} \geq b_i \quad \forall i \in M \tag{II.3}$$

$$\mathbf{x}_j \geq 0 \quad \forall j \in N \tag{II.4}$$

$$\mathbf{x} \in \mathbb{Z}^n \tag{II.5}$$

II.2.2 Métodos de Solução

Os métodos de solução para modelos de otimização podem ser categorizados como exatos ou heurísticos. Métodos exatos garantem a obtenção de solução comprovadamente ótima global entre todas as soluções factíveis do espaço de soluções do problema, ao custo de maior complexidade computacional [Sun et al., 2020]. Por sua vez, métodos heurísticos proporcionam uma busca inteligente por soluções que tendam à ótima com menor custo computacional, mas sem garantia de atingir valor ótimo global. Por serem dependentes do problema e muitos algoritmos possuem

natureza gulosa, existe uma probabilidade maior de que a execução de métodos heurísticos recaia sobre valores ótimos locais, o que é equivalente a uma solução válida, porém subótima. Meta-heurísticas, por sua vez, são algoritmos independentes do problema, menos propensos a recair sobre ótimos locais, mas que também não são capazes de garantir que a solução encontrada é a melhor disponível no espaço de soluções [Singh et al., 2021].

A depender do problema que se deseja resolver, um espaço de soluções de magnitude exponencial deve ser analisado. Solucionar problemas com tal característica é computacionalmente custoso e por vezes inviável se for considerada a avaliação de todas as possíveis soluções. Por conta desse desafio, métodos de solução inteligentes foram desenvolvidos a fim de proporcionar o alcance de soluções ótimas ou subótimas, de acordo com a necessidade, e em tempo computacional aceitável [Hillier e Lieberman, 2013].

O algoritmo Simplex é um algoritmo geral extremamente eficiente para resolver modelos de PL de forma exata, apesar de existirem casos em que apresenta comportamento exponencial. O Simplex é adaptável ao cálculo computacional, e seu funcionamento embasa diversos outros métodos de solução existentes. Basicamente consiste em um método iterativo com base em ferramentas da Álgebra Linear que, partindo de uma solução viável do espaço de soluções do problema, busca sempre outras soluções viáveis que tenham um valor igual ou melhor que a atual. Para problemas convexos, essas iterações sempre garantem matematicamente que, ao fim da execução, ao menos uma solução ótima será encontrada [Goldbarg e Luna, 2000]. Diversos *softwares* conhecidos como *solvers* são capazes de receber modelos complexos como entrada e executar o algoritmo Simplex ou variações deste para resolvê-los de forma exata [Hillier e Lieberman, 2013].

No caso de PLI, por conta da necessidade de lidar com variáveis de decisão discretas, alguns *solvers* optam por utilizar o método *Branch-and-Bound* ou variações deste. Esse método iterativo exato baseia-se em estruturas de árvores de decisão para, a partir da solução inicial do problema em sua forma contínua (que pode ser obtida a partir do algoritmo Simplex ou algum método derivado), adicionar novas restrições progressivamente ao problema a fim de limitar o escopo das variáveis ao espaço das soluções discretas. Assim, diversos subproblemas são resolvidos em sequência e, ao final de cada iteração, o valor do custo ótimo é atualizado com base na comparação entre os resultados dos subproblemas cuja solução obtida é discreta [Tomazella e Nagano, 2020].

II.2.3 Otimização Multiobjetivo

Problemas de otimização multiobjetivo são aqueles que possuem mais de uma FO que podem ser de minimização ou maximização, usualmente conflitantes. Esse tipo de problema é muito comum em áreas da engenharia [Niccolai et al., 2020]. Na modelagem de problemas multiobjetivo, há a necessidade de combinar as múltiplas FO de forma que o modelo possa ser implementado e resolvido.

Para isso, existem diferentes técnicas na literatura, das quais pode-se mencionar: (i) método da soma ponderada, e (ii) método ϵ -restrito. Utilizando-se de parâmetros combinatórios específicos, essas técnicas permitem encontrar soluções “Pareto-ótimas” (ou não dominadas) para o problema, *i.e.* o conjunto de soluções ótimas em que nenhum dos valores das FO individuais possa ser melhorado sem que algum outro seja necessariamente piorado [Brisset e Gillon, 2015].

Dessa forma, torna-se possível observar visualmente um comparativo entre as soluções não dominadas de múltiplas FO, mediante uma ferramenta conhecida como fronteira de Pareto. Um exemplo ilustrativo é apresentado na Figura II.9, na qual supõe-se que ambas as FO são de maximização. Nesse exemplo, os pontos em azul representam as soluções não dominadas que formam a fronteira de Pareto, enquanto os pontos em vermelho representam as soluções dominadas. Ao percorrer a fronteira de Pareto, percebe-se que o valor de uma das FO aumenta, enquanto que o valor da outra é, necessariamente, reduzido.

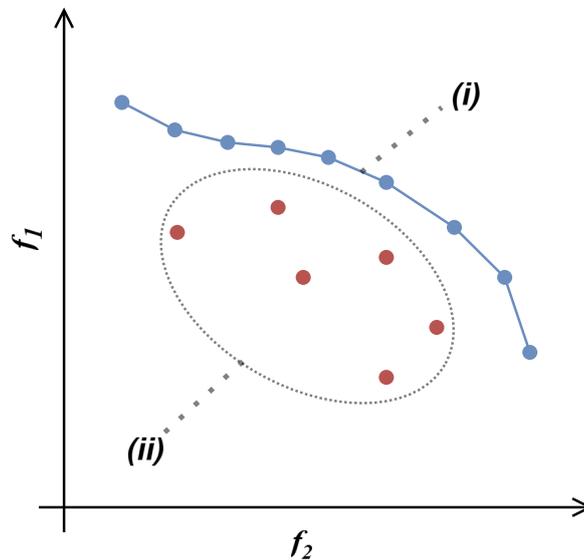


Figura II.9: Exemplo de fronteira de Pareto para duas FO de maximização onde: (i) soluções não dominadas; (ii) soluções dominadas.

O método da soma ponderada consiste em realizar a combinação linear de todos os objetivos do problema, atribuindo diferentes pesos a cada FO, o que permite definir uma importância maior ou menor a cada uma. Esses pesos são determinados manualmente com base em conhecimento prévio do problema em questão. Sendo assim, além das restrições, o modelo final é composto de uma única FO de minimização ou maximização. O maior problema desse método é justamente a definição adequada dos valores para cada peso, o que exige conhecimento aprofundado sobre o problema estudado. Uma definição imprecisa desses valores dificulta a interpretação da saída do modelo e dos devidos compromissos entre objetivos concorrentes [Wang et al., 2024]. O método da soma ponderada pode ser modelado matematicamente segundo exibido na Equação (II.6), na qual

$c(\mathbf{x})$ representa o custo, $f_i(\mathbf{x})$ representa a i -ésima FO do problema, onde $i \in \{1, \dots, m\}$, sendo m a quantidade total de FO, e λ_i os respectivos pesos para cada i -ésima FO.

$$c(\mathbf{x}) = \sum_{i=1}^m \lambda_i f_i(\mathbf{x}) \quad (\text{II.6})$$

Por sua vez, o método ϵ -restrito consiste em selecionar um dos objetivos como principal, enquanto os demais são transformados em restrições que possuem um limiar superior (se minimização) ou inferior (se maximização), representado por um parâmetro ϵ . Dessa forma, soluções Pareto-ótimas podem ser encontradas mediante parametrização do valor de ϵ para essas restrições [Niccolai et al., 2020]. Esse método apresenta vantagens sobre o método de soma ponderada por envolver todos os objetivos, permitindo investigar a compensação entre os mesmos, além de produzir soluções eficientes para problemas de PLIM. No mais, a cada nova iteração do método, normalmente uma nova solução não dominada é encontrada [Wang et al., 2024]. Um modelo matemático de acordo com o método ϵ -restrito pode ser representado conforme as Equações (II.7) - (II.11), nas quais $f_1(\mathbf{x})$ corresponde a uma das FO de minimização do problema, $f_i(\mathbf{x})$ representa a i -ésima FO mapeada em restrição, e ϵ_i indicam os limites superiores parametrizados para cada i -ésima FO exceto $f_1(\mathbf{x})$. As Equações (II.9) - (II.11) denotam as demais restrições do problema e o domínio das variáveis de decisão, respectivamente, conforme visto nas Equações (II.3) - (II.5).

$$\min f_1(\mathbf{x}) \quad (\text{II.7})$$

s.a.

$$f_i(\mathbf{x}) \leq \epsilon_i \quad \forall i \neq 1, i \in M \quad (\text{II.8})$$

$$a_i \mathbf{x} \geq b_i \quad \forall i \in M \quad (\text{II.9})$$

$$\mathbf{x}_j \geq 0 \quad \forall j \in N \quad (\text{II.10})$$

$$\mathbf{x} \in \mathbb{Z}^n \quad (\text{II.11})$$

II.3 Conceitos de Teoria de Grafos

A plena compreensão de sistemas complexos normalmente exige que sejam analisados não apenas todos os seus componentes, mas também como eles interagem entre si. Um sistema complexo pode ser abstraído para uma rede na qual cada componente é chamado nó ou vértice, e as interações diretas entre cada par de elementos é chamada aresta ou ligação. Esse tipo de abstração é uma linguagem geral que pode ser utilizada para representar diversos sistemas que diferem consideravelmente em escopo, natureza ou aparência [Barabasi e Posfai, 2016]. Matematicamente, essa representação corresponde a um grafo que pode ser definido por $G(V, A)$, onde V é um conjunto não vazio de

vértices e A um conjunto de pares ordenados $a = (v, w)$ representando as ligações ou arestas entre os nós, onde $v \in V$ e $w \in V$.

Um grafo pode ser caracterizado de diversas maneiras de acordo com a disposição de seus vértices e arestas. Quando um par de vértices possui uma aresta que os liga, esse par de componentes é dito conexo e um vértice é dito vizinho do outro. Um conjunto de vértices conexos permite que exista um caminho contíguo partindo de um vértice origem até um vértice destino. Se houver um caminho que parte de um nó origem e retorne para o mesmo nó, sem repetição de arestas, é dito que o grafo possui um laço (ligação entre elementos 1, 2 e 3 na Figura II.10a). Por outro lado, se houverem grupos de vértices distintos e não existir qualquer caminho possível entre eles, então o grafo é classificado como desconexo (Figura II.10b)

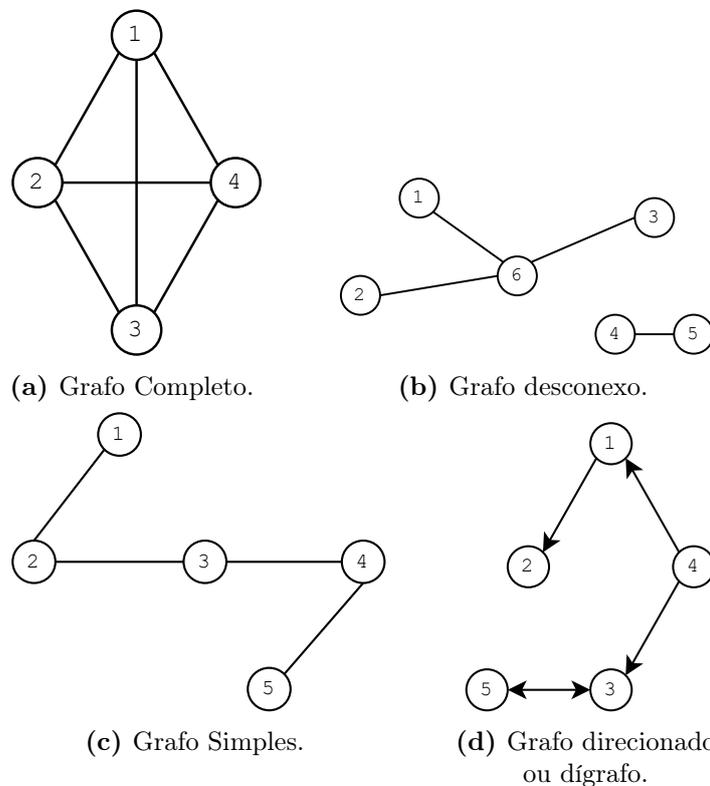


Figura II.10: Ilustrações de diferentes tipos de grafos.

Um grafo é considerado simples se ele não possui laços ou mais de uma aresta conectando o mesmo par de vértices (Figura II.10c). Quando um grafo simples apresenta cada um de seus vértices conectados a todos os demais vértices, ele é classificado como um grafo completo (Figure II.10a). Além disso, um grafo pode ser considerado direcionado ou não-direcionado, a depender dos tipos de arestas que o compõem. Caso as arestas sejam direcionadas, *i.e.* cada aresta apenas conecte vértices origem e destino através de um único sentido, então o grafo é denominado direcionado ou dígrafo (Figure II.10d). Caso o sentido não seja relevante para a abstração, então o grafo é classificado como não direcionado [Barabasi e Posfai, 2016].

II.4 Contextualização da Pesquisa

No presente trabalho buscou-se aplicar PLI para resolver o Problema de Alocação de Sensores (PAS), o qual é um problema comum em cenários de RSSF em que as posições candidatas à alocação dos nós sensores são conhecidas e fixas. Para esse problema, foi considerada a possibilidade de alocar nós sensores heterogêneos, *i.e.* com diferentes tipos de transceptores, cada qual com alcances de transmissão e consumos de energia distintos. Sendo assim, para dada instância do problema, o modelo matemático proposto deve ser capaz de determinar de forma ótima a quantidade, o tipo e o posicionamento dos nós sensores na região de interesse, considerando os seguintes objetivos: *(i)* minimizar o consumo energético da rede; e *(ii)* maximizar a área de cobertura da rede. O método de solução exato foi selecionado, a fim de proporcionar garantia de otimalidade, o que possibilita auxiliar no processo de validação.

O modelo toma como entrada as coordenadas da região de monitoramento, as posições em que os nós sensores podem ser alocados, e os tipos disponíveis para alocação. Então, retorna como saída a quantidade de nós alocados, assim como seus tipos e suas posições na região de interesse. A rede foi modelada matematicamente como um dígrafo cujos vértices são as posições candidatas a receber um nó sensor. Sendo assim, na solução, cada nó sensor alocado representa um vértice do dígrafo, e a capacidade de cada nó sensor transmitir dados para um vizinho é representada por uma aresta direcionada entre eles.

A seleção de um grafo direcionado como estrutura para representação se justifica em vista de que um nó sensor pode possuir um vizinho dentro de seu alcance de transmissão, enquanto não necessariamente pertence ao raio de alcance de transmissão desse mesmo vizinho. No mais, como a rede é formada a partir do processo de otimização, *i.e.* conforme são decididos quais nós sensores alocar na região de interesse, é necessário considerar restrições específicas na modelagem para garantir que a solução representará uma rede conexa. Para isso considerou-se que a rede está organizada em uma topologia Árvore, de modo que qualquer nó sensor da solução sempre consiga se conectar à raiz (ou sorvedouro) através de algum caminho.

Capítulo III Trabalhos Relacionados

Este capítulo apresenta uma breve revisão da literatura a respeito da área de otimização exata aplicada a topologias de RSSF, relatando trabalhos que têm relação direta com PAS. É importante frisar que a maior parte dos trabalhos publicados na área de otimização relacionadas ao PAS aborda métodos de solução heurísticos ou meta-heurísticos, por conta da alta complexidade computacional desse problema [Bhondekar et al., 2009; Balesdent e Piet-Lahanier, 2015; Thike et al., 2016; de Brito et al., 2019; Elfouly et al., 2021; Azevedo et al., 2021; de Brito et al., 2022]. Esses trabalhos não serão abordados em detalhe neste capítulo, devido a métodos não exatos não fazerem parte do escopo desta pesquisa.

No entanto, considerou-se importante destacar os principais métodos utilizados pelos autores nessa área. Bhondekar et al. [2009]; Balesdent e Piet-Lahanier [2015]; de Brito et al. [2019]; e Azevedo et al. [2021] propuseram implementações de Algoritmo Genético (AG) para solucionar os modelos propostos. Thike et al. [2016] propuseram um algoritmo de força bruta para alocação de sensores, Elfouly et al. [2021] utilizaram Colônia de Formigas (CF), e de Brito et al. [2022] utilizaram um Algoritmo Memético. A preferência por uso de meta-heurísticas ou algoritmos inspirados em processos evolutivos para explorar o espaço de soluções em problemas de otimização em RSSF pode ser explicada: *(i)* pela adaptabilidade desses algoritmos a diferentes contextos de problema; *(ii)* pela possibilidade de lidar de forma adequada com alta dimensionalidade; *(iii)* facilidade de implementação; e *(iv)* pela menor probabilidade de recair sobre ótimos locais [Singh et al., 2021].

Nas próximas seções, a metodologia de busca de trabalhos relacionados que utilizaram métodos de otimização exatos é detalhada e, na sequência, os trabalhos encontrados são listados e apresentados. Por fim, é destacado o posicionamento desta pesquisa em relação aos trabalhos relacionados da literatura, contrastando suas principais características.

III.1 Metodologia de Busca

A pesquisa bibliográfica foi iniciada a partir de dois trabalhos previamente selecionados [de Brito et al., 2019, 2022]. Essa seleção se deu por conta da temática diretamente relacionada a esta pesquisa, a saber, otimização multiobjetivo da alocação de nós sensores

heterogêneos em RSSF, dado que os referidos trabalhos apresentam propostas de meta-heurísticas para resolver um PAS com essas mesmas características. Os modelos propostos pelos autores consideram diferentes objetivos de otimização tais como área de cobertura, sobreposição, consumo energético e quantidade de nós sensores por *cluster*. Os estudos de caso foram executados com nós sensores heterogêneos distribuídos em grades de tamanhos 15×15 e 20×20 . Nesses cenários, cada nó da rede está inserido em uma posição da grade (ou seja, cada subárea quadrada da grade possui obrigatoriamente um nó sensor).

A partir dos referidos trabalhos, foram realizados os procedimentos de *forward* e *backward snowballing* [Wohlin, 2014], visando encontrar outros trabalhos relevantes relacionados ao tema de otimização de topologia de RSSF. Os processos foram realizados em dois níveis: uma vez para cada artigo inicial; e então uma segunda vez para cada artigo encontrado durante as primeiras buscas. Os resultados encontrados foram filtrados, considerando-se apenas os trabalhos publicados nos últimos 15 anos (2009-2024), e restringindo-se a trabalhos que utilizaram métodos de solução exatos, de forma que fosse possível realizar uma comparação direta entre as características dos trabalhos encontrados e a abordagem desta pesquisa. Ao fim do processo de *snowballing*, foi consolidada uma lista de 7 trabalhos relacionados relevantes, *i.e.* que atendem aos filtros selecionados. Esses trabalhos são apresentados na seção a seguir.

III.2 Resultados da Busca

Nesta seção são detalhados os resultados mais relevantes da pesquisa bibliográfica. Os artigos estão apresentados em ordem cronológica. A Tabela III.1 destaca as principais características de cada trabalho encontrado.

Tabela III.1: Características dos principais trabalhos relacionados.

Nº	Referência	Objetivo(s)	Modelo(s)	Solver	Topologia	Tamanho máximo da rede*
1	Peng et al. [2009]	Min. consumo de energia	PLIM	LINGO	Linear	100 nós
2	Pinheiro et al. [2013]	Min. consumo de energia	PLI	CPLEX	Árvore	36 nós
3	Alduraibi et al. [2016]	Max. área de cobertura	PLI e PLIM	SCIP	Linear	6 nós
4	Fellah e Kechar [2017]	Min. consumo de energia	PLIM	CPLEX	Grade	40 nós
5	Nguyen et al. [2019]	Max. área de cobertura	PLI	CPLEX	Árvore	600 nós
6	Tam et al. [2019]	Min. consumo de energia	PLIM	CBC	Árvore	400 nós
7	Pinheiro et al. [2022]	Min. consumo de energia e max. área de cobertura	PLI	CPLEX	Árvore	180 nós

*Entre todos os experimentos realizados.

Peng et al. [2009] propõem um modelo de otimização cujo objetivo consiste em maximizar o tempo de vida em uma RSSF com uma única fonte e um único sorvedouro (*Single Source and Single Sink*). Esse problema apresenta como entrada todos os nós sensores já alocados em posições específicas, e deseja-se determinar as melhores taxas de transmissão, além de técnicas de controle de acesso e roteamento de forma a garantir menor consumo energético global. Um modelo PLIM foi

proposto e o *solver* LINGO[®] foi utilizado para validação, destacando-se a diminuição do tempo de vida da rede para instâncias com maior número de nós sensores alocados, e também para aquelas cujas distâncias entre nós sensores é maior. Isso ocorre pois a topologia *Single Source and Single Sink* considerada pelos autores é baseada numa topologia Linear ou Barramento. Além disso, os autores destacam que empregar estratégias de roteamento de múltiplos saltos na camada de rede e considerar um tempo de transmissão médio na camada de enlace são cruciais para garantir maior tempo de vida total nesse tipo de rede.

Por sua vez, Pinheiro et al. [2013] propõem um modelo PLI a fim de otimizar o consumo de energia em RSSF heterogêneas. Os cenários estudados consistem em 36 nós sensores distribuídos em uma região de interesse de forma aleatória. A região é mapeada mediante pontos de interesse organizados em forma de grade. O modelo busca desativar conjuntos específicos de nós sensores de forma intercalada, mantendo o funcionamento da rede de maneira eficiente e conservando energia de nós críticos. Essa característica é importante para evitar condição de inanição na rede (*i.e.* quando a energia de alguns dos nós sensores mais utilizados se esgota mais rapidamente). No entanto, acrescenta tamanha complexidade ao modelo que acaba por limitar a aplicação a redes de pequeno porte, tal como o cenário estudado (com apenas 36 nós sensores). A modelagem considera o tipo de parâmetro monitorado em um dado instante de tempo, e também as possíveis rotas para se alcançar o sorvedouro mais próximo. O modelo penaliza soluções que não monitoram todos os pontos de interesse necessários. A heterogeneidade da proposta se dá por conta de sensores distintos com variadas taxas e alcances de coleta e transmissão de dados. Os autores utilizaram linguagem Java e integração com o *solver* CPLEX[®] para validação.

