



COMPARAÇÃO ENTRE MÉTODOS EXATO E HEURÍSTICO PARA O PROBLEMA DE
ALOCÇÃO DE SENSORES EM REDES DE SENSORES SEM FIO

Diego Rodrigues Moreira Totte

Dissertação apresentada 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 título de mestre.

Orientadora: Laura Silva de Assis
Coorientador: Felipe da Rocha Henriques

Rio de Janeiro,
Maio 2023

COMPARAÇÃO ENTRE MÉTODOS EXATO E HEURÍSTICO PARA O PROBLEMA DE
ALOCAÇÃO DE SENSORES EM REDES DE SENSORES SEM FIO

Dissertação apresentada 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 título de mestre.

Diego Rodrigues Moreira Totte

Banca Examinadora:

Presidente, Professora D.Sc. Laura Silva de Assis (CEFET/RJ) (Orientadora)

Professor D.Sc. Felipe da Rocha Henriques (CEFET/RJ) (Coorientador)

Professor D.Sc. Pedro Henrique González Silva (CEFET/RJ)

Professor D.Sc. Michel Pompeu Tcheou (PEL/UERJ)

Rio de Janeiro,

Maio 2023

Ficha catalográfica elaborada pela Biblioteca Central do CEFET/RJ

T718 Totte, Diego Rodrigues Moreira
Comparação entre métodos exato e heurístico para o problema de alocação de sensores em redes de sensores sem fio / Diego Rodrigues Moreira Totte. — 2023.
81f. : il. color. , enc.

Dissertação (Mestrado) Centro Federal de Educação Tecnológica Celso Suckow da Fonseca, 2023.
Bibliografia : f. 76-81
Orientadora: Laura Silva de Assis
Coorientador: Felipe da Rocha Henriques

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

CDD 621.3845

DEDICATÓRIA

... à minha esposa, Clarissa, e à Lila, nossa filha de quatro patas.

AGRADECIMENTOS

À professora Laura, minha orientadora, pelos ensinamentos, orientação e, mais importante, por acreditar em mim até o final. Ao professor Felipe, meu coorientador, por todo conhecimento compartilhado, pelas ótimas indicações de artigo e pela compreensão e empatia infinitas. Aos professores Pedro e Michel, membros da banca examinadora, pela disponibilidade e contribuição. Aos professores Diego Brandão e Diego Haddad pelo apoio na pesquisa e qualificação. A todo corpo docente do PPCIC, do CEFET, pelas aulas em alto nível e dedicação em manter e evoluir o curso. Orgulho!

À minha esposa, Clarissa, que muito ajudou, apoiou e suportou desde antes do início do mestrado. Vencemos!

Aos meus pais, Jurandir e Luci, pelo carinho e fé. Ao meu irmão, Emílio, pelo apoio na hora mais difícil. Ao meu filho, Carlos Eduardo, pela companhia nos estudos. Voltei!

Aos meus companheiros de mestrado, e agora mestres, Danielle, Davi e Luis, pelo grupo unido que construímos nos estudos durante a pandemia. Ao meu amigo e xará dos primeiros passos no mestrado, Diego, e ao meu amigo dos passos finais da jornada, Fábio. Ao Jorge, pelo apoio na continuidade de sua pesquisa. Ao meu grande amigo, conselheiro, incentivador e parceiro de todos os passos no mestrado, Igor. Contem comigo!

Aos meus gestores Eduardo e Queiroz, pelo apoio e parceria. Não esquecerei!

Por fim, e não menos importante, aos meus amigos desde sempre, Cláudio, Lúcio e Luiz, pelo apoio. Partiu!

A todos os citados, e não citados, que me apoiaram: cada um de vocês está em uma ou mais partes deste trabalho. Obrigado e parabéns a todos nós!

EPÍGRAFE

Ousado aventureiro, decida de uma vez:

Faça o sino vibrar e aguarde o perigo

Ou acabe louco de tanto pensar:

“Se eu tivesse tocado, o que teria acontecido?”