Alduraibi et al. [2016] apresenta três modelos de otimização PLIM a fim de determinar a densidade ideal de nós para atingir melhor cobertura da região monitorada: (*i*) o primeiro modelo visa atingir um nível desejado de fidelidade de detecção enquanto minimiza o número de sensores implantados; (*ii*) o segundo modelo foca em maximizar a cobertura determinando a posição dos nós existentes enquanto considera uma contagem de nós restrita; e (*iii*) o terceiro modelo visa minimizar o número de nós alocados quando a fidelidade desejada não é uniforme, *i.e.* quando alguns locais requerem maior cobertura do que outros. Apesar de os autores terem considerado uma topologia Linear, as formulações de otimização propostas são genéricas, sendo portanto aplicáveis a variados cenários de aplicação. Os modelos propostos foram validados usando o *solver* SCIP, em cenários com apenas 4, 5 e 6 nós sensores.

Se assemelhando um pouco mais ao presente estudo, Fella e Kechar [2017] apresentam um modelo PLIM para minimizar o consumo energético em RSSF móveis sob restrições realísticas. As RSSF estudadas pelos autores possuem nós sensores capazes de se movimentar de acordo com necessidades específicas, alterando sua posição original e por conseguinte a configuração da

topologia física e lógica da rede, o que pode permitir alcançar maior tolerância a falhas e melhor gestão global de energia, por exemplo. O modelo também permite a coexistência entre nós sensores móveis e estáticos na rede, cada qual com uma capacidade própria de energia e com possibilidade de ajustar as potências e alcances de transmissão, o que caracteriza a RSSF em questão como heterogênea. Simulações foram realizadas utilizando parâmetros de nós sensores reais TI CC2420 e o *solver* CPLEX[®]. Os cenários simulados consideram redes com 20 a 40 nós sensores, e os resultados denotam aumento da economia de energia e maior duração de transmissão para maiores densidades de nós móveis. No mais, os autores indicam que a escalabilidade do modelo exato é questionável, devido a alta complexidade computacional, e que pretendem seguir em trabalhos futuros com soluções baseadas em heurísticas para redes maiores.

O problema de posicionar de forma ideal nós sensores e retransmissores (*relays*) a fim de garantir a cobertura adequada da região de monitoramento e a conectividade em uma RSSF com sorvedouros dinâmicos é estudado em Nguyen et al. [2019]. Os autores abordam esse duplo desafio de forma hierárquica. Primeiramente, eles formularam o problema de cobertura da região usando um modelo PLI e apresentaram um algoritmo exato para determinar a solução ideal. Em seguida, para o problema de conectividade de rede, foram propostos dois algoritmos heurísticos distintos: *(i)* um baseado no problema da árvore mínima de Steiner com objetivo de minimizar o número de nós e retransmissores alocados; e *(ii)* um algoritmo que utiliza estratégias de agrupamento e árvore de abrangência, este que se apresentou eficiente em termos de tempo computacional. A validação dos métodos propostos considerou cenários com até 550 nós sensores e 50 sorvedouros, e os resultados apresentam redução de até 10% da quantidade de nós sensores necessários para atingir a cobertura adequada da região de interesse.

Similarmente, Tam et al. [2019] apresentam um modelo PLIM a fim de obter o número mínimo de nós de retransmissão para estender a vida útil de uma RSSF. O problema foi provado ser NP-difícil por meio de uma redução para o Problema de Cobertura de Conjuntos, e dois métodos foram propostos: *(i)* uma heurística de agrupamento e *(ii)* um algoritmo exato utilizando fluxo máximo com uma formulação de custo mínimo-máximo. Os métodos propostos foram avaliados por meio de simulações em cenários com até 400 nós sensores (sendo 200 retransmissores). Os resultados dos experimentos mostraram desempenho superior em comparação aos métodos existentes na literatura. Os autores observam que trabalhos futuros devem levar em conta o alcance de comunicação de cada nó e a conexão entre nós de retransmissão e sorvedouros.

Durante o desenvolvimento do presente trabalho, foi possível realizar uma publicação referente a um modelo de PLI para resolver um PAS multiobjetivo [Pinheiro et al., 2022]. Nesse problema foi considerada uma RSSF heterogênea que suporta 3 tipos distintos de nós sensores, cada qual com uma configuração específica de consumo energético e raio de alcance de transmissão. As FO

do modelo proposto foram combinadas utilizando-se do método de soma ponderada e, para esse estudo inicial, foram realizados 180 experimentos computacionais para instâncias de redes dispostas em regiões de monitoramento de tamanho 10×10 e 15×15 . Foi possível concluir que a utilização do modelo proposto é viável para redes pequenas – por conta da alta complexidade computacional – porém foram percebidas lacunas na modelagem que não permitiam uma precisa compreensão da área de cobertura da rede na região de monitoramento, além da falta de garantia de conectividade dos nós sensores em algumas das soluções obtidas. No mais, a precisa definição dos pesos do método de soma ponderada se mostrou um desafio, o que indicou que poderiam haver ganhos na substituição desse método pelo ϵ -restrito na continuação desse trabalho.

III.3 Análise comparativa

A partir da análise dos trabalhos encontrados, foi possível realizar uma comparação com o proposto nesta pesquisa, a fim de identificar claramente suas contribuições perante a literatura. A Tabela III.2 destaca essas informações, com foco nas características inerentes a cada problema abordado e aos métodos de solução propostos. São destacados: *(i)* a utilização de métodos de otimização multiobjetivo; *(ii)* a consideração de heterogeneidade no modelo da RSSF; *(iii)* a utilização de parâmetros de nós sensores reais; *(iv)* a possibilidade do modelo alocar os sorvedouros da rede; *(v)* e os tamanhos das redes utilizadas nos experimentos computacionais.

Tabela III.2: Análise comparativa entre esta pesquisa e seus principais trabalhos relacionados.

Nº	Referência	Multiobjetivo	Rede(s) Heterogênea(s)	Parâmetros de nós sensores reais	Alocação de sorvedouro(s)	Rede(s) pequena(s)*	Rede(s) média(s)**	Rede(s) grande(s)***
1	Peng et al. [2009]	✗	✗	✓	✗	✓	✓	✗
2	Pinheiro et al. [2013]	✗	✓	✗	✗	✓	✗	✗
3	Alduraibi et al. [2016]	✗	✗	✗	✗	✓	✗	✗
4	Fellah e Kechar [2017]	✗	✓	✓	✓	✓	✗	✗
5	Nguyen et al. [2019]	✗	✗	✗	✗	✓	✓	✓
6	Tam et al. [2019]	✗	✗	✗	✗	✓	✓	✗
7	Pinheiro et al. [2022]	✓	✓	✗	✓	✓	✓	✗
8	Esta Pesquisa	✓	✓	✓	✓	✓	✓	✗

* Cenário experimental com menos de 50 nós.

** Cenário experimental com entre 50 e 500 nós.

*** Cenário experimental com mais de 500 nós.

Em contraste a esta pesquisa, que considera a organização da RSSF numa topologia em Árvore – que garante maior flexibilidade para roteamento e tolerância a falhas – Peng et al. [2009] considera uma topologia Linear, o que restringe a aplicação de seu modelo a problemas específicos como monitoramento de sistemas de dutos, por exemplo. Além disso, seu modelo matemático considera um problema de objetivo único, ao contrário deste trabalho que considera um PAS multiobjetivo. Por sua vez, Pinheiro et al. [2013] diverge desta pesquisa por não considerar otimização multiobjetivo e também devido aos nós sensores operarem de forma intercalada ao longo do tempo de vida da rede, de forma a alcançar assim maior economia de energia. Na sequência, os autores em Alduraibi et al. [2016] tratam também de otimização de uma topologia Linear, além de considerarem apenas

redes pequenas em sua validação experimental. Por outro lado, Fella e Kechar [2017] é o trabalho que mais se aproxima das características desta pesquisa, se diferindo apenas por não considerar otimização multiobjetivo e redes de médio porte.

Além disso, Nguyen et al. [2019] é o trabalho que apresenta experimentos com a maior quantidade de nós sensores. Essa diferença é justificada por conta da combinação de métodos heurísticos e exatos por parte dos autores. No mais, o trabalho não leva em consideração a formulação multiobjetivo do problema, a utilização de heterogeneidade na rede, o uso de parâmetros de nós sensores reais, ou mesmo possibilita alocação de sorvedouros, estando estes previamente determinados em cada cenário. De forma similar, Tam et al. [2019] também não abordam os aspectos supracitados e utilizam uma combinação de métodos heurísticos e exatos para propor soluções em redes de maior escala. Por fim, é importante destacar que o presente trabalho contribui para aprimorar o modelo originalmente proposto em Pinheiro et al. [2022]: *(i)* ao corrigir problemas no modelo referentes a conectividade e cobertura; *(ii)* ao utilizar o método de otimização multiobjetivo ϵ -restrito em substituição ao método da soma ponderada; e *(iii)* ao considerar a possibilidade de utilização de dados de transceptores reais – o que favorece a utilização do modelo proposto em futuras implementações práticas.

A partir dos trabalhos investigados, percebe-se que um grande desafio na área de otimização de topologias de RSSF consiste em lidar com a alta complexidade computacional inerente aos problemas de otimização combinatória tal como o PAS, principalmente quando são considerados nós sensores heterogêneos e redes de média a grande escala. Essas dificuldades são usualmente contornadas com métodos heurísticos ou meta-heurísticos, que fornecem soluções aceitáveis para cada cenário avaliado, apesar de não fornecerem resultados que sejam comprovadamente ótimos globais. Mesmo nesses casos, é evidente que a elaboração e consequente validação de um modelo matemático preciso é de suma importância para embasar os estudos na área, o que justifica o objetivo principal desta pesquisa.

Capítulo IV Metodologia de Solução para o Problema de Alocação de Sensores

Neste Capítulo é apresentada a definição detalhada do PAS em estudo, assim como a modelagem matemática proposta para solucionar o referido problema. Os dados de entrada e saída esperados para o modelo também são apresentados, tal como o método de validação utilizado. É importante frisar que o modelo apresentado neste capítulo é uma extensão do trabalho inicial Pinheiro et al. [2022], cujo modelo apresentava duas limitações: *(i)* lacunas nas restrições que permitiam soluções com redes desconexas; e *(ii)* definição imprecisa da área de cobertura alcançada pela rede. O modelo vigente resolve os problemas elencados, além de considerar o método de otimização multiobjetivo ϵ -restrito e possibilitar o uso de dados de nós sensores reais como entrada – o que denota a sua aplicabilidade para auxiliar em projetos reais de RSSF.

IV.1 Descrição do Problema de Alocação de Sensores

Considerando a necessidade de instalação de uma RSSF sobre uma região plana de dimensões $w \times h$ para fins de monitoramento, deve-se determinar a quantidade, os tipos e o melhor posicionamento dos nós sensores que compõem essa rede a fim de obter o mínimo custo energético global, ao passo que deseja-se alcançar a máxima área de cobertura da região. Existem n posições sobre a região cujas coordenadas são conhecidas e sobre as quais os nós sensores podem ser alocados. Sabe-se que os tipos de nós sensores disponíveis para alocação se diferem apenas pelo modelo de transceptor que possuem. São considerados dados de transceptores reais como entrada, cujos modelos disponíveis para compor os nós sensores que devem ser alocados são conhecidos de antemão. Os dados relativos a alcance, taxa de transferência de dados, e consumo energético de cada modelo de transceptor podem ser observados na Tabela IV.1.

Foram selecionados dados de entrada de transceptores comerciais Digi[®] XBee[®]¹, por conta de serem vastamente utilizados em projetos de IdC [Nagashima et al., 2015; Ferreira et al., 2019], e também devido à facilidade de obtenção dos dados necessários para a modelagem do problema a partir dos *datasheets* oficiais [Digi International Inc., 2022]. Considera-se que os transceptores são equipados com antenas omnidirecionais e sabe-se que ambos os modelos selecionados são

¹www.digi.com

Tabela IV.1: Dados do problema, obtidos dos *datasheets* de transceptores comerciais [Digi International Inc., 2022].

Dados	Modelo de transceptor (t)	
	XBee [®] S2C (1)	XBee [®] S2C Pro (2)
Alcance máximo teórico (R^t)	1200 <i>m</i>	3200 <i>m</i>
Taxa de transferência máxima (T_R^t)	250 <i>kbps</i>	250 <i>kbps</i>
Corrente consumida TX (J_{TX}^t)	33 <i>mA</i>	120 <i>mA</i>
Corrente consumida RX (J_{RX}^t)	28 <i>mA</i>	31 <i>mA</i>
Corrente consumida em hibernação (J_{SLP}^t)	0,9 μA	0,9 μA

compatíveis, *i.e.* conseguem se intercomunicar.

Além disso, as seguintes restrições foram consideradas:

1. Em cada uma das n posições conhecidas da região, apenas um modelo de transceptor pode ser alocado.
2. É definido um limite inferior para a quantidade de transceptores que serão alocados na rede. Considerando toda a região, devem ser alocados no mínimo dois (um par) ou 5% das n posições disponíveis, o que for maior. Essa definição garante a obtenção de soluções que sejam redes viáveis, de um ponto de vista prático.
3. Não deve ocorrer alocação de transceptores que não consigam se comunicar com nenhum vizinho.
4. Deve haver maior dispersão possível de transceptores na região, de forma a alcançar maior cobertura, ao passo que deve-se minimizar o consumo energético global da rede.

IV.2 Formulação Matemática

Esta seção apresenta o modelo proposto para solucionar o PAS. De forma a propiciar maior clareza, optou-se por organizar o detalhamento da formulação matemática em duas subseções. Primeiramente é apresentado o modelo inicialmente proposto em Pinheiro et al. [2022], após ajustes de conectividade e cobertura, em sua formulação não linear. Em seguida é apresentada sua versão linear, juntamente com os ajustes realizados para aplicar o método de solução multiobjetivo ϵ -restrito. Ao apresentar o modelo não linear, são esclarecidas as FO, variáveis de decisão, restrições, e constantes presentes no modelo, assim como os dados de entrada e saída.

IV.2.1 Modelo de Programação Não Linear Inteira (PNLI)

Nesta seção, é apresentada a versão não linear do modelo proposto. São explicadas as FO, variáveis de decisão, restrições e constantes, assim como outras definições necessárias para compreensão da formulação matemática.

A RSSF para o PAS descrito na Seção IV.1 pode ser representada por um grafo simples, conexo e direcionado $G(V, A)$, no qual cada vértice $i \in V$ representa um transceptor alocado, e cada aresta $(i, j) \in A$ representa a possibilidade de um nó i se comunicar com um nó $j \neq i$. Pretende-se determinar a quantidade, o posicionamento e quais modelos de transceptor alocar, destacando suas respectivas posições na região de monitoramento. Os transceptores disponíveis para alocação podem ser selecionados dentre os tipos $t \in S = \{1, 2\}$, segundo os modelos elencados na Tabela IV.1. No modelo proposto, o conjunto de variáveis de decisão pode ser definido conforme apresentado nas Equações (IV.1) - (IV.6). Todas as variáveis de decisão do modelo são binárias, exceto por $\mathbf{L}_i \forall i \in V$ (IV.4) que tem domínio inteiro.

A variável \mathbf{s}_i^t (IV.1) representa o estado de alocação de um transceptor do tipo $t \in S$ em uma posição $i \in V$ da região de monitoramento, enquanto que \mathbf{P}_{ij}^{tu} (IV.2) representa o simultâneo estado de alocação de dois transceptores de tipos não necessariamente iguais $t \in S$ e $u \in S$, nas posições de alocação $i \in V$ e $j \in V$ da região, respectivamente. A variável \mathbf{a}_{ij}^{tu} (IV.3) denota as arestas direcionadas do grafo (que representam as conexões entre os transceptores t e u respectivamente alocados nas posições i e j), enquanto a variável \mathbf{L}_i (IV.4) representa o nível dos nós na hierarquia da rede, que é organizada em uma topologia Árvore. Dessa forma, quanto menor o nível \mathbf{L}_i dentre os inteiros positivos, mais próximo da raiz da árvore está o nó i , sendo que um valor $\mathbf{L}_i \leq 0$ denota que o ponto i da região não recebeu nenhum transceptor na solução. No mais, é importante citar que $\mathbf{L}_0 = 1$ ($i = 0$) representa o nível de um nó raiz artificial da rede. Esse nó artificial não possui coordenadas fixas na região, e é utilizado para garantir a conectividade dos demais nós a uma única árvore formada na solução. Dessa forma, um dos nós alocados na solução se tornará o sorvedouro da RSSF ao estar diretamente conectado ao nó artificial $i = 0$, que é a raiz da árvore.

No mais, \mathbf{q}_{ik}^t (IV.5) e \mathbf{Q}_k (IV.6) são as variáveis que representam a cobertura dos pontos de interesse na região de monitoramento, *i.e.* os pontos da região que devem ser alcançados pelo raio de transmissão dos transceptores alocados. A variável \mathbf{q}_{ik}^t representa o estado de cobertura de um ponto de interesse k pelo raio de alcance de transmissão de um transceptor tipo t alocado na posição i , ao passo que \mathbf{Q}_k representa a cobertura do mesmo ponto de interesse k pelo raio de alcance de transmissão de ao menos um transceptor alocado. Dessa forma, $\sum_{k \in K} \mathbf{Q}_k$ representa a quantidade total de pontos de interesse cobertos na região de monitoramento.

$$\mathbf{s}_i^t = \begin{cases} 1, & \text{se um transceptor do tipo } t \text{ está alocado na } i\text{-ésima posição da região;} \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.1})$$

$$\mathbf{P}_{ij}^{tu} = \begin{cases} 1, & \text{se transceptores do tipo } t \text{ e } u \text{ foram alocados nas posições } i \text{ e } j, \\ & \text{respectivamente;} \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.2})$$

$$\mathbf{a}_{ij}^{tu} = \begin{cases} 1, & \text{se a aresta direcionada } (i,j) \text{ pertence à árvore que conecta todos os nós} \\ & \text{ativos ao nó raiz artificial } 0; \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.3})$$

$$\mathbf{L}_i (\in \mathbb{Z}) \begin{cases} \geq 2, & \text{se a posição } i \text{ da região recebeu um transceptor;} \\ = 1, & \text{se } i = 0, \text{ i.e. } i \text{ corresponde ao nó raiz artificial } 0; \\ \leq 0, & \text{se a posição } i \text{ não recebeu nenhum transceptor.} \end{cases} \quad (\text{IV.4})$$

$$\mathbf{q}_{ik}^t = \begin{cases} 1, & \text{se o } k\text{-ésimo ponto de interesse da região está dentro do raio de alcance} \\ & \text{de transmissão do transceptor } t \text{ alocado em } i; \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.5})$$

$$\mathbf{Q}_k = \begin{cases} 1, & \text{se o } k\text{-ésimo ponto de interesse da região está dentro do raio de alcance} \\ & \text{de transmissão de ao menos um transceptor;} \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.6})$$

Considerando as variáveis de decisão definidas e as premissas da descrição do problema, o PAS em questão pode ser modelado matematicamente como um problema de PNLI, representado pelas Equações (IV.7) - (IV.46), das quais (IV.7) e (IV.8) definem as FO, (IV.9) - (IV.24) apresentam as restrições, (IV.25) - (IV.30) os domínios das variáveis de decisão, e (IV.31) - (IV.46) representam as definições de termos, conjuntos e constantes.

$$\min I(\mathbf{s}_i^t) = \min \sum_{i \in V} \sum_{t \in S} J^t \mathbf{s}_i^t \quad (\text{IV.7})$$

$$\max C(\mathbf{Q}_k) = \max \sum_{k \in K} \mathbf{Q}_k \quad (\text{IV.8})$$

s.a.