(C. S. Lewis, O Sobrinho do Mago)

RESUMO

Comparação entre Métodos Exato e Heurístico para o Problema de Alocação de Sensores em Rede de Sensores Sem Fio

Redes de Sensores Sem Fio (RSSFs) estão cada vez mais presentes na sociedade, sejam em casas, carros, fábricas ou em apoio a resgates e preservação ambiental. Vários métodos de otimização são propostos na literatura a fim de alocar os nós sensores de forma a melhorar o desempenho da rede, considerando um ou mais objetivos. Contudo, grande parte dos estudos neste tema são realizados com métodos heurísticos, os quais não possuem garantia de otimalidade. Já abordagens exatas, devido à complexidade envolvida na garantia da solução ótima, geralmente não resolvem instâncias de grande porte. Nesta pesquisa, são comparadas duas abordagens de solução para o Problema de Alocação de Sensores (PAS) com objetivo de minimizar o custo energético geral da rede: a primeira é um método exato usando Programação Linear Inteira Mista (PLIM), através de formulação matemática proposta, e a segunda um método heurístico proposto baseado nos conceitos de Algoritmos Genéticos (AGs). Os resultados obtidos mostraram que a abordagem exata alcançou resultados ótimos para o PAS considerando instâncias de pequeno, médio e grande portes. Por sua vez, o AG gerou resultados subótimos para quase o dobro de instâncias que a abordagem exata, no mesmo período de tempo. Foram utilizadas instâncias de formatos regular e não regulares.

Palavras-chave: Rede de Sensores Sem Fio; Problema de Alocação de Sensores; Programação Linear Inteira Mista; Algoritmo Genético.

ABSTRACT

Comparison between Exact and Heuristic Methods for Sensor Allocation Problem in Wireless Sensor Network

Wireless Sensor Networks (WSNs) are increasingly present in society, whether in homes, cars, factories or in support for rescue and environmental preservation. Several optimization methods have been proposed in the literature to allocating the sensor nodes in order to improve the network performance, considering one or more objectives. However, most studies on this subject are carried out with heuristic methods, which do not guarantee optimality. Exact approaches, on the other hand, generally do not solve large instances due to the complexity involved in finding the optimal solution. In this research, two approaches to solve the Sensor Allocation Problem (SAP) are compared in order to minimize the overall energy cost of the network: the first is an exact method using Mixed Integer Linear Programming (MILP), through mathematical formulation proposed, and the second is a proposed heuristic method based on the concepts of Genetic Algorithms (GAs). The results show that the exact approach achieved optimal results for PAS considering small, medium and large instances. In turn, the GA generated suboptimal results for almost twice as many instances as the exact approach, in the same period of time. Instances of regular and non-regular formats were used.

Keywords: Wireless Sensor Network; Sensor Allocation Problem; Mixed-Integer Linear Program; Genetic Algorithm.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Estrutura interna básica de um nó sensor.	22
Figura 2 –	Exemplo de diferentes topologias em RSSFs.	24
Figura 3 –	Topologia em estrela com agrupamentos.	25
Figura 4 –	Fluxograma com as etapas genéricas de um AG.	29
Figura 5 –	Exemplo representativo da seleção por roleta indicando a chance de cada indivíduo ser selecionado, conforme o valor de aptidão de cada um frente ao valor de aptidão da população.	30
Figura 6 –	Exemplo de comunicação entre os tipos de nós sensores considerados.	32
Figura 7 –	Exemplo da composição de vizinhança em C_i^s para $i = 7$ e $s = sz$ numa rede de formato regular com $l = 4$.	35
Figura 8 –	Exemplos dos formatos de rede utilizados nesta pesquisa.	37
Figura 9 –	Representação de um indivíduo equivalente à rede apresentada na Figura 6.	39
Figura 10 –	Exemplo de cruzamento de dois pontos.	44
Figura 11 –	Exemplo da mutação em um filho.	45
Figura 12 –	Gráficos com a relação da quantidade de sensores pelo tempo na otimização do PAS pela abordagem exata em instâncias de formato regular.	52
Figura 13 –	Gráficos com a relação da quantidade de sensores pelo tempo na otimização do PAS pelo AG em instâncias de formato regular.	57
Figura 14 –	Gráficos comparativos entre abordagens, relacionando a quantidade de sensores com o valor da FO. Mostra a perda de qualidade do AG com o aumento da quantidade de sensores.	60