$$\sum_{t \in S} \mathbf{s}_i^t \leq 1 \quad \forall i \in V \quad (\text{IV.9})$$

$$\sum_{i \in V} \sum_{t \in S} \mathbf{s}_i^t \geq \max(2, \lceil 0,05n \rceil) \quad (\text{IV.10})$$

$$\mathbf{s}_i^t \leq |N_i^t| - 1 \quad \forall i \in V, t \in S \quad (\text{IV.11})$$

$$\mathbf{P}_{ij}^{tu} = \mathbf{s}_i^t \mathbf{s}_j^u \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.12})$$

$$\mathbf{a}_{ii}^{tu} = 0 \quad \forall i \in V, t \in S, u \in S \quad (\text{IV.13})$$

$$\mathbf{a}_{ij}^{tu} = 0 \quad \forall i \in V, j \in V \setminus N_i^t, t \in S, u \in S \quad (\text{IV.14})$$

$$\mathbf{a}_{ij}^{tu} \leq \mathbf{P}_{ij}^{tu} \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.15})$$

$$\mathbf{a}_{i0}^{tu} \leq \mathbf{s}_i^t \quad \forall i \in V, t \in S, u \in S \quad (\text{IV.16})$$

$$\sum_{j \in N_i^t} \sum_{t \in S} \sum_{u \in S} \mathbf{a}_{ij}^{tu} = \sum_{t \in S} \mathbf{s}_i^t \quad \forall i \in V \quad (\text{IV.17})$$

$$\sum_{i \in V} \sum_{t \in S} \sum_{u \in S} \mathbf{a}_{i0}^{tu} = 1 \quad (\text{IV.18})$$

$$\mathbf{L}_i \geq \mathbf{L}_j + \mathbf{a}_{ij}^{tu} - n(1 - \mathbf{a}_{ij}^{tu}) \quad \forall i \in V, j \in N_i^t, t \in S, u \in S \quad (\text{IV.19})$$

$$\mathbf{L}_i \leq \left(\sum_{t \in S} \mathbf{s}_i^t \right) n - \left(1 - \sum_{t \in S} \mathbf{s}_i^t \right) \quad \forall i \in V \quad (\text{IV.20})$$

$$\mathbf{L}_0 = 1 \quad (\text{IV.21})$$

$$\mathbf{q}_{ik}^t = \mathbf{s}_i^t \quad \forall \Delta_{ik} \leq R^t, i \in V, t \in S, k \in K \quad (\text{IV.22})$$

$$\mathbf{q}_{ik}^t = 0 \quad \forall \Delta_{ik} > R^t, i \in V, t \in S, k \in K \quad (\text{IV.23})$$

$$\mathbf{Q}_k = \min\left(1, \sum_{i \in V} \sum_{t \in S} \mathbf{q}_{ik}^t\right) \quad \forall k \in K \quad (\text{IV.24})$$

$$\mathbf{s}_i^t \in \{0, 1\} \quad \forall i \in V, \forall t \in S \quad (\text{IV.25})$$

$$\mathbf{P}_{ij}^{tu} \in \{0, 1\} \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.26})$$

$$\mathbf{a}_{ij}^{tu} \in \{0, 1\} \quad \forall i \in V, j \in V_0, t \in S, u \in S \quad (\text{IV.27})$$

$$\mathbf{L}_i \in \mathbb{Z} \quad \forall i \in V_0 \quad (\text{IV.28})$$

$$\mathbf{q}_{ik}^t \in \{0, 1\} \quad \forall i \in V, t \in S, k \in K \quad (\text{IV.29})$$

$$\mathbf{Q}_k \in \{0, 1\} \quad \forall k \in K \quad (\text{IV.30})$$

Onde:

$$V = \{i \in \mathbb{Z}^{*+} \mid 1 \leq i \leq n\} \quad (\text{IV.31})$$

$$V_0 = V \cup 0 \quad (\text{IV.32})$$

$$K = \{k \in \mathbb{Z}^{*+} \mid 1 \leq k \leq (w \times h)\} \quad (\text{IV.33})$$

$$d_{ij} = Z \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad \forall i \in V, j \in V \quad (\text{IV.34})$$

$$\Delta_{ik} = Z \sqrt{(x_i - x_k)^2 + (y_i - y_k)^2} \quad \forall i \in V, k \in K \quad (\text{IV.35})$$

$$N_i^t = \{j \in V \mid j \neq i, d_{ij} \leq R^t\} \cup 0 \quad \forall i \in V, t \in S \quad (\text{IV.36})$$

$$T_{TX}^t = \frac{8B}{T_{MAX}^t} \quad \forall t \in S \quad (\text{IV.37})$$

$$T_C^t = \frac{T_{TX}^t + T_{RX}^t}{D_C} \quad \forall t \in S \quad (\text{IV.38})$$

$$T_{SLP}^t = T_C^t - T_{TX}^t - T_{RX}^t \quad \forall t \in S \quad (\text{IV.39})$$

$$J^t = \frac{(J_{TX}^t T_{TX}^t + J_{RX}^t T_{RX}^t + J_{SLP}^t T_{SLP}^t)}{T_C^t} \quad \forall t \in S \quad (\text{IV.40})$$

Sendo constantes:

$$n \in \mathbb{Z}^{*+}, B \in \mathbb{Z}^{*+}, D_C \in (0, 1], Z \in \mathbb{R}^{*+}, w \in \mathbb{Z}^{*+}, h \in \mathbb{Z}^{*+} \quad (\text{IV.41})$$

$$\{T_C^t, T_{TX}^t, T_{RX}^t, T_{SLP}^t, J^t, J_{TX}^t, J_{RX}^t, J_{SLP}^t, R^t\} \in \mathbb{R}^+ \quad \forall t \in S \quad (\text{IV.42})$$

$$x_i \in \mathbb{Z}^+ \mid 0 \leq x_i < w \quad \forall i \in V \quad (\text{IV.43})$$

$$y_i \in \mathbb{Z}^+ \mid 0 \leq y_i < h \quad \forall i \in V \quad (\text{IV.44})$$

$$x_k \in \mathbb{Z}^+ \mid 0 \leq x_k < w \quad \forall k \in K \quad (\text{IV.45})$$

$$y_k \in \mathbb{Z}^+ \mid 0 \leq y_k < h \quad \forall k \in K \quad (\text{IV.46})$$

Funções Objetivo

As FO estão em função das variáveis de decisão \mathbf{s}_i^t e \mathbf{Q}_k , e são apresentadas individualmente no modelo nas Equações (IV.7) e (IV.8). A FO $I(\mathbf{s}_i^t)$ (IV.7) busca minimizar o consumo de energia da rede, onde a constante J^t (IV.40) representa o custo energético médio de um transceptor do tipo t em um ciclo de operação. A constante J^t , em mA , é calculada ao considerar a corrente consumida média de um transceptor alocado, considerando seus diferentes estados de atividade durante um ciclo de operação. Essa FO é um limitante para o posicionamento de grandes quantidades de transceptores, tendo em vista que quanto maior for o número de transceptores na rede, maior será o custo energético. Entende-se que o valor em mA representado por essa FO é apenas uma referência para o quão custosa a rede é em termos de energia, e não é uma representação que permite estimar de forma precisa o tempo de vida da rede, pois o consumo de energia ao longo do tempo e o

comportamento individual dos nós sensores não são considerados nesse modelo.

Por sua vez, a FO $C(\mathbf{Q}_k)$ (IV.8) visa obter a máxima área de cobertura da rede na região de monitoramento, em termos de pontos de interesse k . A quantidade total de pontos de interesse k que estão cobertos pela rede na solução é representada pelo somatório do conjunto de variáveis de decisão $\mathbf{Q}_k \forall k \in K$. Portanto, quanto maior a área da região de monitoramento coberta pela rede, maior será o valor da FO e vice-versa. Para computar a área de cobertura, dado que admitem-se antenas omnidirecionais no PAS, é considerado que a área de alcance de transmissão de cada transceptor é representada por um círculo com raio $R^t \forall t \in S$, estando o transceptor posicionado de forma concêntrica a esse círculo.

Restrições

O PAS foi modelado considerando que os transceptores só podem ser alocados caso possuam vizinhos também ativos. Para garantir essa restrição, foi considerada a atribuição de níveis $\mathbf{L}_i \forall i \in V$ de forma que se consiga identificar os pontos que possuem nós alocados, e que se garanta conectividade apenas entre nós origem de nível maior para nós destino de nível menor. Essa formulação pode ser compreendida analogamente como um fluxo em cascatas, e isso garante que não haverá laços na rede. Ao limitar também a quantidade de arestas na rede a $(n - 1)$, pela definição de árvore geradora, garante-se que apenas uma única rede conexa esteja presente na solução [Abdelmaguid, 2018]. Para tanto, foi considerada na formulação matemática a existência de um nó raiz artificial $i = 0$ cujo nível $\mathbf{L}_0 = 1$ é o menor entre os nós ativos. Dessa forma, o nó $i = 0$ tem a funcionalidade de um sorvedouro artificial da rede. Por conta de não possuir um posicionamento fixo na região de monitoramento, esse nó raiz artificial pertence à vizinhança de todo nó $i \in V$, o que permite que qualquer um dos nós alocados, independente de sua posição na rede, alcancem o sorvedouro artificial diretamente.

A partir dessas definições, pode-se compreender as restrições do modelo proposto para o PAS. A restrição (IV.9) garante que no máximo um modelo de transceptor pode ser alocado em cada posição disponível da região. Por sua vez, a restrição (IV.10) determina o limiar inferior referente à quantidade de transceptores a serem alocados na região, sendo igual a um par de transceptores ou 5% do total de posições candidatas n (o que for maior). A restrição (IV.11) garante que apenas posições de alocação que possuam vizinhança ativa além do nó raiz artificial $i = 0$ recebam transceptores.

A restrição (IV.12) é não linear por consistir da multiplicação de duas variáveis de decisão binárias \mathbf{s}_i^t e \mathbf{s}_j^u . Essa restrição é necessária para definir a variável de decisão \mathbf{P}_{ij}^{tu} , que representa o estado da simultânea alocação de dois transceptores de modelos t e u não necessariamente iguais, em posições distintas i e j . No mais, existem restrições que definem as relações entre diferentes nós da RSSF na forma de arestas de um grafo. A restrição (IV.13) determina que não deve existir solução

com *auto-loop*, ou seja, qualquer aresta direcionada entre um nó alocado em $i \in V$ e ele próprio. A restrição (IV.14) exige que nunca exista aresta direcionada entre $i \in V$ e $j \in V$ caso j não esteja coberto pelo raio de transmissão de um transceptor t alocado em i (i.e. $j \notin N_i^t$). A restrição (IV.15) determina que só devem existir arestas entre duas posições caso ambas possuam nós alocados, e a restrição (IV.16) indica que somente deve existir aresta partindo de qualquer posição i para o nó raiz artificial caso a posição i tenha um transceptor t alocado.

Adicionalmente, a restrição (IV.17) determina que o número total de arestas direcionadas que partem de um nó $i \in V$ para cada um de seus vizinhos $j \in N_i^t$ é sempre igual a 1. De forma similar, a restrição (IV.18) garante que apenas um nó alocado em uma posição i alcance o nó raiz artificial diretamente através de uma aresta direcionada, tornando o nó i em questão necessariamente o sorvedouro da rede. A restrição (IV.19) garante que a aresta direcionada sempre partirá de um nó $i \in V$ com nível maior que um nó j vizinho. Essas últimas duas restrições garantem que existam exatamente $(n - 1)$ arestas na rede. De forma complementar, a restrição (IV.20) garante que as posições i que não receberam nós possuam sempre um nível \mathbf{L}_i negativo, e a restrição (IV.21) garante que o nó raiz artificial $i = 0$ receba nível $\mathbf{L}_0 = 1$, que é o menor nível entre os nós alocados na rede.

No que tange a modelagem da área de cobertura, foi considerado o mapeamento da região de monitoramento em diversos pontos de interesse $k \in K$ organizados em uma grade. A restrição (IV.22) determina que um ponto de interesse k está coberto se está dentro do raio de alcance de um transceptor t alocado na posição i , enquanto (IV.23) define o caso contrário. Essa verificação é realizada a partir do cálculo da distância euclidiana Δ_{ik} entre as coordenadas (x_k, y_k) do ponto de interesse k e as coordenadas (x_i, y_i) do ponto de alocação i , considerando a escala Z dessa região (IV.35). Por sua vez, a restrição (IV.24), não linear, permite computar cada ponto de interesse k na região que esteja coberto por pelo menos um nó alocado. Dessa forma, essa restrição viabiliza contabilizar a área de cobertura total da região.

Dados do Modelo

Os dados de entrada do modelo consistem na quantidade total n de posições disponíveis na região de monitoramento que podem receber transceptores, assim como suas respectivas coordenadas geográficas $(x_i, y_i) \forall i \in V$, sendo $|V| = n$. São conhecidos também todos os pontos de interesse $k \in K$ e suas respectivas coordenadas cartesianas (x_k, y_k) , que mapeiam a região de monitoramento em uma grade. Além disso, são fornecidos ao modelo os seguintes dados referentes a cada tipo de transceptor: (i) corrente total média consumida durante um ciclo de atividade ($J^t \forall t \in S$, em mA), e (ii) raio máximo teórico de alcance da antena ($R^t \forall t \in S$, em metros). O valor de R^t foi obtido diretamente dos *datasheets* dos modelos de transceptores selecionados (Tabela IV.1).

Como o raio R^t – de cada modelo de transceptor $t \in S$ – e as coordenadas (x_i, y_i) são conhecidas

para toda posição disponível para alocação $i \in V$ da região de monitoramento, é possível calcular a distância euclidiana d_{ij} (IV.34) entre cada par de posições e determinar assim cada conjunto N_i^t (IV.36) que representa a vizinhança de i , considerando que um transceptor do tipo t está alocado nessa posição. Essa distância é calculada de acordo com uma constante $Z \in \mathbb{Z}$, que representa a escala da região de monitoramento mapeada no problema. A escala Z é definida como a distância ortogonal entre cada par de pontos de interesse $k \in K$ distribuídos em grade na região de monitoramento que sejam vizinhos diretos.

No mais, para determinar J^t , foi necessário obter o tempo gasto nas etapas de transmissão (T_{TX}^t) e recepção (T_{RX}^t) de uma carga de dados (*payload*) B – em *bytes* – e também o tempo gasto em modo de hibernação ou *sleep* (T_{SLP}^t) dentro de um ciclo de operação do transceptor t . Para isso, foi necessário estabelecer como constantes a quantidade de dados B transferida em um ciclo e o D_C , este que representa o percentual de tempo de um ciclo de operação que um nó sensor opera em estado ativo (*i.e.* com consumo de energia normal). Essas constantes, apresentadas na Tabela IV.2, foram escolhidas de acordo com a capacidade de funcionamento dos módulos transceptores Digi[®] XBee[®] [Digi International Inc., 2022].

Tabela IV.2: Valores das constantes usados nos experimentos.

Constante	Valor
B (Bytes)	16
D_C (%)	1

É importante denotar que algumas simplificações no modelo foram necessárias: por não ser possível estimar a taxa de transferência real dos modelos de transceptores escolhidos – já que isso pode depender de múltiplos fatores inerentes ao ambiente de instalação da rede – foi considerada a taxa de transferência máxima T_{MAX}^t (Tabela IV.1). Além disso, também não foi possível encontrar na documentação do fabricante o tempo total necessário para que os modelos de transceptores efetuem uma recepção completa de B bytes durante um ciclo de operação. Dessa forma assumimos que esse tempo é aproximadamente igual ao tempo necessário para uma transmissão da mesma quantidade de dados ($T_{TX}^t \approx T_{RX}^t$). Com isso, é possível calcular T_{TX}^t a partir da Equação (IV.37), e por conseguinte o tempo total de operação T^t em um ciclo a partir da Equação (IV.38). Logo, T_{SLP}^t pode ser obtido pela Equação (IV.39), e assim torna-se possível obter $J^t \forall t \in S$ (IV.40).

Saída do Modelo

Espera-se obter como saída um mapeamento bidimensional com a alocação ótima de transceptores na região em estudo, respeitando-se as restrições definidas e a escala $Z \in \mathbb{Z}$, além dos valores das FO, do gap de otimalidade e do tempo de execução. No mapeamento devem

constar a quantidade e os modelos de transceptores alocados, assim como seu posicionamento e o seu respectivo raio de transmissão, enquanto devem ser destacadas também as posições que não receberam nenhum transceptor. Deve ser possível observar todos os pontos de interesse $k \in K$, destacando os que estão dentro da área de cobertura da rede. Por fim, na solução deve haver uma única rede conexa.

IV.2.2 Modelo de Programação Linear Inteira (PLI) Multiobjetivo

Em consonância com o apresentado na Seção IV.2.1, esta seção apresenta a linearização das restrições do modelo proposto, assim como ajustes realizados para aplicar o método de otimização multiobjetivo ϵ -restrito. A restrição (IV.12) foi linearizada e substituída no modelo de acordo com o mostrado nas restrições (IV.47) - (IV.49). Similarmente, a restrição (IV.24) foi linearizada e substituída de acordo com o mostrado nas restrições (IV.50) - (IV.54). Para essa segunda linearização, foi necessária a utilização de duas variáveis de decisão binárias auxiliares \mathbf{m}_k^1 (IV.55) e \mathbf{m}_k^2 (IV.56), além de uma constante auxiliar M (IV.57) de valor suficientemente grande.

$$\mathbf{P}_{ij}^{tu} \leq \mathbf{s}_i^t \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.47})$$

$$\mathbf{P}_{ij}^{tu} \leq \mathbf{s}_j^u \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.48})$$

$$\mathbf{P}_{ij}^{tu} \geq \mathbf{s}_i^t + \mathbf{s}_j^u - 1 \quad \forall i \in V, j \in V, t \in S, u \in S \quad (\text{IV.49})$$

$$\mathbf{Q}_k \leq 1 \quad \forall k \in K \quad (\text{IV.50})$$

$$\mathbf{Q}_k \leq \sum_{i \in V} \sum_{t \in S} \mathbf{q}_{ik}^t \quad \forall k \in K \quad (\text{IV.51})$$

$$\mathbf{Q}_k \geq 1 - M \mathbf{m}_k^1 \quad \forall k \in K \quad (\text{IV.52})$$

$$\mathbf{Q}_k \geq \sum_{i \in V} \sum_{t \in S} \mathbf{q}_{ik}^t - M \mathbf{m}_k^2 \quad \forall k \in K \quad (\text{IV.53})$$

$$\mathbf{m}_k^1 + \mathbf{m}_k^2 \leq 1 \quad \forall k \in K \quad (\text{IV.54})$$

$$\mathbf{m}_k^1 \in \{0, 1\} \quad \forall k \in K \quad (\text{IV.55})$$

$$\mathbf{m}_k^2 \in \{0, 1\} \quad \forall k \in K \quad (\text{IV.56})$$

Sendo constante:

$$M \in \mathbb{Z}^{*+} \mid M \gg 0 \quad (\text{IV.57})$$

Por sua vez, para ajustar o modelo ao método de otimização multiobjetivo ϵ -restrito, foi necessário transformar uma das FO em uma restrição cujo limiar é definido por uma constante ϵ . Para isso, a FO $C(\mathbf{Q}_k)$, que busca maximizar a área de cobertura, foi selecionada. Essa função foi então reformulada como a restrição (IV.58), onde a constante ϵ determina o limite inferior para a

quantidade de pontos de interesse que devem ser cobertos.

A constante ϵ pertence ao domínio inteiro (IV.59), e é definida dentro do intervalo $[0, \sum_{k \in K} \Phi_k]$ (IV.60), onde Φ_k (IV.61) indica se um ponto de interesse k está coberto por ao menos um transceptor, considerando a hipótese de que todas as posições de alocação i da região possuem um transceptor do tipo $t = 2$ (IV.62) – que possui o maior raio de transmissão segundo os dados do problema (Tabela IV.1). Dessa forma, o valor máximo de ϵ é igual a quantidade máxima de pontos de interesse k da região que podem ser cobertos pela rede, considerando as coordenadas pré-determinadas dos pontos de alocação $i \in V$.

$$\sum_{k \in K} \mathbf{Q}_k \geq \epsilon \quad (\text{IV.58})$$

Sendo constantes:

$$\epsilon \in \mathbb{Z}^+ \quad (\text{IV.59})$$

$$\epsilon \in [0, \sum_{k \in K} \Phi_k] \quad (\text{IV.60})$$

$$\Phi_k = \min(1, \sum_{i \in V} \phi_k^i) \quad \forall k \in K \quad (\text{IV.61})$$

$$\phi_k^i = \begin{cases} 1, & \text{se o ponto de interesse } k \text{ está coberto por um transceptor, o qual está} \\ & \text{hipoteticamente alocado na posição } i, \text{ supondo que todos os pontos } i \in V \\ & \text{possuem um transceptor alocado cujo raio de alcance de transmissão seja} \\ & \text{o maior possível;} \\ 0, & \text{caso contrário.} \end{cases} \quad (\text{IV.62})$$

IV.3 Geração das Instâncias e Validação do Modelo

De forma a validar o modelo proposto, foi escolhido utilizar um *solver* para implementar e executar o modelo linearizado, visando encontrar soluções ótimas para cenários variados gerados aleatoriamente. Mediante análise da qualidade das soluções encontradas, buscou-se avaliar se o modelo representa fielmente o PAS em estudo e se pode ser utilizado para auxiliar no planejamento de implantação de RSSF heterogêneas reais. Para isso, um estudo de caso multiobjetivo foi realizado, levando em conta também o tempo computacional para cada cenário.

Para o processo de validação, inicialmente foram geradas aleatoriamente instâncias bidimensionais de regiões de monitoramento de tamanhos quadrados de lado $w = h = \{10, 15, 20\}$, com escala $Z = 800m$, que é referente a 1/4 do maior valor de alcance de transmissão teórico (R^2),

de acordo com a Tabela IV.1. Esse valor de Z foi selecionado de forma a haver coerência entre os raios de transmissão dos transceptores disponíveis e as dimensões da região de alocação. Cada um dos pontos de coordenadas inteiras nas áreas quadradas são considerados pontos de interesse $k \in K$ que serão observados na análise da área de cobertura da rede. Dessa forma, as instâncias de tamanho $w = h = 10$ possuem 100 pontos de interesse, por exemplo. A escala Z determina que a distância ortogonal entre cada par de pontos de interesse vizinhos na área quadrada é equivalente a 800 m, totalizando cenários com áreas de $51,84 \text{ km}^2$, $125,44 \text{ km}^2$ e $231,04 \text{ km}^2$, respectivamente.

Durante o processo de geração aleatória das instâncias foram consideradas várias densidades referente à quantidade de posições de alocação disponíveis, como $D = \{10, 20, 30, 40, 50\}\%$. A densidade representa o percentual de pontos de interesse da região de monitoramento que são considerados também como posições candidatas à alocação de nós sensores. Dessa maneira, para os cenários de tamanho $w = h = 10$ e $D = 10\%$, por exemplo, 10 dos pontos de interesse da região foram selecionados aleatoriamente como candidatos à alocação de nós, o que pode ser representado matematicamente como $n = 10$ no modelo proposto. A Figura IV.1 ilustra um exemplo de instância de tamanho 10×10 e densidade $D = 10\%$, destacando a escala Z da região. Considerando os 5 possíveis valores de densidade de posições candidatas à alocação e os 3 tamanhos distintos para as regiões de monitoramento, foram geradas aleatoriamente 15 instâncias distintas no total para este estudo.