Figura 15 – Gráfico comparativo entre abordagens, relacionando a quantidade de sensores pelo tempo de otimização do PAS em redes de formato regular.	61
Figura 16 – Instâncias de formato regular de pequeno porte ($l = 5$).	65
Figura 17 – Instâncias de formato regular de médio porte ($l = 15$).	66
Figura 18 – Instâncias de formato regular de grande porte ($l = 35$).	67
Figura 19 – Instâncias de formato semirregular de pequeno porte (equivalente a $l = 5$).	68
Figura 20 – Instâncias de formato semirregular de médio porte (equivalente a $l = 15$).	69
Figura 21 – Instâncias de formato semirregular de grande porte (equivalente a $l = 35$).	70
Figura 22 – Instâncias de formato irregular de pequeno porte (equivalente a $l = 5$).	71
Figura 23 – Instâncias de formato irregular de médio porte (equivalente a $l = 15$).	72
Figura 24 – Instâncias de formato irregular de grande porte (equivalente a $l = 35$).	73

LISTA DE TABELAS

Tabela 1 – Amostragem da quantidade de nós sensores nas instâncias utilizadas em trabalhos científicos.	17
Tabela 2 – Características dos tipos de nós sensores.	32
Tabela 3 – Relação de hiperparâmetros do AG.	48
Tabela 4 – Resultados das execuções da abordagem exata em instâncias de formato regular até o limite do tempo estipulado.	54
Tabela 5 – Comparação entre os registros de execução do <i>Solver</i> em redes de formato regular de lados sequenciais onde o maior lado obteve o resultado em menor tempo.	55
Tabela 6 – Configuração de valores para os hiperparâmetros.	56
Tabela 7 – Resultados das execuções do AG em instâncias de formato regular até o limite do tempo estipulado.	58
Tabela 8 – Resultados da execução da abordagem exata em instâncias de formatos não regulares.	62
Tabela 9 – Resultados da execução do AG em instâncias de formatos não regulares.	62
Tabela 10 – Comparação entre valores da FO em instâncias de portes pequeno, médio e grande.	63
Tabela 11 – Comparação entre tempos de otimização em instâncias de portes pequeno, médio e grande.	63

LISTA DE ALGORITMOS

Algoritmo 1 –	Gerador de População Inicial.	40
Algoritmo 2 –	Processo de Viabilização de Indivíduo.	41
Algoritmo 3 –	Seleção.	43
Algoritmo 4 –	Cruzamento.	44
Algoritmo 5 –	Mutação.	45

LISTA DE ABREVIATURAS E SIGLAS

AG	Algoritmo Genético
AM	Algoritmo Memético
BnB	<i>Branch-and-bound</i>
BnC	<i>Branch-and-cut</i>
CAA	Colônia Artificial de Abelhas
DARPA	<i>United States Defense Advanced Research Projects Agency</i>
DSN	<i>Distributed Sensor Network</i>
EUA	Estados Unidos da América
FO	Função Objetivo
IoT	<i>Internet of Things</i>
iRace	<i>Iterated Racing for Automatic Algorithm Configuration</i>
MHH	Meta-Heurística Híbrida
OCF	Otimização por Colônia de Formigas
OEP	Otimização por Enxame de Partículas
PAS	Problema de Alocação de Sensores
PL	Programação Linear
PLI	Programação Linear Inteira
PLIM	Programação Linear Inteira Mista
RNSSF	Rede de Nanossensores Sem Fio
RSCH	Rede de Sensores do Corpo Humano
RSSF	Rede de Sensores Sem Fio
RSSFm	Rede de Sensores Sem Fio Multimídia
RSSFST	Rede de Sensores Sem Fio Subterrânea
RSSFt	Rede de Sensores Sem Fio Terrestre
SA	<i>Simulated Annealing</i>
URSS	União das Repúblicas Socialistas Soviéticas