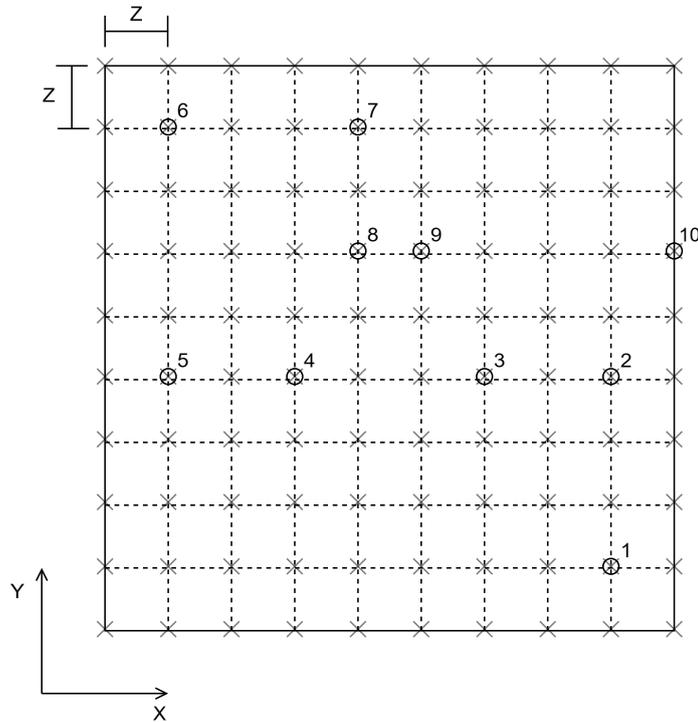


Figura IV.1: Exemplo de instância de tamanho 10×10 e $D = 10\%$.

A geração de cada instância segue o procedimento mostrado no Algoritmo 1. Nesse processo, após aplicação da escala Z na região de monitoramento (linha 2), seleciona-se um ponto inicial (linha 3). Em seguida, enquanto não se obtém n pares de coordenadas dos possíveis pontos de alocação, faz-se uma seleção aleatória de uma direção e uma distância δ a ser percorrida entre $(R^2/4)$ a R^2 (linhas 4 - 5), dado que R^2 é o raio de alcance de transmissão máximo dentre os transceptores disponíveis, de acordo com a Tabela IV.1. Se não for possível caminhar a distância sorteada na direção escolhida, partindo do ponto inicial selecionado, e ainda permanecer dentro da região (linha 6), então repete-se a seleção aleatória da direção e da distância (linhas 7 - 8) até que se consiga percorrer o caminho selecionado. Quando isso ocorrer (linha 10), as coordenadas desse novo ponto alcançado são armazenadas (linha 11) e então define-se o novo ponto como ponto de partida para a próxima iteração do algoritmo (linha 12). O processo iterativo ocorre até que seja obtido todo o conjunto de coordenadas de posições candidatas a receber um transceptor (linha 15).

Algoritmo 1 DETERMINAÇÃO DAS POSIÇÕES CANDIDATAS A ALOCAÇÃO DE TRANSCETORES.

Entrada: W, H, w, h, Z, R^2, n

Saída: Conjunto de coordenadas cartesianas das n possíveis posições de alocação

```

1 início
2   Aplicar a escala  $Z$  na área  $w \times h$ ;
3   Selecionar um ponto inicial  $Z(x_k, y_k)$  para  $k \in K$ ;
4   enquanto Não obtiver  $n$  pares de coordenadas faça
5     Selecionar aleatoriamente uma das quatro direções do plano bidimensional: cima, baixo,
6     esquerda ou direita;
7     Sortear uma distância aleatória  $\delta$  de forma que  $\delta = [(R^2/4), R^2]$ ;
8     Caminhar a distância  $\delta$  na direção sorteada e verificar as coordenadas do ponto destino;
9     se O ponto destino está fora da região quadrada então
10      | continue
11      | fim
12      | senão
13        | Armazena as coordenadas do ponto destino;
14        | Define o ponto destino como novo ponto inicial;
15        | fim
16      | fim
17   retorna Conjunto de coordenadas de pontos de alocação
18 fim

```

Para realizar a análise multiobjetivo, foi necessário considerar diferentes valores de ϵ para cada instância, de forma que se pudesse observar a qualidade das soluções em contraste com a variação dos valores de ambas as FO, através de uma aproximação da fronteira de Pareto [Mavrotas, 2009]. Sendo assim, para cada instância foi calculado um valor máximo de área de cobertura, em termos de pontos de interesse, considerando que todas as posições de alocação receberam um transceptor de maior alcance possível. Em seguida, dividiu-se esse valor máximo pelo tamanho do lado da região quadrada ($w = h$), obtendo-se assim a quantidade de valores e o passo de variação de ϵ .

Considerando um cenário de $w = h = 10$, por exemplo, caso o valor máximo de ϵ fosse calculado como 90 (o que representaria que 90% dos pontos de interesse estariam dentro da área de cobertura máxima), teriam-se 10 valores distintos de ϵ e o passo de variação de ϵ seria 9. Assim, para a primeira execução dessa instância seria considerado o valor $\epsilon = 9$, que é incrementado em 9 a cada nova iteração dessa mesma instância, até que seja executada a iteração com $\epsilon = 90$.

Capítulo V Resultados e Discussões

Este capítulo apresenta os resultados obtidos a partir da validação do modelo proposto para solucionar o PAS. O modelo foi executado no *solver* comercial Gurobi[®]¹, fazendo-se uso de uma licença acadêmica, e implementado no *framework* livre Pyomo, em linguagem Python. Para cada execução foi considerada tolerância (*gap* de otimalidade) de 0,1% e um tempo limite de 12 horas. Essa limitação de tempo foi escolhida para adequar a duração total dos experimentos ao cronograma deste trabalho, e por ser estimado suficiente para resolver instâncias de pequena e média escala (*i.e.* instâncias com até 500 posições candidatas a receber um nó sensor). Os experimentos foram executados em sequência em um *cluster* com sistema operacional Ubuntu 22.04.4 LTS, 192GB RAM e CPU Intel[®] Xeon[®] Gold 5120 CPU @ 2.20GHz com 28 núcleos físicos, dos quais o *solver* foi capaz de utilizar até 28 *threads*.

De acordo com o mostrado na Seção IV.3, sabe-se que foram geradas 15 instâncias do PAS – considerando 3 tamanhos distintos de região de monitoramento (10×10 , 15×15 e 20×20), cada qual com 5 diferentes densidades de posições candidatas à alocação de nós sensores ($D = \{10, 20, 30, 40, 50\}\%$). Para cada tamanho de instância foi considerada uma quantidade de valores de ϵ proporcional, sendo 10 valores para cada uma das instâncias de tamanho 10×10 , 15 valores para cada uma das instâncias de tamanho 15×15 , e 20 valores para cada uma das instâncias de tamanho 20×20 . A Tabela V.1 mostra todos os valores de ϵ considerados para cada instância do PAS. É importante destacar que, em alguns casos, existe diferença nos valores de ϵ para instâncias de mesmo tamanho e densidades distintas, por conta de que o valor máximo de ϵ para cada instância – que corresponde à cobertura máxima da região – depende das coordenadas das posições candidatas à alocação de nós sensores, selecionadas aleatoriamente no processo descrito na Seção IV.3.

Com isso, foram totalizados 225 experimentos computacionais, cada qual representado por uma execução do modelo com uma configuração combinada de tamanho de instância, densidade de posições candidatas à alocação, e valor de ϵ . Em cada instância, os pontos de interesse $k \in K$, que representam a área de cobertura da região de monitoramento, são espaçados de forma equidistante em um formato de grade. A distância entre esses pontos é definida mediante a escala $Z = 800m$, determinada de forma a viabilizar o uso dos modelos de transceptores selecionados para esse estudo.

¹Versão do solver: 11.0.2 build v11.0.2rc0.

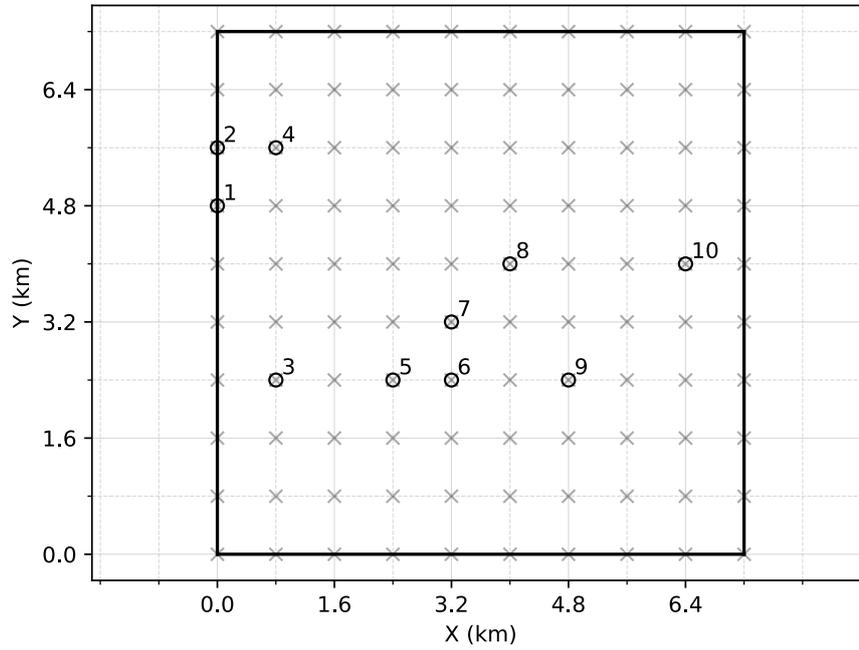
Tabela V.1: Valores de ϵ para cada instância do PAS.

Tamanho da Instância	Densidade (D)	Valores de ϵ
10 x 10	10%	9, 18, 27, 36, 45, 54, 63, 72, 81, 90
	20%	10, 20, 30, 40, 50, 60, 70, 80, 90, 100
	30%	10, 20, 30, 40, 50, 60, 70, 80, 90, 100
	40%	9, 18, 27, 36, 45, 54, 63, 72, 81, 90
	50%	10, 20, 30, 40, 50, 60, 70, 80, 90, 100
15 x 15	10%	11, 22, 33, 44, 55, 66, 77, 88, 99, 110, 121, 132, 143, 154, 165
	20%	14, 28, 42, 56, 70, 84, 98, 112, 126, 140, 154, 168, 182, 196, 210
	30%	13, 26, 39, 52, 65, 78, 91, 104, 117, 130, 143, 156, 169, 182, 195
	40%	14, 28, 42, 56, 70, 84, 98, 112, 126, 140, 154, 168, 182, 196, 210
	50%	15, 30, 45, 60, 75, 90, 105, 120, 135, 150, 165, 180, 195, 210, 225
20 x 20	10%	13, 26, 39, 52, 65, 78, 91, 104, 117, 130, 143, 156, 169, 182, 195, 208, 221, 234, 247, 260
	20%	20, 40, 60, 80, 100, 120, 140, 160, 180, 200, 220, 240, 260, 280, 300, 320, 340, 360, 380, 400
	30%	18, 36, 54, 72, 90, 108, 126, 144, 162, 180, 198, 216, 234, 252, 270, 288, 306, 324, 342, 360
	40%	20, 40, 60, 80, 100, 120, 140, 160, 180, 200, 220, 240, 260, 280, 300, 320, 340, 360, 380, 400
	50%	19, 38, 57, 76, 95, 114, 133, 152, 171, 190, 209, 228, 247, 266, 285, 304, 323, 342, 361, 380

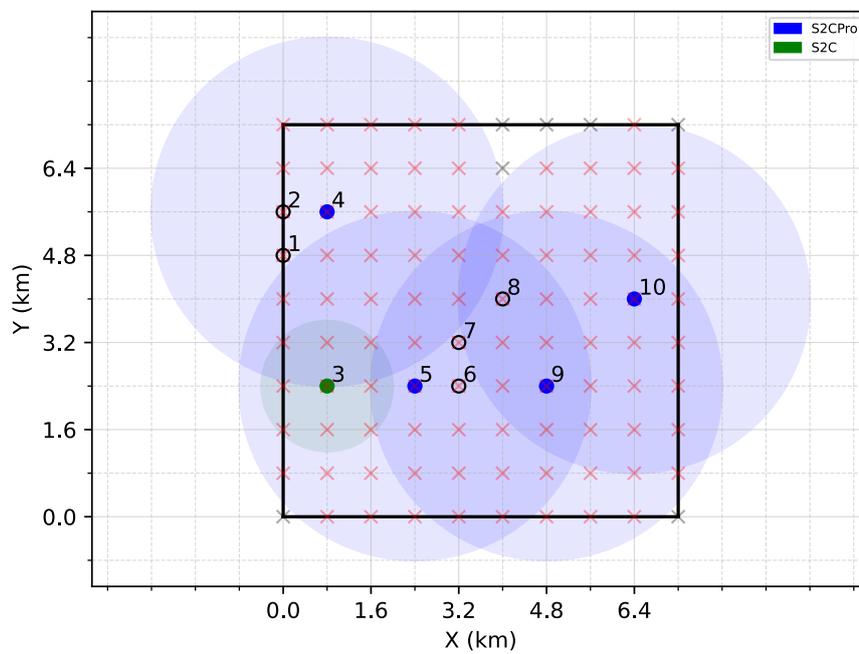
V.1 Ilustrações de Rede e Solução

Para melhor compreensão das soluções obtidas, a Figura V.1 ilustra uma instância de rede (Fig. V.1a) e sua respectiva solução (Fig. V.1b). Nessa Figura, é possível observar um exemplo de solução para uma rede com região de monitoramento de tamanho 10×10 , com 10% de densidade de nós. O valor de $\epsilon = 90$ foi utilizado na obtenção da solução apresentada. Cada ponto de interesse é representado por um símbolo “x” em cinza posicionado no interior da região, e cada circunferência representa uma posição candidata à alocação de um nó sensor (Figura V.1a). Cada par de pontos vizinhos na região está apartado a uma distância ortogonal $Z = 800$ m. Na Figura V.1b pode-se perceber os transceptores alocados (modelo S2C em verde, e modelo S2CPro em azul), com destaque para seus respectivos raios de alcance de transmissão. Além disso, os pontos de interesse cobertos pela rede estão mostrados em vermelho.

Através da análise do raio de transmissão de cada nó na Figura V.1b, pode-se perceber que a rede é conexa, de acordo com as restrições do PAS. Por se tratar do maior valor de ϵ para a respectiva instância, esse exemplo apresenta mais alocação de nós modelo S2CPro, o que configura maior consumo energético global da rede, conforme esperado. No mais, é possível notar que o nó $i = 3$ foi elencado como o sorvedouro da rede, já que é o único de modelo S2C e que, por consequência, possui o menor raio de transmissão, sendo incapaz de encaminhar dados, porém apto a receber dos nós vizinhos $i = 4$ e $i = 5$. O sorvedouro foi selecionado na solução por conta da existência do nó raiz artificial $i = 0$ na modelagem matemática, e também por conta das restrições que garantem que apenas um nó sensor alocado esteja conectado a esse nó artificial (IV.16) através de uma única aresta (IV.18).



(a) Exemplo de uma instância 10×10 para o PAS.



(b) Solução ótima encontrada para a instância mostrada na Figura V.1a.

Figura V.1: Exemplo de instância e solução do PAS com tamanho 10×10 , $D = 10\%$ e $\epsilon = 90$.

Através da Figura V.2 pode-se observar diferentes soluções para a mesma instância do PAS, as quais foram obtidas pela variação do valor de ϵ . É possível perceber a diferença tanto da quantidade quanto do posicionamento dos nós sensores na região, com destaque para os raios de transmissão dos transceptores de modelos S2C (em verde) e S2CPro (em azul). É possível verificar que quanto maior o valor de ϵ , maiores quantidades de nós sensores estão presentes na solução, e maiores são as chances de existirem transceptores do modelo S2CPro – que possuem maior alcance de transmissão e, logo, proporcionam uma maior área de cobertura da rede. Conseqüentemente, dado que transceptores S2CPro possuem também um maior consumo de energia, entende-se que quanto maior o valor de ϵ , maior será o custo energético global da RSSF. Esse compromisso entre energia e cobertura representa um dos maiores desafios de atender múltiplos objetivos contrastantes na resolução do PAS em estudo.

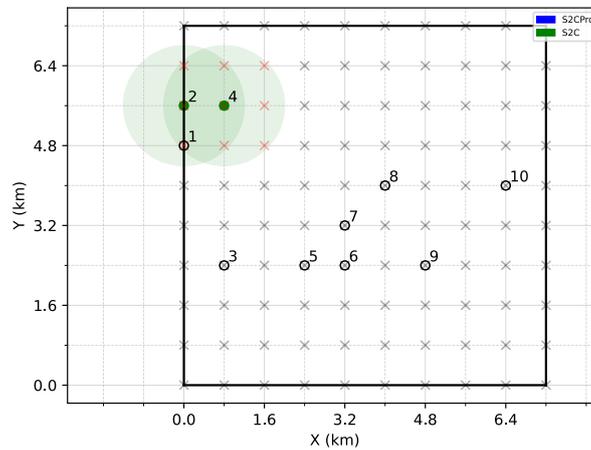
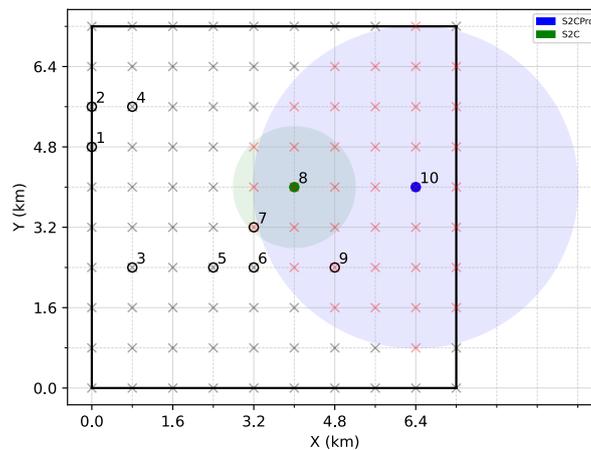
(a) $\epsilon = 9$ (b) $\epsilon = 27$

Figura V.2: Exemplo de solução do PAS para dimensões 10×10 , $D = 10\%$ e variados valores de ϵ .

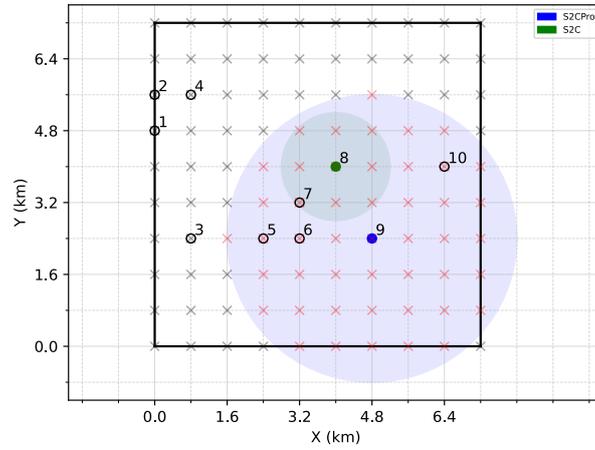
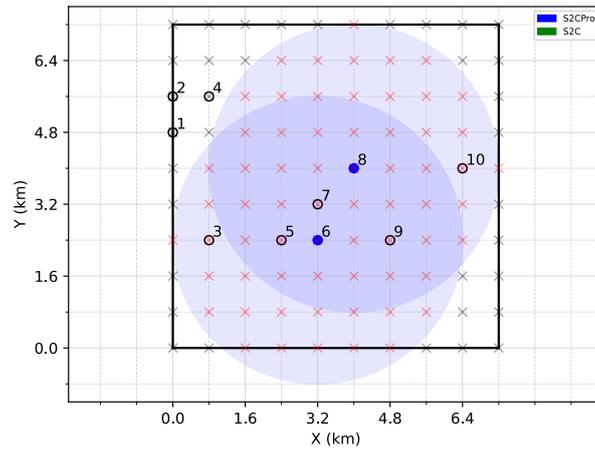
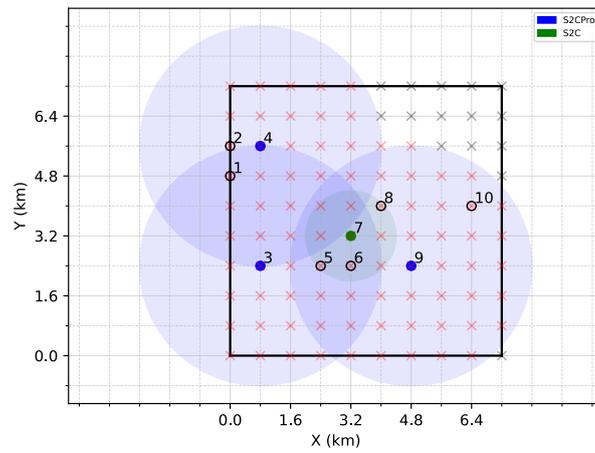
(c) $\epsilon = 45$ (d) $\epsilon = 63$ (e) $\epsilon = 81$

Figura V.2: Exemplo de solução do PAS para instância de dimensões 10×10 , $D = 10\%$ e variados valores de ϵ .

V.2 Experimentos Computacionais

Os experimentos computacionais foram realizados com o objetivo de observar se o modelo PLI proposto é capaz de produzir topologias para RSSF práticas e viáveis, garantindo a conectividade e obtendo soluções com um bom equilíbrio entre o consumo de energia e a cobertura da rede, considerando um determinado limite de tempo de execução. A Tabela V.2 lista os parâmetros utilizados e seus respectivos valores empregados nos experimentos de validação.

Tabela V.2: Parâmetros de configuração para os cenários de validação do modelo proposto.

Parâmetro	Descrição	Valores
$w = h$	Lado da região de monitoramento quadrada (em pontos)	{10 , 15 , 20}
D	Densidade de pontos de alocação de transceptores (%)	{10 , 20 , 30 , 40 , 50}
Z	Escala da área de monitoramento (em metros)	800
<i>tempo</i>	Limite máximo de tempo de execução para cada ϵ (horas)	12
<i>gap</i>	Tolerância do <i>gap</i> de otimização (%)	0,1

Conforme visto na Tabela V.1, para cada instância a sequência de valores de ϵ pode variar, o que ocorre por conta da distribuição aleatória das posições candidatas à alocação durante o processo de geração das instâncias. Por conta disso, os valores de ϵ foram omitidos da Tabela V.2. A fim de obter a faixa de valores de ϵ para cada instância, primeiramente foi calculado o valor máximo possível de ϵ , supondo que cada posição candidata à alocação possui um transceptor de máximo raio de transmissão dentre os disponíveis. O valor máximo de ϵ equivale ao máximo de pontos de interesse $k \in K$ que a rede é capaz de cobrir na região. Ao dividir o valor máximo de ϵ pelo tamanho do lado da região quadrada ($w = h$), foi possível obter um passo de incremento de valores de ϵ para a respectiva instância, segundo mostrado na Tabela V.1.

A título de exemplo, para obter a sequência de valores de ϵ para a instância gerada de tamanho 10×10 e $D = 10\%$, percebeu-se que o máximo de pontos de interesse que poderiam ser cobertos pela rede seriam 90. Com isso, dividindo-se o valor máximo de $\epsilon = 90$ pelo tamanho do lado da região quadrada ($w = h = 10$), obteve-se um passo de incremento igual a 9. Assim, para essa instância, o valor de ϵ inicial é 9, e cada valor seguinte é incrementado em 9 até alcançar o décimo e último valor da sequência (90).

Sendo assim, os experimentos foram realizados variando-se o valor de ϵ para cada configuração de instância, totalizando 225 cenários executados no *solver* Gurobi[®]. A qualidade dos resultados foi determinada com base no menor *gap* de otimalidade obtido para as maiores densidades D possíveis em cada tamanho de instância. Sendo assim, para os cenários de dimensões 10×10 e 15×15 , os melhores resultados foram os de $D = 50\%$, enquanto que para os cenários de dimensões 20×20 , os melhores resultados foram os de $D = 30\%$. Todos os melhores resultados numéricos podem ser observados nas Tabelas V.3 - V.5, nas quais os resultados que não possuem solução

comprovadamente ótima – últimos resultados encontrados até o limite de tempo – são destacados em vermelho. Nessas tabelas, os experimentos que não resultaram em nenhuma solução até o limite de tempo estão marcados com um traço “-” em vermelho. Através das Figuras V.3 - V.5 é possível observar os melhores resultados para as instâncias de tamanhos 10×10 , 15×15 e 20×20 , respectivamente. Os resultados completos (gráficos e numéricos) podem ser visualizados em detalhes no repositório público deste trabalho².

Tabela V.3: Resultados numéricos para instância de tamanho 10×10 e densidade $D = 50\%$.

Valor ϵ	Nós alocados (S2C)	Nós alocados (S2CPro)	Objetivo I	Objetivo C	Gap (%)	Tempo Solver (s)	Tempo Total (s)
10	3	0	0,9176	12	0	1,8163	6,31
20	4	0	1,2235	21	0	5,4797	9,72
30	2	1	1,3676	41	0	7,2536	11,63
40	2	1	1,3676	40	0	1,8715	6,06
50	2	1	1,3676	53	0	1,7859	5,83
60	3	1	1,6735	61	0	23,549	27,64
70	1	2	1,8176	70	0	21,4564	25,43
80	2	2	2,1235	80	0	27,0705	31,02
90	1	3	2,5735	90	0	20,1489	24,28
100	1	4	3,3894	100	0	13,735	17,87

Quantidade de posições candidatas à alocação: 50.

Variáveis binárias: 30600. Variáveis inteiras: 30652.

Total de variáveis: 30652. Total de restrições: 61055.

Tabela V.4: Resultados numéricos para instância de tamanho 15×15 e densidade $D = 50\%$.

Valor ϵ	Nós alocados (S2C)	Nós alocados (S2CPro)	Objetivo I	Objetivo C	Gap (%)	Tempo Solver (s)	Tempo Total (s)
15	6	0	1,8353	21	0	15,29	40,15
30	6	0	1,8353	30	0	12,57	37,16
45	5	1	2,2853	54	0	562,7	586,8
60	5	1	2,2853	64	0	20,64	44,54
75	2	1	2,5912	76	11,49	43200,3	43223,33
90	4	2	2,7353	90	0	19210,9	19246,41
105	4	2	2,7353	105	0	82,74	106,02
120	3	3	3,1853	138	0	25367,38	25391,21
135	3	3	3,1853	135	0	597	620,88
150	2	4	3,6353	151	0	25574,81	25597,88
165	3	4	3,9412	167	0,0816	20882,31	20904,42
180	2	5	4,3912	182	0	24025,52	24049,83
195	1	6	4,8412	195	0	10171,03	10194,87
210	3	6	5,453	210	0	3967,6	3992,83
225	-	-	-	-	-	43200	43223

Quantidade de posições candidatas à alocação: 112.

Variáveis binárias: 152099. Variáveis inteiras: 152213.

Total de variáveis: 152213. Total de restrições: 303642.

²www.github.com/LucasPinheiro23/ppcic_PLI-PAS_2024

Tabela V.5: Resultados numéricos para instância de tamanho 20×20 e densidade $D = 30\%$.

Valor ϵ	Nós alocados (S2C)	Nós alocados (S2CPro)	Objetivo I	Objetivo C	Gap (%)	Tempo Solver (s)	Tempo Total (s)
18	6	0	1,8353	20	0	15,49	67,43
36	7	0	2,1412	37	0	258,88	288,05
54	5	1	2,2853	57	0	35,11	64,02
72	5	1	2,2853	72	0	383,86	413,35
90	4	2	2,7353	90	0	17290,51	17321,14
108	4	2	2,7353	108	0	213,08	243,36
126	3	3	3,1853	127	5,92	43200	43229
144	3	3	3,1853	144	0	246,41	283,36
162	2	4	3,6353	162	0	34488	34518
180	1	5	4,0853	183	8,5	43200	43229
198	2	5	4,3912	198	5,23	43200	43235
216	2	6	5,1471	216	14,68	43200	43246
234	2	7	5,903	234	17,63	43200	43238
252	3	7	6,2089	255	14,56	43200	43237
270	3	8	6,9648	273	15,76	43200	43233
288	2	9	7,4148	289	13,59	43200	43242
306	4	10	8,7824	306	19,99	43200	43233
324	1	12	9,3765	325	16,87	43200	43233
342	2	13	10,4383	342	14,86	43200	43230
360	5	14	360	12,1119	13,11	43200	43230

Quantidade de posições candidatas à alocação: 120.

Variáveis binárias: 213120. Variáveis inteiras: 213242.

Total de variáveis: 213242. Total de restrições: 387325.

Nas Figuras V.3d, V.4d e V.5d, podem ser observadas aproximações das fronteiras de Pareto para as respectivas instâncias. Através desses gráficos, é possível comparar os valores das funções objetivo I e C conforme o valor de ϵ varia. Os valores de I indicam o consumo de energia (em mA); enquanto que C indica a cobertura da região, medida pela quantidade de pontos de interesse que estão cobertos pelo raio de alcance de transmissão dos nós sensores. Nessas figuras, os resultados comprovadamente ótimos, *i.e.* com *gap* de otimalidade abaixo do intervalo de tolerância definido na Tabela V.2, são representados como pontos azuis, enquanto os resultados que não possuem comprovação de otimalidade são representados como pontos vermelhos. O número ao lado dos pontos azuis ou vermelhos indica o valor de ϵ que gerou o respectivo resultado do compromisso entre I e C , enquanto que o valor percentual ao lado dos pontos vermelhos indica também o *gap* alcançado. Esses gráficos permitem observar o crescimento dos valores de ambas as funções objetivo conforme o valor de ϵ aumenta, o que denota a concorrência e relação de proporcionalidade (compromisso) entre as funções objetivo. Cabe ao projetista da rede selecionar um dos pontos que se adéque melhor em termos de consumo energético e cobertura.

É importante destacar que o consumo energético denotado através da corrente elétrica consumida, em mA , nas Figuras V.3d, V.4d e V.5d e nos resultados numéricos (Tabelas V.3, V.4 e V.5), é um valor de referência baseado no somatório do consumo médio de corrente dos

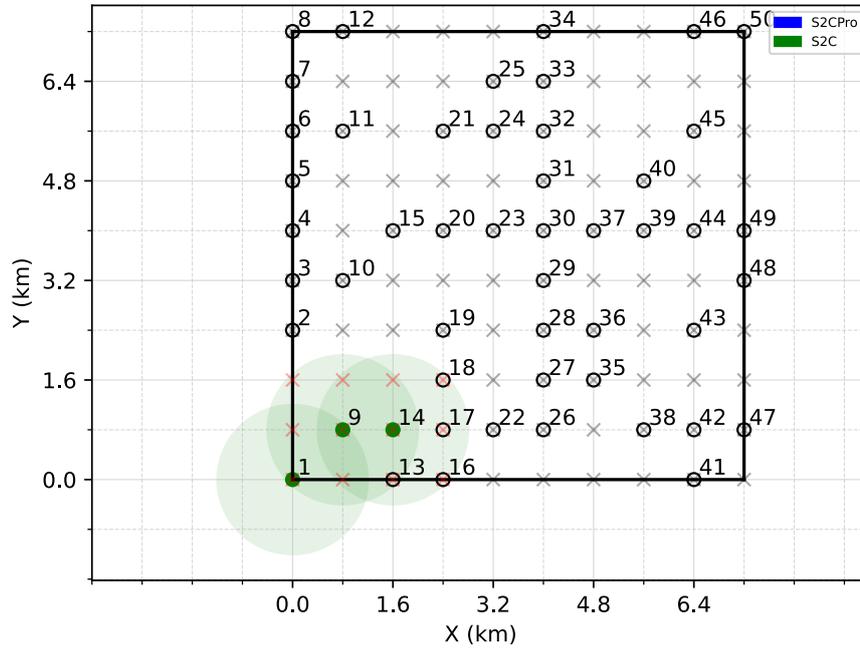
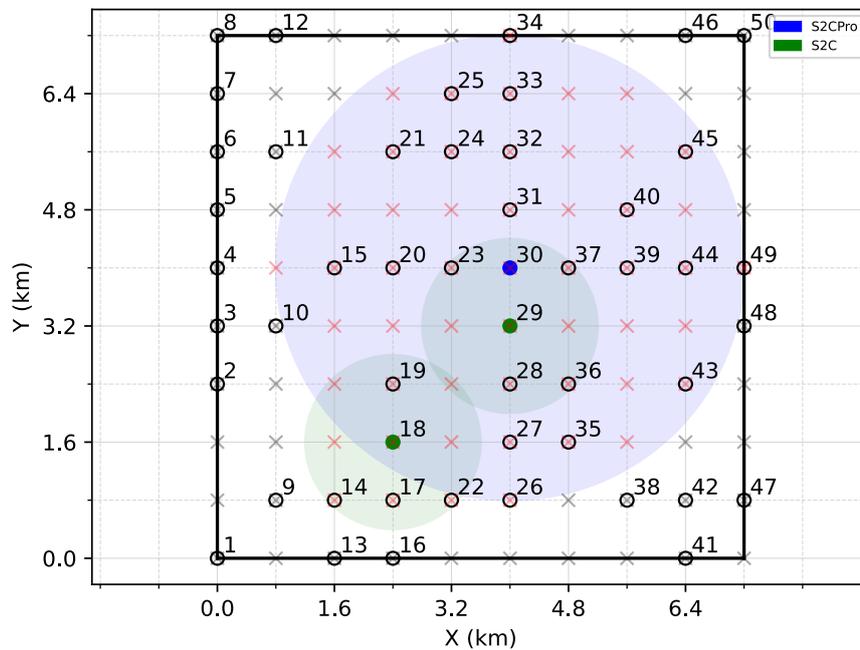
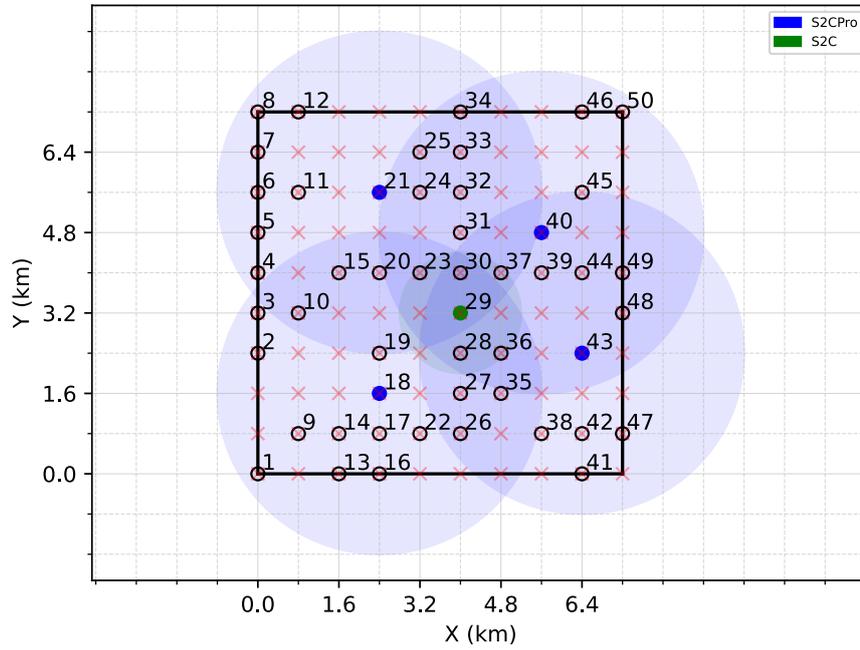
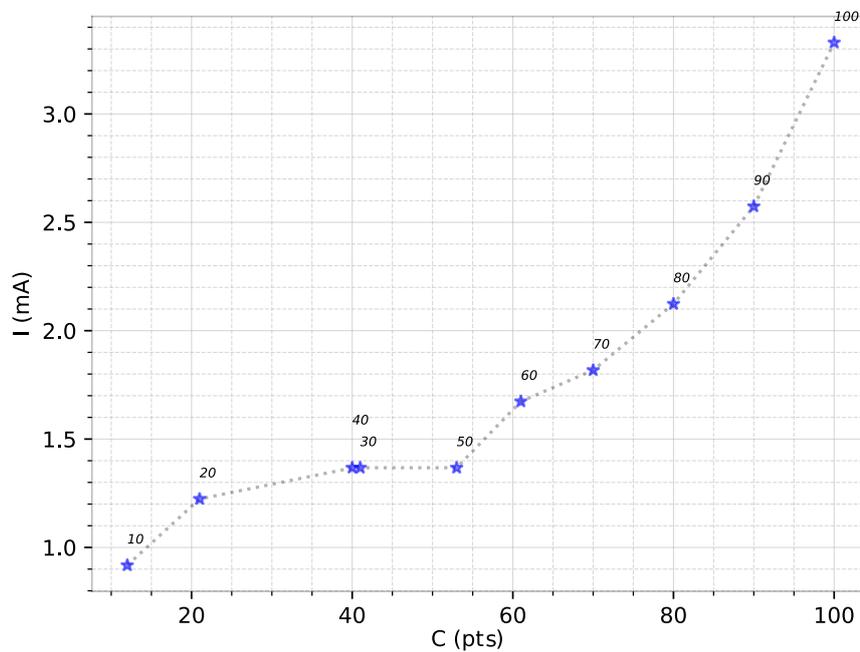
(a) $\epsilon = 10$ (b) $\epsilon = 50$

Figura V.3: Melhores resultados para instância de dimensões 10×10 e $D = 50\%$, para variados valores de ϵ .

(c) $\epsilon = 100$ 

(d) Fronteira de Pareto (aproximada)

Figura V.3: Melhores resultados para instância de dimensões 10×10 e $D = 50\%$, para variados valores de ϵ .

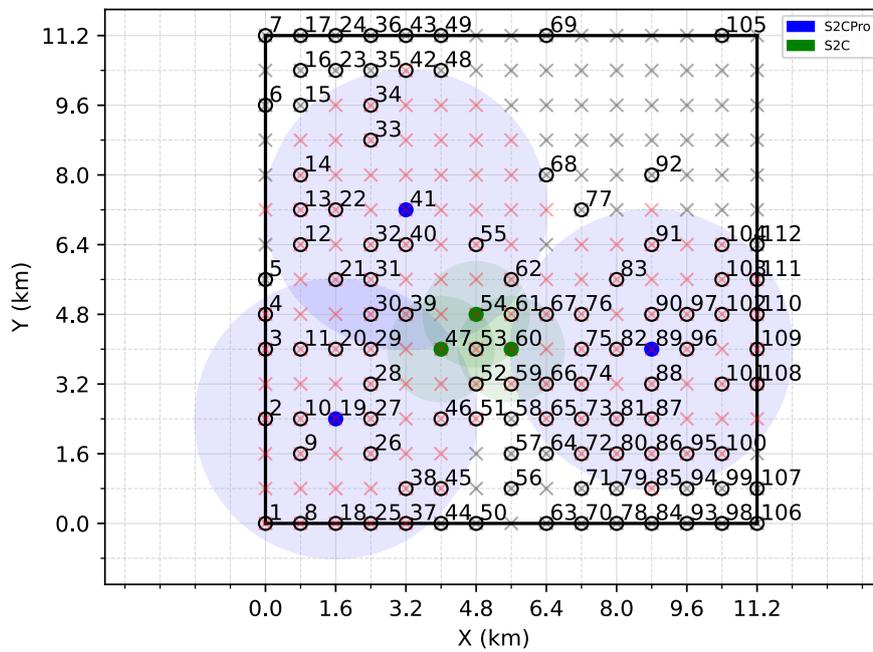
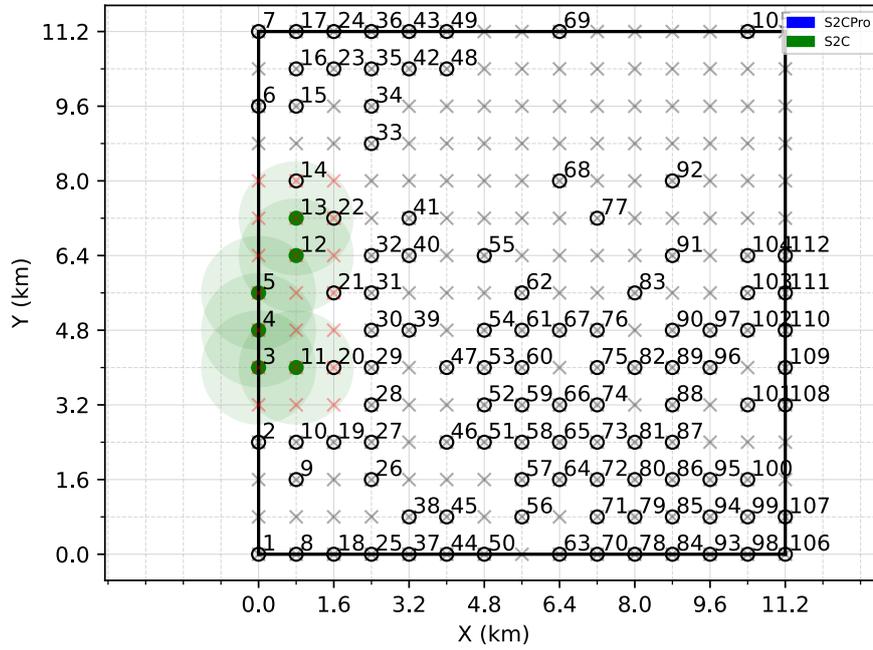
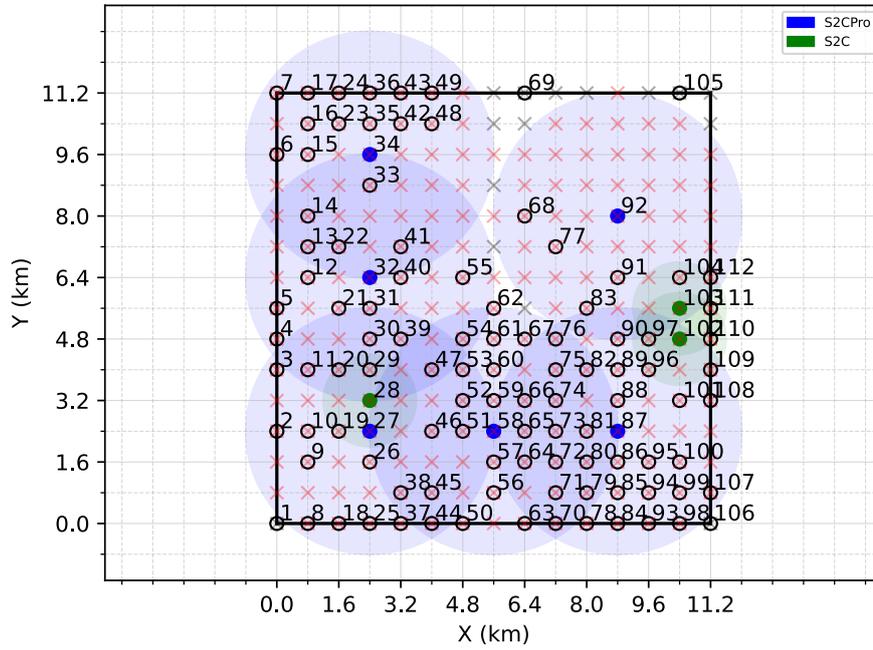
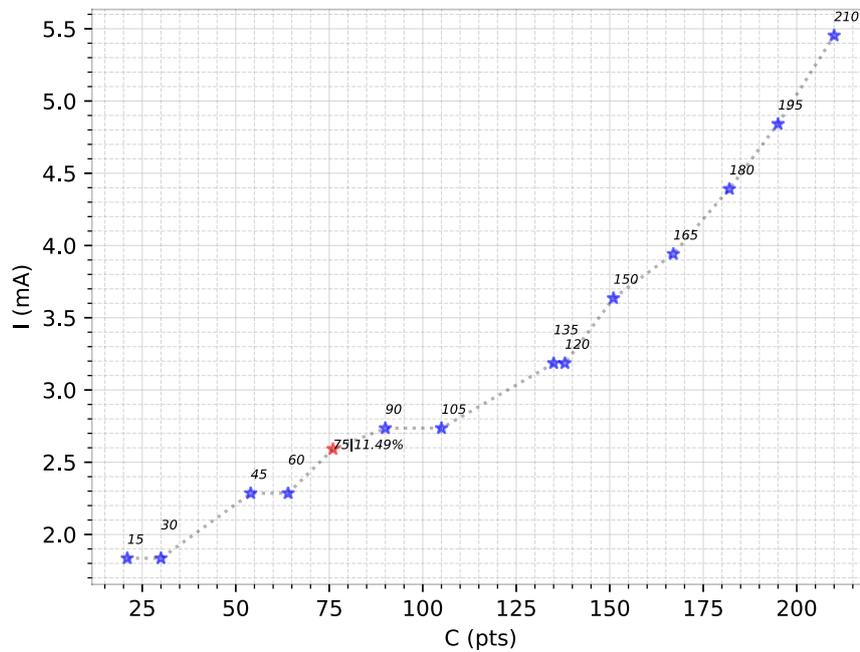


Figura V.4: Melhores resultados para instância de dimensões 15×15 e $D = 50\%$, para variados valores de ϵ .