SUMÁRIO

Introdução	16
1 Fundamentação Teórica	19
1.1 Rede de Sensores Sem Fio	19
1.2 Nós Sensores	21
1.3 Conectividade e Topologia	23
1.4 Métodos de Otimização	26
1.5 Programação Linear Inteira Mista	27
1.6 Algoritmo Genético	27
2 Descrição e Formulação do PAS	31
2.1 Problema de Alocação de Sensores	31
2.2 Modelo Matemático	33
2.3 Formatos de Rede	35
3 AG para Solução do PAS	38
3.1 Representação	38
3.2 População Inicial	39
3.3 Viabilização	40
3.4 Função de Avaliação	41
3.5 Seleção	42
3.6 Cruzamento	43
3.7 Mutação	44
3.8 Reinicialização	45
3.9 Funções Auxiliares	46
3.10 Hiperparâmetros	47
4 Resultados	49

4.1	Estrutura e Execução da Otimização	49
4.2	Otimização por Mét. Exato em Inst. de Formato Regular	51
4.3	Otimização dos Hiperparâmetros do AG	55
4.4	Otimização por Mét. Heurístico em Inst. de Formato Regular	56
4.5	Comparação entre Inst. de Formato Regular	60
4.6	Otimização em Inst. de Formatos Não Regulares e Comparação entre Inst. de todos os Formatos	61
4.7	Alocação Otimizada dos Sensores	64
5	Conclusão e Trabalhos Futuros	74

Introdução

Sensores são usados para capturar fenômenos físicos ou químicos de forma que possibilite a medição do fenômeno para análise e/ou tomada de decisão. Possuem o transdutor como principal componente, este sendo responsável pela conversão de um sinal de um tipo para outro (analógico para digital, por exemplo), passível de observação. Sensores são usados no dia a dia para medir as temperaturas do corpo humano e do ambiente, em termômetros, para acender lâmpadas pela aproximação de pessoas, por sensores de movimento, e em várias outras situações [Javaid et al., 2021]. Uma grande quantidade de sensores interligados e com um objetivo em comum formam uma Rede de Sensores Sem Fio (RSSF) [Akyildiz et al., 2002]. Uma RSSF pode ser utilizada para monitoramento de uma determinada região e, com os dados obtidos, alcançar benefícios maiores, tais como prevenções de catástrofes, preservação ambiental e melhoria da segurança territorial [Ghosh and Das, 2008].

Criada pelos militares, as RSSFs agora são usadas em muitas áreas de aplicação civil, incluindo monitoramento de ambiente e habitat, aplicações de saúde, automação residencial e tráfego [Singh et al., 2010]. Uma grande quantidade de atividades de pesquisa vem sendo realizada para explorar suas limitações, e avanços significativos são realizados no desenvolvimento e implantação de RSSFs. Prevê-se que as RSSFs vão mudar a forma que as pessoas vivem, trabalham e interagem com o mundo físico em um futuro próximo [Zheng and Jamalipour, 2009]. Porém, apesar dos avanços, devido ao fornecimento limitado de energia, o gerenciamento deste recurso é uma questão importante para as RSSFs [Hussain and Islam, 2007; Henriques et al., 2016, 2019], sendo inclusive apontada por Slijepcevic and Potkonjak [2001] como a sua principal limitação operacional. Outras limitações, como a conectividade, a confiabilidade e a cobertura da rede, são também questões críticas ao se definir uma topologia otimizada de uma RSSF. A otimização dessas propriedades são exploradas na literatura através do estudo das variações do Problema de Alocação de Sensores (PAS).

Diversos trabalhos presentes na literatura apresentam metodologias distintas para solução do PAS. Meta-heurísticas e métodos híbridos são utilizados [Srivastava and Mishra, 2021], assim como métodos exatos [Thike et al., 2016]. O PAS é um problema

de otimização combinatória, conhecido pela sua complexidade NP-difícil [Ozkan et al., 2019], o que leva a uma complexidade exponencial, o qual pode ser computacionalmente custoso determinar sua solução ótima, principalmente para instâncias de grande porte. Como consequência, métodos de solução que resolvam o PAS em RSSFs considerando instâncias grandes é algo ainda pouco explorado na literatura. Algumas vezes, a quantidade de nós sensores das redes testadas nem são citadas diretamente, aparecendo discretamente nos resultados. Apesar de informações indicando que a quantidade de nós sensores em uma RSSF varia entre dezenas e milhares [Singh et al., 2010], os testes com instâncias que chegam ou passam de mil nós sensores são raros. A média encontrada em 24 artigos analisados foi de 322 nós sensores e apenas 1 artigo utilizou uma instância maior que 1000 nós sensores, como pode ser observado na Tabela 1, a qual apresenta a referência do artigo em questão e a quantidade de nós sensores considerada nos testes.