(c) $\epsilon = 210$ 

(d) Fronteira de Pareto (aproximada)

Figura V.4: Melhores resultados para instância de dimensões 15×15 e $D = 50\%$, para variados valores de ϵ .

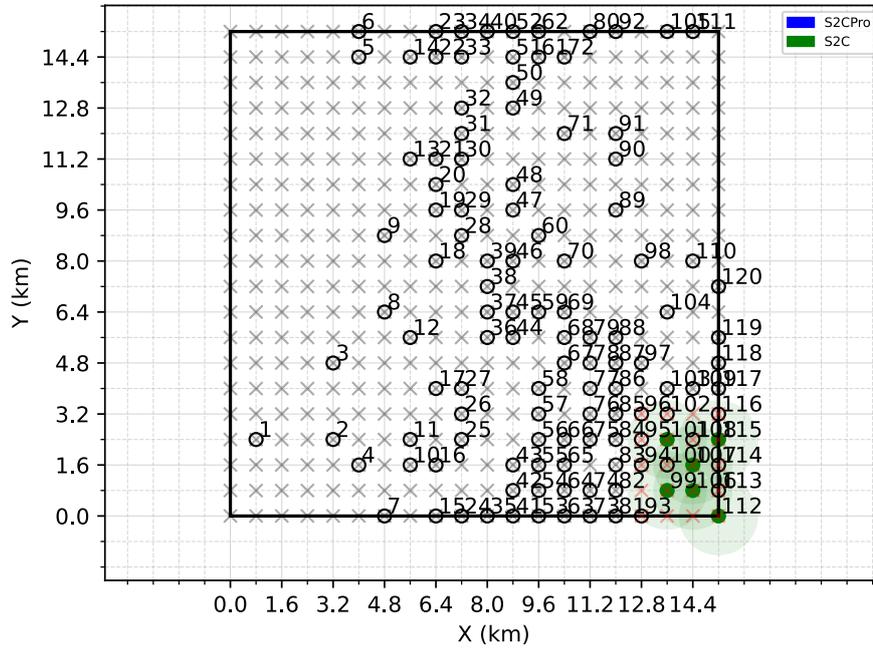
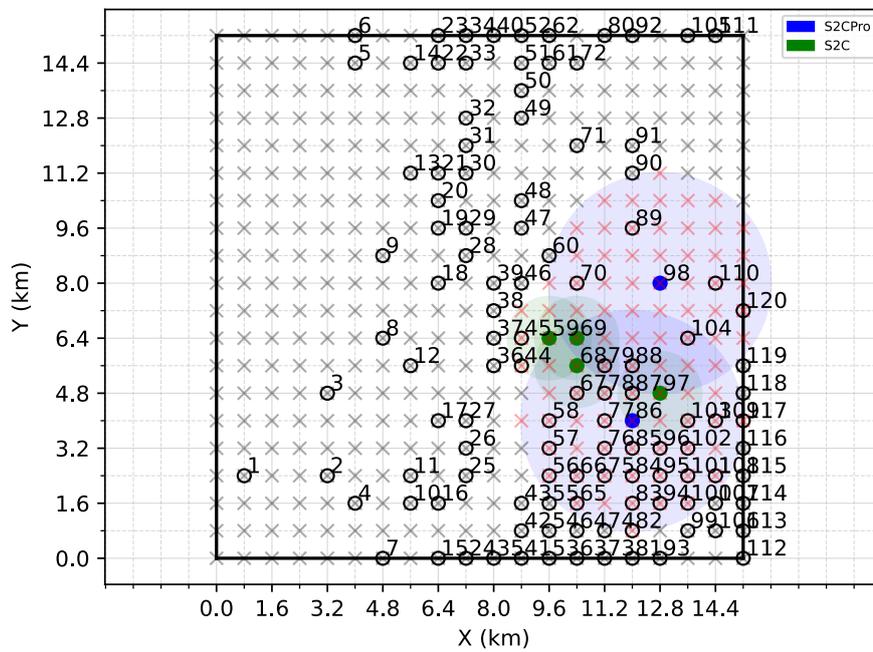
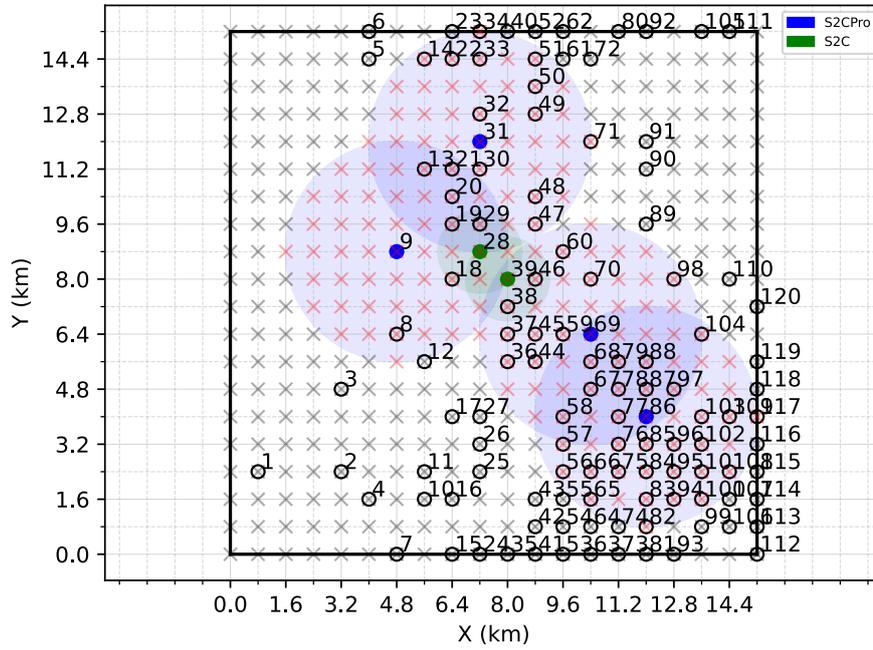
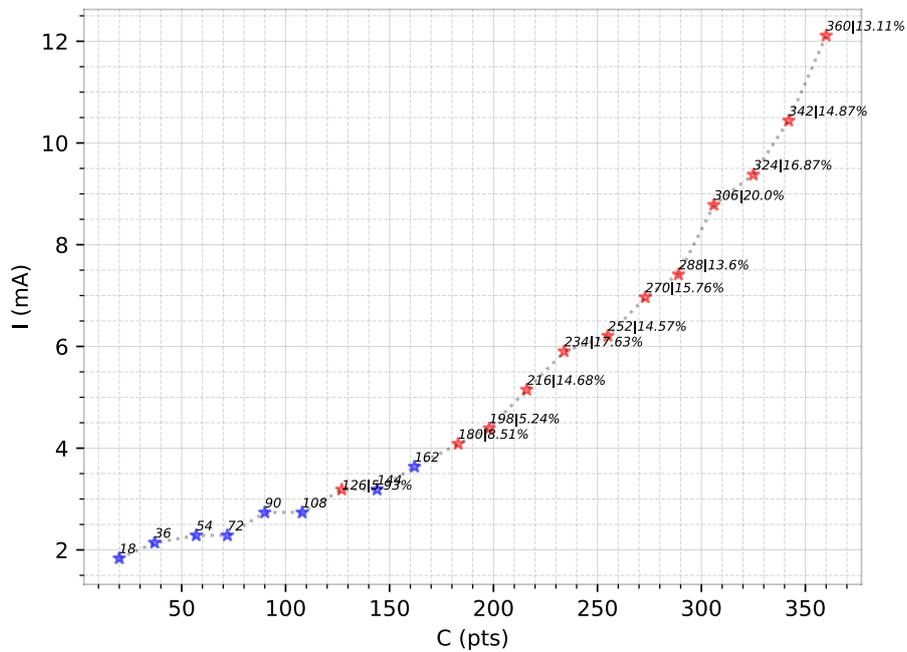
(a) $\epsilon = 18$ (b) $\epsilon = 90$

Figura V.5: Melhores resultados para instância de dimensões 20×20 e $D = 30\%$, para variados valores de ϵ .

(c) $\epsilon = 162$ 

(d) Fronteira de Pareto (aproximada)

Figura V.5: Melhores resultados para instância de dimensões 20×20 e $D = 30\%$, para variados valores de ϵ .

transceptores alocados na rede durante um ciclo de operação. Sendo assim, não há utilidade prática para estimar o tempo de vida de uma rede real a partir dos valores apresentados. Diferentemente da modelagem proposta, uma RSSF real pode, por exemplo, considerar que cada tipo de nó sensor possui um comportamento distinto em termos de D_C ou de quantidade de tráfego, o que pode exigir maior ou menor consumo energético de acordo com o posicionamento do nó sensor na topologia. Além disso, a localização dos nós pode ainda defini-los como pontos críticos de falha, o que limitaria o tempo de vida útil da rede ao tempo de vida desses nós críticos. No entanto, o valor de referência em mA como apresentado no modelo proposto é útil como representação e auxilia a compreender a proporção do aumento do consumo de energia global da RSSF ao passo que a necessidade de cobertura da região de monitoramento também aumenta.

Nas Figuras V.6, V.7 e V.8 é possível observar a variação da quantidade de modelos de transceptores alocados conforme varia-se ϵ para uma mesma instância. Em concordância com o que já foi observado nas Figuras V.3, V.4 e V.5, é possível perceber que, conforme a necessidade de cobertura cresce, a quantidade de transceptores do modelo S2C diminui, enquanto a quantidade de transceptores do modelo S2CPro aumenta, o que é explicado pelo modelo S2CPro possuir maior raio de alcance de transmissão. Conseqüentemente, um aumento no custo energético global é percebido de forma proporcional, por conta do modelo S2CPro apresentar maior consumo energético que o modelo S2C.

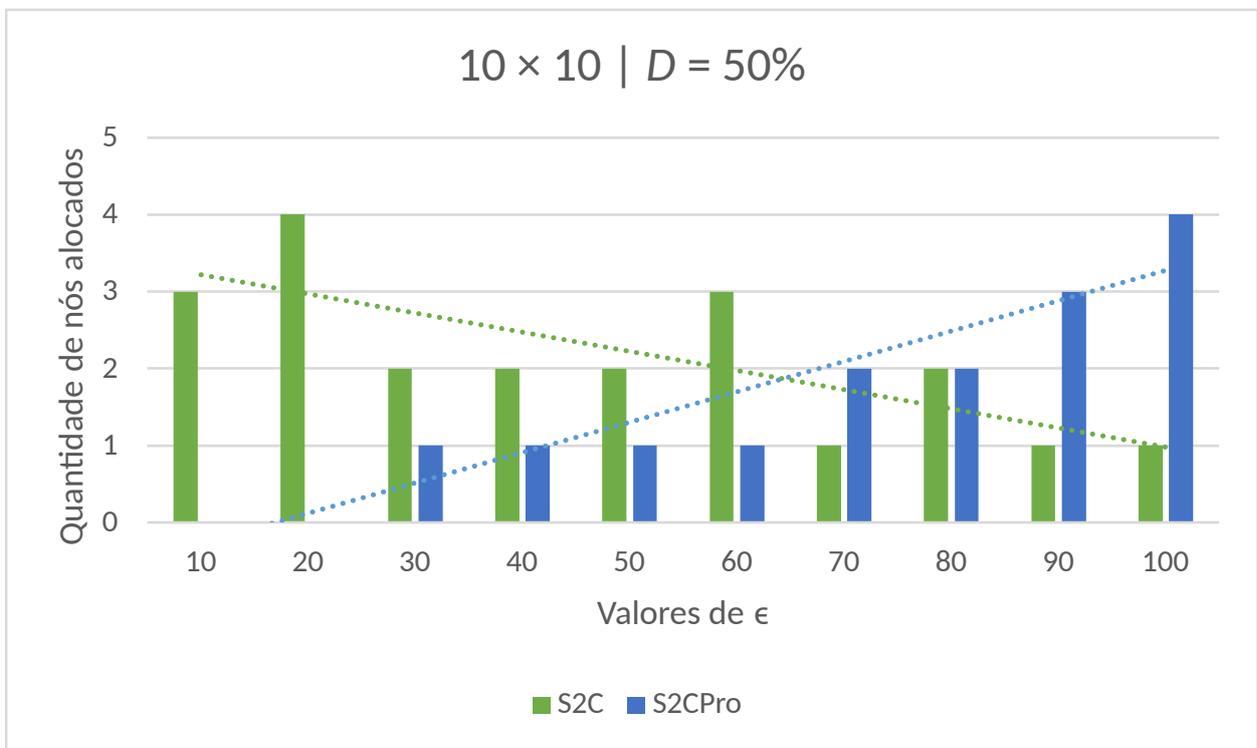


Figura V.6: Variação da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 10×10 e $D = 50\%$.

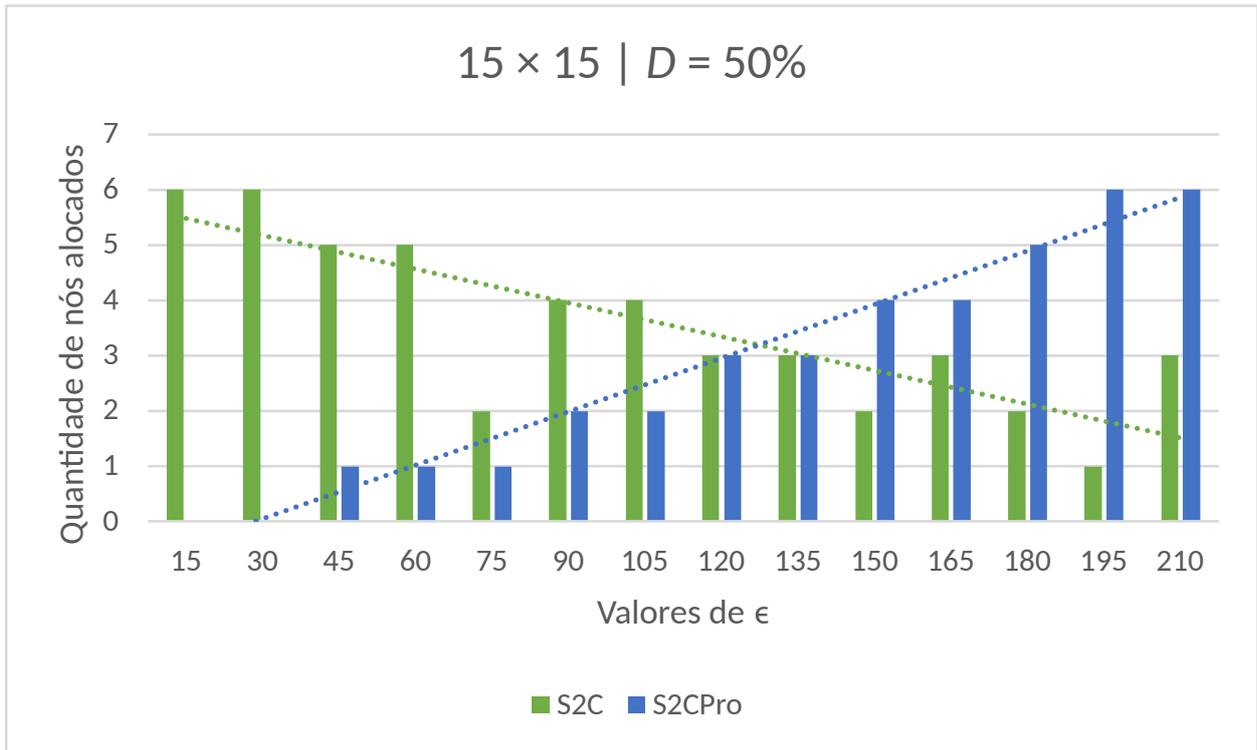


Figura V.7: Variação da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 15×15 e $D = 50\%$.

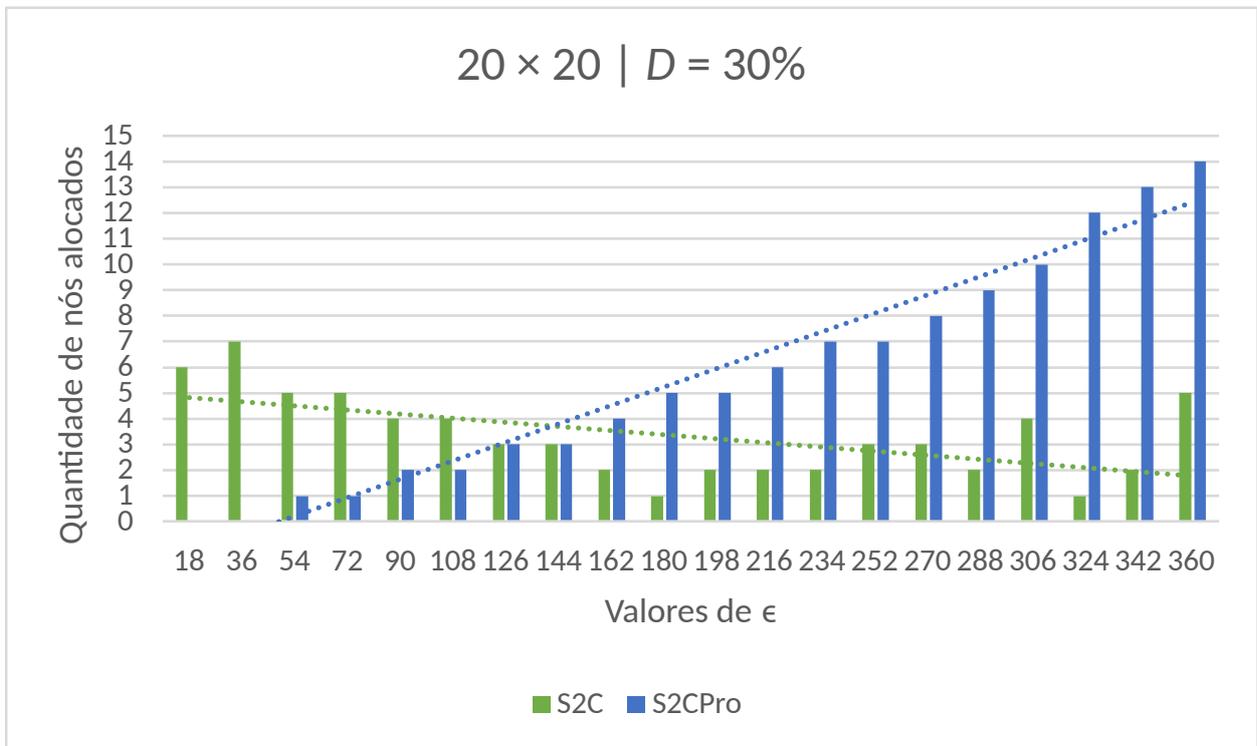


Figura V.8: Variação da quantidade de transceptores alocados conforme varia-se ϵ para instância de tamanho 20×20 e $D = 30\%$.

Nas Figuras V.9, V.10, V.11 pode-se observar, para cada tamanho da região de monitoramento, a variação do tamanho do modelo computacional em quantidade de variáveis de decisão e restrições (eixo vertical), conforme aumenta-se a densidade D de posições candidatas à alocação (eixo horizontal). De forma complementar, a Figura V.12 mostra o aumento da quantidade de variáveis de decisão e restrições do modelo (eixo horizontal) conforme aumenta-se o tamanho de instância e a densidade D (eixo vertical), onde todos os tamanhos de instância considerados são mostrados lado a lado. De acordo com as linhas de tendência traçadas, é perceptível que a complexidade combinatória do PAS é exponencial, o que pode configurar métodos de solução exatos como inviáveis para se obter soluções de redes de média a grande escala em um tempo computacional aceitável. Nas Figuras V.4d e V.5d e nas Tabelas V.4 e V.5 podem-se observar resultados que alcançaram o tempo limite sem comprovação de otimalidade, o que ocorre devido a essa alta complexidade computacional.

Complementarmente, as Figuras V.13, V.14 e V.15 indicam – em escala logarítmica – o crescimento exponencial do tempo computacional conforme o tamanho do modelo aumenta. É possível observar que os maiores tempos de execução nas Figuras V.14 e V.15 correspondem ao tempo limite de 12 horas (43200 segundos), e por isso os respectivos valores de ϵ apresentam resultados não comprovadamente ótimos nas Figuras V.4d e V.5d e Tabelas V.4 e V.5. Destaca-se também a diferença entre o tempo de execução no *solver* e o tempo total de execução. Este último é consideravelmente maior, pois a interface entre o ambiente Python e o *solver* gera um custo adicional de tempo de processamento. Isso se dá pois o *framework* Pyomo, utilizado na implementação, precisa traduzir o modelo – implementado em linguagem Python – para um formato que o *solver* seja capaz de interpretar.

A partir dos resultados apresentados, pode-se observar que o modelo PLI proposto apresenta viabilidade de utilização para otimização de topologias de RSSF heterogêneas, pois apresenta configurações de rede conexas – de acordo com as restrições do PAS – e permite ao projetista selecionar a melhor relação entre os objetivos de custo energético e área de cobertura a partir da variação do parâmetro ϵ . No entanto, percebe-se a limitação de utilização para cenários grandes (com muitas posições de alocação e muitos pontos de interesse), o que resulta em uma grande quantidade de variáveis e restrições e, conseqüentemente, em um alto tempo computacional para esses casos. Para as instâncias 20×20 , com 80 posições de alocação e 400 pontos de interesse, a execução do modelo em *solver* começa a se tornar inviável dentro do tempo limite de execução determinado, resultando em soluções não comprovadamente ótimas.

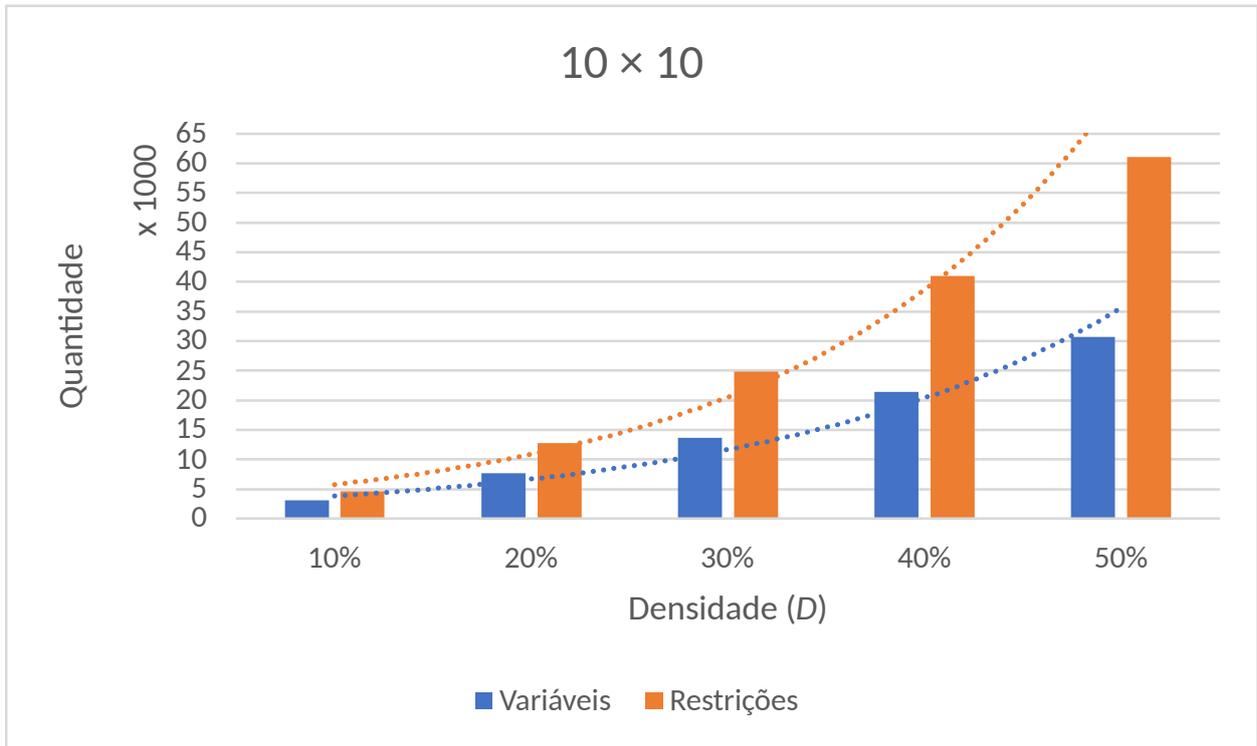


Figura V.9: Quantidade de variáveis e restrições do modelo para instâncias de tamanho 10×10 .

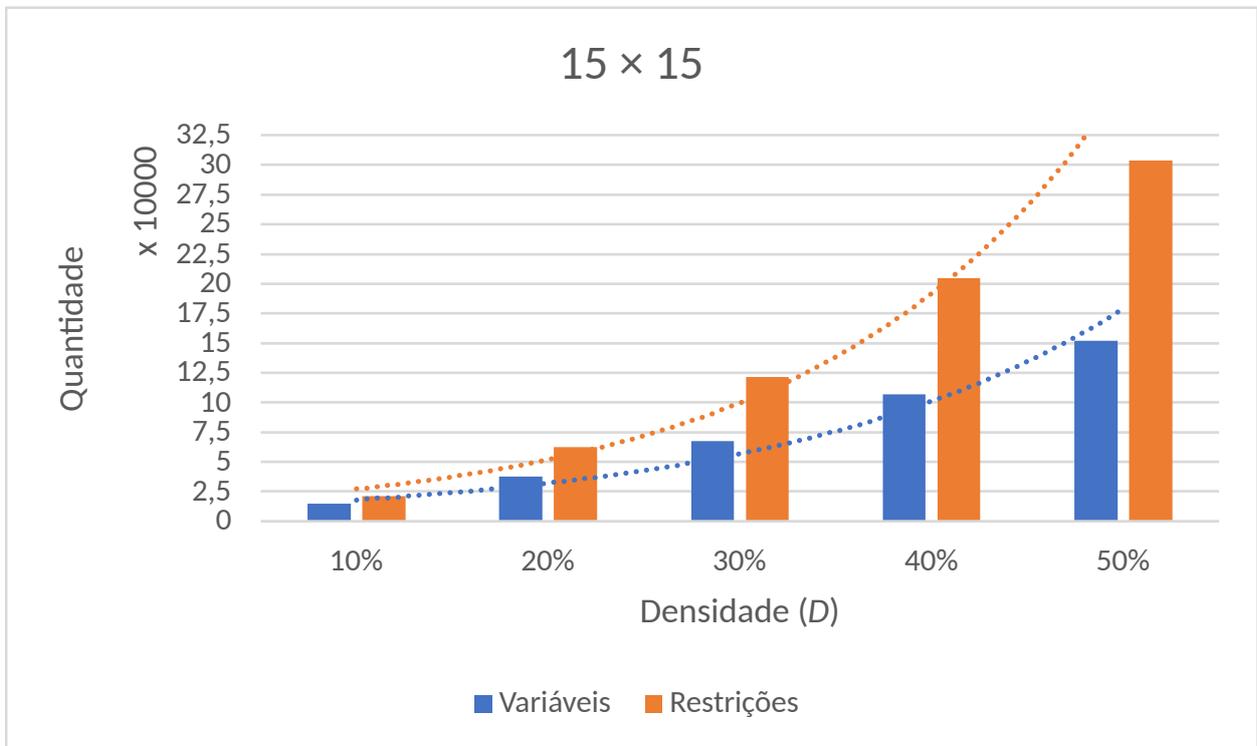


Figura V.10: Quantidade de variáveis e restrições do modelo para instâncias de tamanho 15×15 .

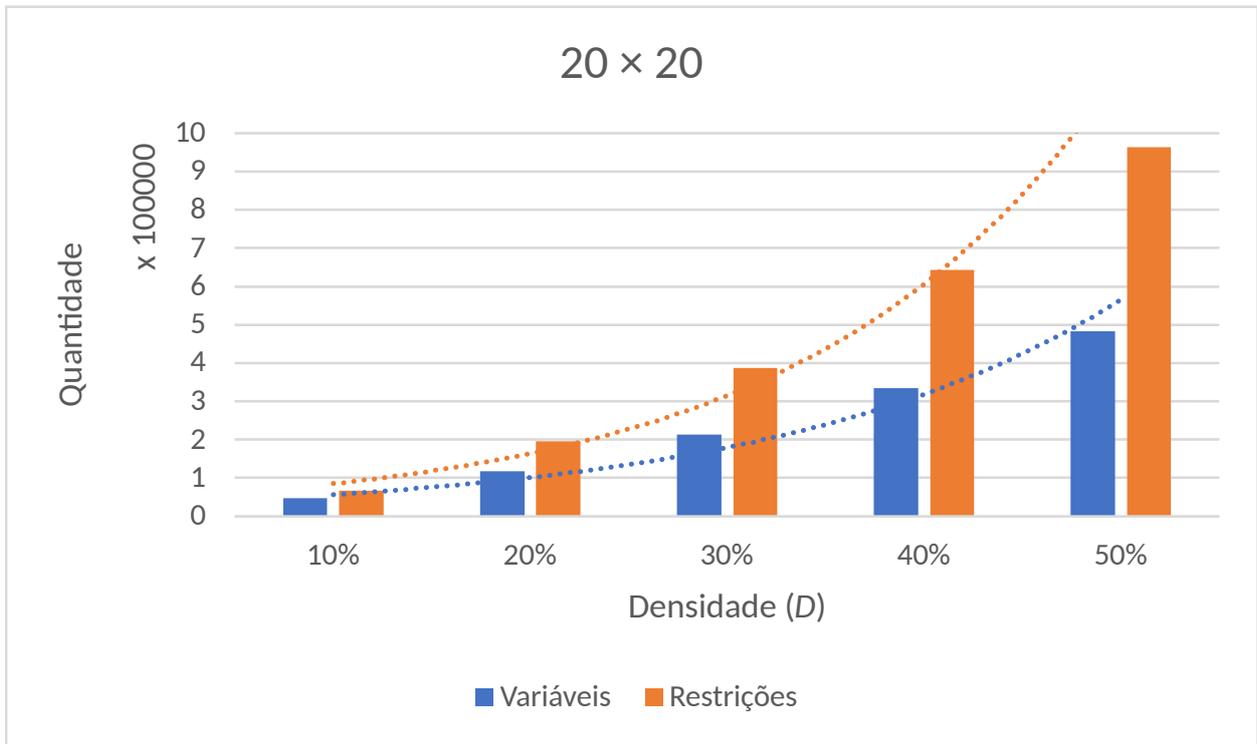


Figura V.11: Quantidade de variáveis e restrições do modelo para instâncias de tamanho 20×20 .

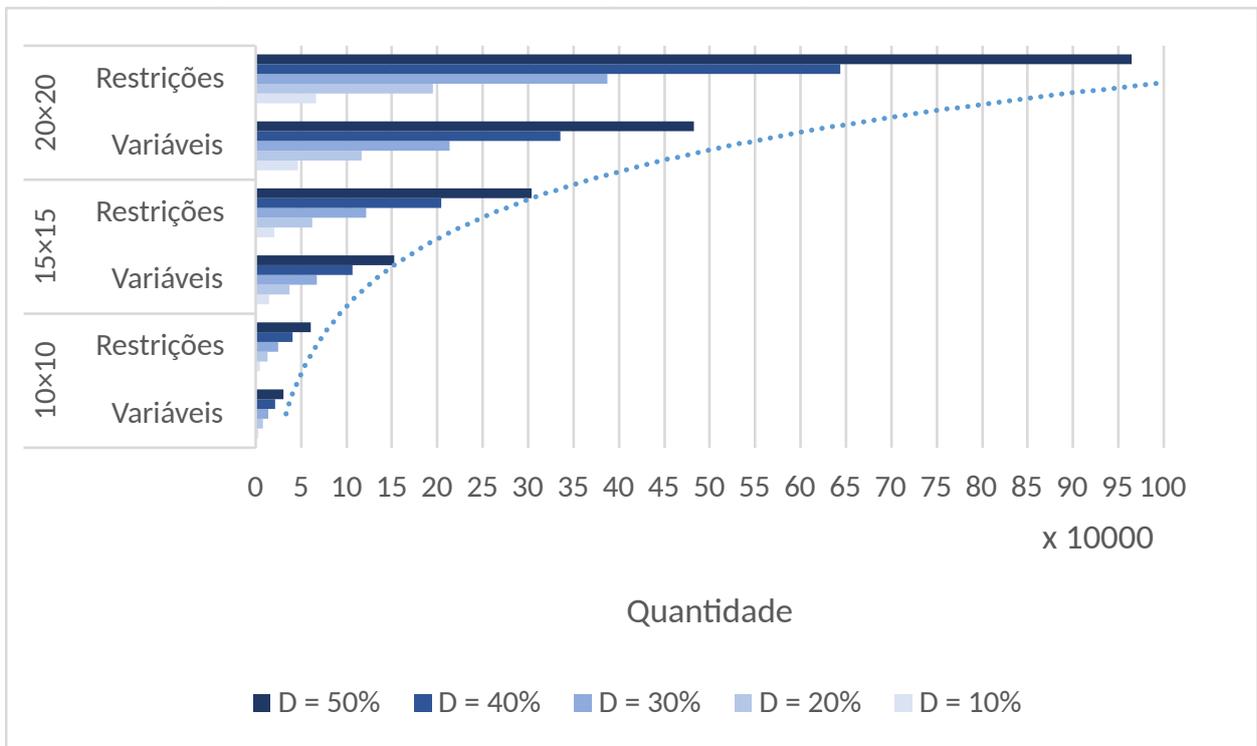


Figura V.12: Quantidade de variáveis e restrições para todas as instâncias.

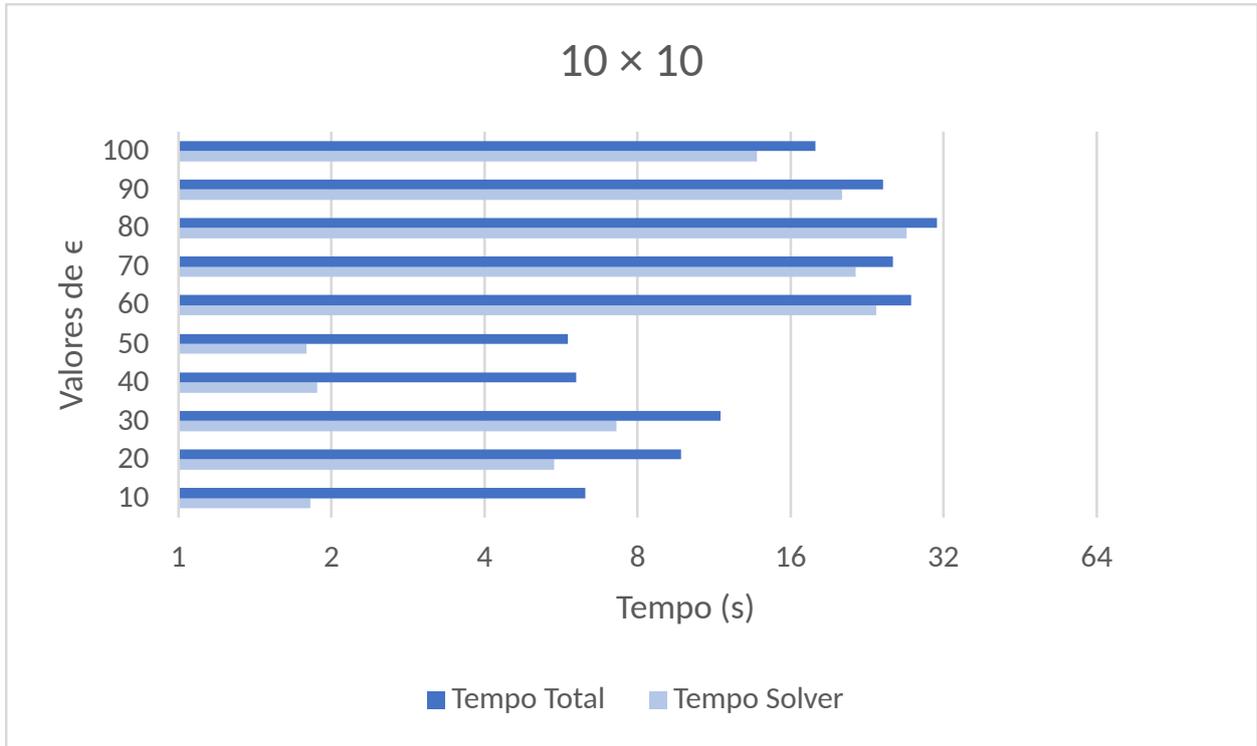


Figura V.13: Tempos de execução para cada ϵ da instância de tamanho 10×10 e $D = 50\%$.

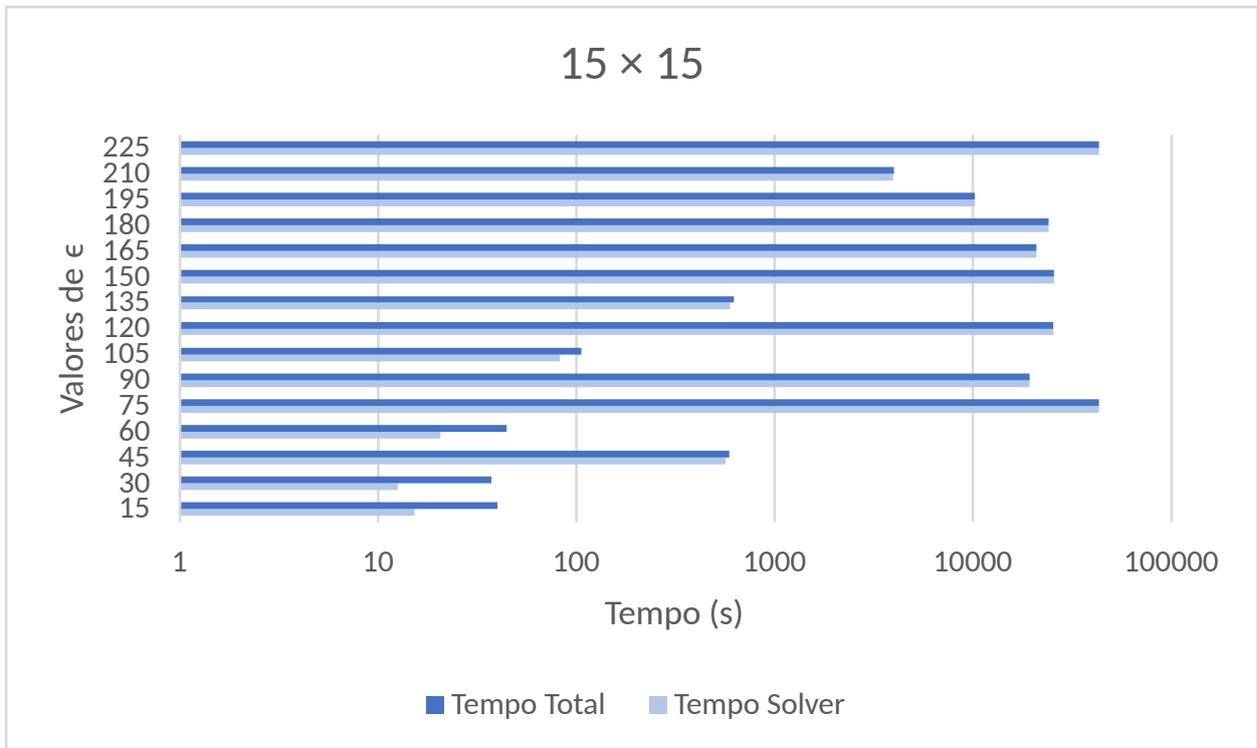


Figura V.14: Tempos de execução para cada ϵ da instância de tamanho 15×15 e $D = 50\%$.

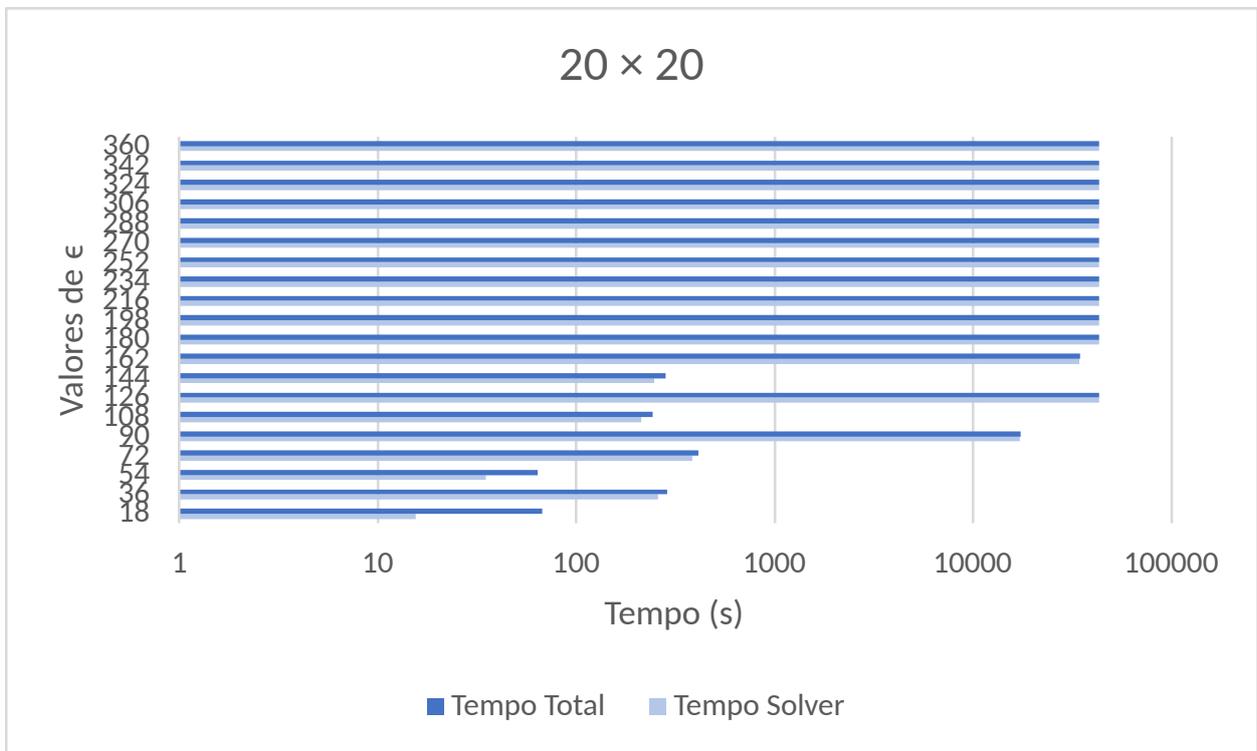


Figura V.15: Tempos de execução para cada ϵ da instância de tamanho 20×20 e $D = 30\%$.