Tabela 1 – Amostragem da quantidade de nós sensores nas instâncias utilizadas em trabalhos científicos.

Qtd. Nós Sensores	Artigos
50	Mao et al. [2006]; Henriques et al. [2016]
54	Henriques et al. [2019]
75	Gu et al. [2007]
80	Tossa et al. [2022]
85	Ribeiro [2012]
100	Hussain and Islam [2007]; Bhondekar et al. [2009]; Sadi and Ergen [2013]; Zanjireh et al. [2013]
150	Chen et al. [2016]
196	Floréen et al. [2005]
200	Xie and Wang [2014]; Lee [2017]; Li and Gong [2021]
250	Ishizuka and Aida [2004]
300	Yang et al. [2019]
350	Eshaftri [2017]
400	Slijepcevic and Potkonjak [2001]
500	Alves et al. [2019]
1000	Abusafia et al. [2016]; Srinivasa Rao and Banka [2017]; Castaño et al. [2018]
1200	Kim and Han [2015]

Fonte: o próprio autor.

Dado que os métodos exatos garantem o resultado ótimo, enquanto o tempo de execução para encontrar a solução ótima não for proibitivo, tais métodos são ideais para solucionar o PAS. Assim, a comparação entre abordagens exata e heurística é interessante para determinar até que tamanho de instância o método exato consegue resolver o problema, dado um limiar de tempo. E a partir de então, os métodos heurísticos passam a ser abordagens interessantes, fornecendo uma solução com bom compromisso entre qualidade e tempo computacional, além de fornecerem limitantes superiores para solução ótima.

Considerando as questões supracitadas, esta pesquisa tem os seguintes objetivos principais, no intuito de comparar metodologias de otimização para solucionar o PAS:

1. Propor modelo matemático para solucionar o PAS por método exato.
2. Desenvolver método heurístico para solução do PAS.
3. Realizar estudos de caso que permitirão comparar as abordagens exata e heurística propostas.
4. Obter informações claras sobre o limite de resultados do método exato.
5. Analisar as soluções obtidas por abordagem heurística, principalmente para instâncias de grande porte.

Outros objetivos visados por esta pesquisa são: *(i)* realizar testes considerando redes com formatos distintos; e *(ii)* realizar e documentar a otimização de hiperparâmetros da abordagem heurística.

Os trabalhos de Brito et al. [2019] e Brito et al. [2022] que estudam o PAS multi-objetivo pela proposição de métodos para solução, um Algoritmo Genético (AG) e um Algoritmo Memético (AM), são base para parte desta pesquisa. Características da rede, dos nós sensores e o AG implementado neste trabalho têm origem nesses artigos-base. Nesta pesquisa, o PAS é mono-objetivo para minimização do custo energético da rede. Um modelo de Programação Linear Inteira Mista (PLIM) é proposto e submetido a um *Solver*. O *Solver* é utilizado em diversos trabalhos, como em Floréen et al. [2005], You et al. [2009] e Morais [2018], e objetiva manter o foco na modelagem ao invés da implementação. Já a escolha do AG tem como pressuposto a continuidade dos artigos-base citados, além de ser um método ainda atual, conhecido, dinâmico e de implementação relativamente fácil. Para mais, as abordagens desta pesquisa otimizam o PAS também para formatos de rede não regulares, identificadas como semirregular e irregular, expandindo o artigo-base.

Além deste capítulo de introdução, este trabalho está dividido como descrito a seguir. O Capítulo 1 é dedicado às informações teóricas necessárias para o entendimento do assunto tratado. O Capítulo 2 apresenta a descrição e formulação matemática do PAS. O Capítulo 3 descreve a metodologia desenvolvida para solução do PAS pelo AG. O Capítulo 4 apresenta e discute os resultados obtidos. Por fim, no Capítulo 5, são descritas as conclusões e sugestões de trabalhos futuros com base nos resultados desta pesquisa.