Capítulo VI Conclusão

Este trabalho teve por objetivo estudar técnicas de modelagem computacional para resolver um PAS de forma exata, considerando uma RSSF heterogênea. O PAS em estudo consiste em encontrar a topologia ótima determinando quantos e quais modelos de transceptores devem ser alocados em determinadas posições a fim de minimizar o consumo energético e maximizar a cobertura da rede. Foi possível elaborar e validar uma proposta de modelo PLI baseada em trabalhos recentes da literatura que consideram problemas similares [de Brito et al., 2019; Bhondekar et al., 2009].

O modelo proposto recebe como entrada o número n de posições de monitoramento e suas coordenadas geográficas em uma região plana, bem como as dimensões do espaço estudado ($w \times h$). A saída do processamento exibe a quantidade e o posicionamento exato de cada modelo de transceptor na área de monitoramento, destacando o raio de cobertura. O modelo foi executado no *solver* Gurobi[®] em 225 experimentos computacionais, utilizando-se de 15 instâncias distintas geradas aleatoriamente e diferentes valores de ϵ , que determinam os limiares inferiores de área de cobertura da região da instância em cada experimento.

A partir dos resultados de validação apresentados no Capítulo V, conclui-se que foi obtido êxito em elaborar um modelo matemático que represente o PAS estudado de forma fidedigna. Por consequência, acredita-se que o modelo em questão possa ser utilizado para auxiliar na implantação de aplicações reais de RSSF, principalmente por permitir a utilização de dados de transceptores reais como entrada e possibilitar a formação de redes heterogêneas. O fato de possibilitar que o modelo realize a seleção dos transceptores em cada cenário exime o projetista da rede de ter de realizar essa seleção manualmente. No mais, a heterogeneidade da rede permite que complexidades do ambiente de implantação possam ser mitigadas. Em RSSF subterrâneas, por exemplo, o próprio meio solo no qual os nós sensores são instalados é um ambiente heterogêneo, o que faz com que a alocação de nós sensores com capacidades distintas de propagação possa ser a chave para que a rede alcance o ótimo desempenho.

Apesar do sucesso na validação do modelo proposto, percebeu-se uma complexidade combinatória elevada – devido à natureza do PAS – o que inviabiliza a busca por soluções comprovadamente ótimas em tempo aceitável para regiões de monitoramento grandes (*i.e.* com muitas posições de alocação e pontos de interesse na região de monitoramento). Notou-se também que, apesar de eficiente, o uso do método ϵ -restrito teve certo impacto no tempo computacional

total, dado que múltiplas variações da mesma instância do PAS precisaram ser executadas para obter um conjunto de soluções ótimas. Além disso foi observado que, para os casos em que o *solver* encontre múltiplas soluções ótimas, não necessariamente aquela de maior cobertura será selecionada. Isso normalmente ocorre em cenários mais densos, nos quais toda solução que minimize o consumo energético e que satisfaça a restrição de cobertura pode ser considerada equivalente – em termos do valor da FO. De forma a contornar esses casos, pode ser interessante avaliar a atribuição de um peso menor à FO de minimização do consumo energético, verificando como essa alteração influencia a qualidade das soluções obtidas. Essa alteração, juntamente com uma melhor definição dos passos de incremento de ϵ para cada cenário, pode permitir obter uma melhor aproximação das fronteiras de Pareto.

Dentre outras possíveis futuras contribuições à esta pesquisa, é importante citar a investigação de melhorias para o modelo proposto de forma a buscar reduzir o crescimento da quantidade de variáveis e restrições em relação ao aumento do tamanho das instâncias. Para isso, uma parametrização inteligente da região de monitoramento pode ser realizada, por exemplo, de forma a reduzir a quantidade de pontos de interesse. Outro problema consiste em que, apesar de as soluções apresentarem redes conexas, estas são limitadas à topologia em *Árvore*, o que impossibilita que os nós sensores encontrem caminhos alternativos até o sorvedouro da rede caso algum nó sensor crítico venha a falhar. Para resolver esse problema, um modelo adicional pode ser desenvolvido para alocação de nós sensores intermediários que possibilitem caminhos redundantes e a transformação da topologia da RSSF para uma configuração em *Malha*. Nesse caso, os modelos poderiam ser utilizados de forma hierárquica, sendo o modelo proposto neste trabalho o responsável por construir a rede base, enquanto o modelo sugerido poderia ser executado em sequência para possibilitar um aprimoramento da configuração topológica da RSSF, tal como observado em Balesdent e Piet-Lahanier [2015]. Além do mais, para se reduzir o tempo computacional, podem ser estudadas técnicas de paralelismo ou realizar a aplicação de métodos de solução heurísticos ou meta-heurísticos que possibilitem alcançar soluções factíveis para cenários reais, usando para isso os resultados exatos mostrados nesse trabalho como linha de base para fins de comparação – incluindo aqueles para os quais não foi possível comprovar otimalidade por conta do tempo limite de execução.

Outros desafios em aberto e que fogem do escopo do presente trabalho podem ser destacados: *(i)* estimar o raio de alcance dos transceptores – ao invés de utilizar valores teóricos – com base em modelos de propagação sem fio através do ar (ou propagação *free-space*) disponíveis na literatura [Huang et al., 2020]; *(ii)* acréscimo de outras funções objetivo, tais como minimização da latência ou maximização do *throughput*, permitindo que os cenários avaliados repliquem de forma fiel o comportamento da transmissão de dados em uma RSSF e o respectivo impacto no

consumo energético; *(iii)* considerar a adaptação do modelo para RSSF subterrâneas, subaquáticas ou implantadas em ambientes tridimensionais e com obstáculos, seguindo as tendências que podem ser observadas na literatura [Sadeghioon et al., 2017; Sardar et al., 2019; Lin et al., 2019]; *(iv)* investigar a aplicabilidade das topologias ótimas obtidas através do modelo proposto – mediante simulações computacionais – verificando o comportamento dos nós sensores ao longo do tempo e estimando o tempo de vida da rede de forma precisa. Evidentemente, para resolver alguns desses desafios, pode ser necessário realizar incrementos substanciais no modelo proposto, o que conseqüentemente adicionaria ainda mais complexidade combinatória. Portanto, dependendo dos acréscimos realizados, um estudo de viabilidade pode ser recomendável para verificar se a busca por soluções comprovadamente ótimas globais ainda é factível, ou se a aplicação de métodos heurísticos ou meta-heurísticos é aceitável mediante as premissas do problema.

Referências

- Abdelmaguid, T. F. An efficient mixed integer linear programming model for the minimum spanning tree problem. *Mathematics*, 6(10):1–17, 2018.
- Akyildiz, I., Su, W., Sankarasubramaniam, Y., e Cayirci, E. Wireless sensor networks: a survey. *Computer Networks*, 38(4):393–422, 2002.
- Akyildiz, I. F. Wireless sensor networks in challenged environments such as underwater and underground. In *Proceedings of the 17th ACM International Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems, MSWiM '14*, pages 1–2, New York, NY, USA. Association for Computing Machinery, 2014.
- Akyildiz, I. F. e Stuntebeck, E. P. Wireless underground sensor networks: Research challenges. *Ad Hoc Networks*, 4(6):669–686, 2006.
- Alduraibi, F., Lasla, N., e Younis, M. Coverage-based node placement optimization in wireless sensor network with linear topology. In *2016 IEEE International Conference on Communications (ICC)*, pages 1–6, 2016.
- Ali, A., Jadoon, Y. K., Changazi, S. A., e Qasim, M. Military operations: Wireless sensor networks based applications to reinforce future battlefield command system. In *2020 IEEE 23rd International Multitopic Conference (INMIC)*, pages 1–6, 2020.
- Ayedi, M., Eldesouky, E., e Nazeer, J. Energy-spectral efficiency optimization in wireless underground sensor networks using salp swarm algorithm. *Journal of Sensors*, 2021(1):1–16, 2021.
- Azevedo, B. F., Brito, T., Lima, J., e Pereira, A. I. Optimum sensors allocation for a forest fires monitoring system. *Forests*, 12(4), 2021.
- Balesdent, M. e Piet-Lahanier, H. A multi-level optimization approach for the planning of heterogeneous sensor networks. In Le Thi, H. A., Pham Dinh, T., e Nguyen, N. T., editors, *Modelling, Computation and Optimization in Information Systems and Management Sciences*, pages 221–233, Cham. Springer International Publishing, 2015.

- Barabasi, A. e Posfai, M. *Network Science*. Cambridge University Press, 2016.
- Bertsimas, D. e Tsitsiklis, J. *Introduction to Linear Optimization*. Athena Scientific books. Athena Scientific, 1997.
- Bhondekar, A., Renu, V., Singla, M., Ghanshyam, C., e Pawan, K. Genetic algorithm based node placement methodology for wireless sensor networks. *Lecture Notes in Engineering and Computer Science*, 2174:106–112, 2009.
- Brisset, S. e Gillon, F. 4 - approaches for multi-objective optimization in the ecodesign of electric systems. In Bessède, J.-L., editor, *Eco-Friendly Innovation in Electricity Transmission and Distribution Networks*, pages 83–97. Woodhead Publishing, Oxford, 2015.
- Da Rocha Henriques, F., Guedes, R., Ferreira, C., e Silva de Assis, L. Prioridade dinâmica de mensagens aplicada a redes de sensores corporais sem-fio. *Anais do Computer on the Beach*, pages 171–177, 2021.
- de Brito, J. A. G., de P. Junior, J. R., da R. Henriques, F., e de Assis, L. S. Topology control optimization of wireless sensor networks for iot applications. In *Proceedings of the 25th Brazilian Symposium on Multimedia and the Web*, pages 477–480, Porto Alegre, RS, Brasil. SBC, 2019.
- de Brito, J. A. G., Totte, D. R. M., Silva, F. O., Junior, J. R. d. P., Henriques, F. d. R., Tarrataca, L., Haddad, D. B., e de Assis, L. S. Memetic algorithm applied to topology control optimization of a wireless sensor network. *Wireless Networks*, 28(8):3677–3697, 2022.
- Digi International Inc. Digi xbee®/xbee-pro s2c zigbee® rf module user guide, 2022.
- Elfouly, F. H., Ramadan, R. A., Khedr, A. Y., Yadav, K., Azar, A. T., e Abdelhamed, M. A. Efficient node deployment of large-scale heterogeneous wireless sensor networks. *Applied Sciences*, 11(22), 2021.
- Fahmy, H. M. A. *Protocol Stack of WSNs*, pages 55–68. Springer Singapore, Singapore, 2016.
- Fellah, K. e Kechar, B. An integer linear programming approach for optimising energy consumption in mobile wireless sensor networks under realistic constraints. *International Journal of Mathematical Modelling and Numerical Optimisation*, 8(2):162–182, 2017.
- Ferreira, A. E., M. Ortiz, F., e M. K. Costa, L. H. Avaliação de tecnologias de comunicação sem-fio para monitoramento em ambientes de floresta. In *Anais do XXXVII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*, pages 113–126, Gramado. UFRJ, SBC, 2019.

- García, L., Parra, L., Jimenez, J. M., Parra, M., Lloret, J., Mauri, P. V., e Lorenz, P. Deployment strategies of soil monitoring wsn for precision agriculture irrigation scheduling in rural areas. *Sensors*, 21(5), 2021.
- Goldbarg, M. e Luna, H. *Otimização combinatória e programação linear: modelos e algoritmos*. Campus, 2000.
- Guedes, R. M., De Rezende, J. F., e Barbosa, V. C. Integrated optimization of heterogeneous-network management and the elusive role of macrocells. *IEEE Access*, 9:149552–149559, 2021.
- Hillier, F. e Lieberman, G. *Introdução à Pesquisa Operacional*. AMGH, 2013.
- Huang, H., Shi, J., Wang, F., Zhang, D., e Zhang, D. Theoretical and experimental studies on the signal propagation in soil for wireless underground sensor networks. *Sensors (Switzerland)*, 20(9), 2020.
- Ismail, M. N., Shukran, M., Isa, M. R. M., Adib, M., e Zakaria, O. Establishing a soldier wireless sensor network (wsn) communication for military operation monitoring. *International Journal of Informatics and Communication Technology*, 7(2):89–95, 2018.
- Jafarian, M. e Jaseemuddin, M. Routing of emergency data in a wireless sensor network for mines. In *2008 IEEE International Conference on Communications*, pages 2813–2818, 2008.
- Kannan, V. T. e Chakravarthi, R. Efficient addressing schemes for internet of things. *International Journal of Electrical and Computer Engineering*, 12(4):4415–4429, 2022.
- Kanthavel, R. e Dhaya, R. Wireless underground sensor networks channel using energy efficient clustered communication. *Intelligent Automation and Soft Computing*, 31(1):649–659, 2022.
- Kendler, S. e Fishbain, B. Optimal wireless distributed sensor network design and ad-hoc deployment in a chemical emergency situation. *Sensors*, 22(7), 2022.
- Kim, D.-S. e Tran-Dang, H. *Wireless Sensor Networks for Industrial Applications*, pages 127–140. Springer International Publishing, 2019.
- Ko, A. H. R., Jouselme, A. L., Sabourin, R., e Gagnon, F. A dominance-based stepwise approach for sensor placement optimization. *Applied Soft Computing Journal*, 28(March):466–482, 2015.
- Kochhar, A., Kaur, P., Singh, P., e Sharma, S. Protocols for wireless sensor networks: A survey. *Journal of Telecommunications and Information Technology*, 2018(1):77–87, 2018.
- Li, C., Bai, J., Gu, J., Yan, X., e Luo, Y. Clustering routing based on mixed integer programming for heterogeneous wireless sensor networks. *Ad Hoc Networks*, 72:81–90, 2018.

- Lin, K., Hao, T., Yu, Z., Zheng, W., e He, W. A preliminary study of u2ag link quality in lora-based wireless underground sensor networks. In *2019 IEEE 44th Conference on Local Computer Networks (LCN)*, pages 51–59, 2019.
- Majid, M., Habib, S., Javed, A. R., Rizwan, M., Srivastava, G., Gadekallu, T. R., e Lin, J. C.-W. Applications of wireless sensor networks and internet of things frameworks in the industry revolution 4.0: A systematic literature review. *Sensors*, 22(6), 2022.
- Mansourkiaie, F. e Ahmed, M. H. Optimal and near-optimal cooperative routing and power allocation for collision minimization in wireless sensor networks. *IEEE Sensors Journal*, 16(5):1398–1411, 2016.
- Mavrotas, G. Multi-objective programming, ϵ -constraint method, gams. *Applied Mathematics and Computation*, 213(2):455–465, 2009.
- Nagashima, T., Tanaka, Y., e Ishihara, S. Measurement of wireless communication characteristics in sewer pipes for sewer inspection systems using multiple wireless sensor nodes. In *2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC)*, pages 2055–2060, 2015.
- Nguyen, P. L., Hanh, N. T., Khuong, N. T., Binh, H. T. T., e Ji, Y. Node placement for connected target coverage in wireless sensor networks with dynamic sinks. *Pervasive and Mobile Computing*, 59:101070, 2019.
- Niccolai, A., Grimaccia, F., Mussetta, M., e Zich, R. E. Different approaches to multi-objective sparse array problem with social network optimization. In *2020 IEEE Congress on Evolutionary Computation (CEC)*, pages 1–7, 2020.
- Osamy, W., Aziz, A., e M Khedr, A. Deterministic clustering based compressive sensing scheme for fog-supported heterogeneous wireless sensor networks. *PeerJ Computer Science*, 7:1–28, 2021.
- Peng, B., Zou, J., Tan, C., e Wang, M. Network lifetime optimization in wireless video sensor networks. In *IET International Communication Conference on Wireless Mobile and Computing (CCWMC 2009)*, pages 172–175, 2009.
- Pinheiro, L. F., de Assis, L. S., e da Rocha Henriques, F. Integer programming applied to wireless sensor networks topology optimization. In Pereira, A. I., Košir, A., Fernandes, F. P., Pacheco, M. F., Teixeira, J. P., e Lopes, R. P., editors, *Optimization, Learning Algorithms and Applications*, pages 246–260. Springer International Publishing, 2022.

- Pinheiro, P. R., Sobreira Neto, A. M., e Aguiar, A. B. Handing optimization energy consumption in heterogeneous wireless sensor networks. *International Journal of Distributed Sensor Networks*, 9(9):1–9, 2013.
- Ranganathan, S. Home automation system using wireless sensor network. *International Journal of Emerging Technology in Computer Science & Electronics*, 13:230–234, 2015.
- Sadeghioon, A., Chapman, D., Metje, N., e Anthony, C. A new approach to estimating the path loss in underground wireless sensor networks. *Journal of Sensor and Actuator Networks*, 6(3):1–11, 2017.
- Saeed, N., Alouini, M.-S., e Al-Naffouri, T. Y. Toward the internet of underground things: A systematic survey. *IEEE Communications Surveys Tutorials*, 21(4):3443–3466, 2019.
- Saini, J., Dutta, M., e Marques, G. A comprehensive review on indoor air quality monitoring systems for enhanced public health. *Sustainable Environment Research*, 30(1):1–12, 2020.
- Sardar, M. S., Xuefen, W., Yi, Y., Kausar, F., e Akbar, M. W. Wireless underground sensor networks. *International Journal of Performability Engineering*, 15(11):1–10, 2019.
- Sharma, D., Verma, S., e Sharma, K. Network topologies in wireless sensor networks: A review. *International Journal of Electronics & Communication Technology*, 4(3):93–97, 2013.
- Shutimarrungson, N. e Wuttidittachotti, P. Realistic propagation effects on wireless sensor networks for landslide management. *EURASIP Journal on Wireless Communications and Networking*, 2019, 2019.
- Singh, A., Sharma, S., e Singh, J. Nature-inspired algorithms for wireless sensor networks: A comprehensive survey. *Computer Science Review*, 39:1–21, 2021.
- Srivastava, A. e Mishra, P. K. A survey on wsn issues with its heuristics and meta-heuristics solutions. *Wireless Personal Communications*, 121:745–814, 2021.
- Sun, Y., Rehfeldt, D., Brazil, M., Thomas, D., e Halgamuge, S. A physarum-inspired algorithm for minimum-cost relay node placement in wireless sensor networks. *IEEE/ACM Transactions on Networking*, 28(2):681–694, 2020.
- Sun, Z. e Akyildiz, I. F. Deployment algorithms for wireless underground sensor networks using magnetic induction. In *2010 IEEE Global Telecommunications Conference GLOBECOM 2010*, pages 1–5, 2010.

- Tam, N. T., Binh, H. T. T., Dung, D. A., Lan, P. N., Vinh, L. T., Yuan, B., e Yao, X. A hybrid clustering and evolutionary approach for wireless underground sensor network lifetime maximization. *Information Sciences*, 504:372–393, 2019.
- Thakur, D., Kumar, Y., Kumar, A., e Singh, P. K. Applicability of wireless sensor networks in precision agriculture: A review. *Wireless Personal Communications*, 107(1):471–512, 2019.
- Thike, A. M., Lupin, S., Chakirov, R., e Vagapov, Y. Topology optimisation of wireless sensor networks. In *2016 International Conference on Design, Mechanical and Material Engineering (D2ME 2016)*, volume 82, pages 57–62, 2016.
- Tomazella, C. P. e Nagano, M. S. A comprehensive review of branch-and-bound algorithms: Guidelines and directions for further research on the flowshop scheduling problem. *Expert Systems with Applications*, 158:1–63, 2020.
- Wang, Y., Wang, H., Razzaghi, R., Jalili, M., e Liebman, A. Multi-objective coordinated ev charging strategy in distribution networks using an improved augmented epsilon-constrained method. *Applied Energy*, 369:1–12, 2024.
- Wohlin, C. Guidelines for snowballing in systematic literature studies and a replication in software engineering. In *Proceedings of the 18th International Conference on Evaluation and Assessment in Software Engineering, EASE '14*, New York, NY, USA. Association for Computing Machinery, 2014.
- Wu, C. H. e Chung, Y. C. Heterogeneous wireless sensor network deployment and topology control based on irregular sensor model. In Cérin, C. e Li, K.-C., editors, *Advances in Grid and Pervasive Computing*, pages 78–88, Berlin, Heidelberg. Springer Berlin Heidelberg, 2007.
- Wu, D., Chatzigeorgiou, D., Youcef-Toumi, K., Mekid, S., e Ben-Mansour, R. Channel-aware relay node placement in wireless sensor networks for pipeline inspection. *IEEE Transactions on Wireless Communications*, 13(7):3510–3523, 2014.
- Xie, H., Yan, Z., Yao, Z., e Atiquzzaman, M. Data collection for security measurement in wireless sensor networks: A survey. *IEEE Internet of Things Journal*, 6(2):2205–2224, 2018.
- Zungeru, A. M., Ezea, H., e Katende, J. Pulsed power system for wireless underground sensor networks. In *2016 3rd International Conference on Electrical, Electronics, Computer Engineering and their Applications, EECEA 2016*, pages 126–132. IEEE, 2016.