1- Fundamentação Teórica

Nesse capítulo, são apresentados conceitos subjacentes e relevantes para o entendimento deste trabalho, relacionados às RSSFs e aos métodos de otimização. A Seção 1.1 apresenta diversas informações sobre as RSSFs: início, evolução, aplicações atuais e tipos de RSSF. A Seção 1.2 aborda informações sobre os nós sensores. A Seção 1.3 discute sobre a organização física e lógica das RSSFs. Em seguida, a Seção 1.4 inicia o tema dos métodos de otimização. A Seção 1.5 define PLIM enquanto a Seção 1.6 apresenta o AG.

1.1- Rede de Sensores Sem Fio

Uma RSSF é formada por um conjunto de dispositivos eletrônicos com sensores, conectados entre si e distribuídos ao longo de uma área com um objetivo específico de monitoramento de fenômenos [Akyildiz et al., 2002]. Como muitas outras tecnologias, a história da RSSF teve seu início pelos militares. Nos anos 50, no contexto da guerra-fria, foi desenvolvida pelos Estados Unidos da América (EUA) uma rede de sensores sonoros subaquáticos, implantada no fundo do oceano para o rastreamento de submarinos da antiga União das Repúblicas Socialistas Soviéticas (URSS) [Chee-Yee Chong and Kumar, 2003]. Seguindo os altos investimentos feitos nos anos 60 e 70 na infraestrutura da Internet, a *United States Defense Advanced Research Projects Agency* (DARPA), agência americana de pesquisa militar, lançou em 1980 o programa nomeado *Distributed Sensor Network* (DSN) para fomentar o estudo de RSSF, abrindo o caminho para o estudo científico em universidades americanas parceiras [Jondhale et al., 2022]. Em seguida, governo e universidades começaram a usar as RSSFs em diversas aplicações. Logo, estudantes de engenharia, absorvidos pelo mercado corporativo de tecnologia, começaram a promover o uso de RSSFs em aplicações industriais. Até esse momento, a implementação de RSSFs contava com sensores volumosos e caros e protocolos de rede proprietários.

As RSSFs ganharam uma atenção considerável nos últimos anos. A diminuição do

tamanho dos dispositivos, a melhoria na tecnologia do sensoriamento e da comunicação sem fio e a produção em massa promoveram o desenvolvimento de equipamentos sensores mais eficientes e acessíveis [Ting and Liao, 2010; Boukerche and Sun, 2018]. As melhorias energética e do processamento foram outros fatores importantes. Os sensores como ponto central da Internet das Coisas [Brito et al., 2019], do inglês *Internet of Things* (IoT), alinhados ao *Big Data* [Djedouboum et al., 2018] e à Computação em Nuvem (*Cloud Computing*) [Zhang et al., 2014], estão cada vez mais possibilitando o desenvolvimento de aplicações para RSSFs.

Em uma RSSF padrão, ou Rede de Sensores Sem Fio Terrestre (RSSFT), os sensores são localizados em meio aéreo, comunicam-se entre si e transmitem a informação para um dispositivo central, chamado de nó coletor, via comunicação sem fio. O nó coletor, por sua vez, envia os dados recebidos para um destino, via Internet ou rede local, utilizando conexão por fio ou sem fio. Na maioria das vezes, o nó coletor possui amplo acesso à energia, diferente dos demais nós sensores da rede. A pesquisa sobre RSSF é bem extensa e pode ser separada em categorias específicas de estudo, quando alguma característica física ou de aplicação se torna crítica ao ponto de ocorrer mudanças significativas em suas propriedades de comunicação, energia, processamento, tamanho, topologia, dentre outras.

Esse é o caso da Rede de Sensores Sem Fio Subterrânea (RSSFST). Trata-se de uma RSSF com os nós sensores enterrados que se comunicam através do solo entre si e com o dispositivo coletor, que fica localizado na superfície [Silva et al., 2015]. O ambiente subterrâneo é bastante hostil para as comunicações e a maioria dos desafios em uma RSSFST são maximizados em relação a RSSFs padrão [Akyildiz and Stuntebeck, 2006]. Os custos financeiros de implantação das RSSFST são elevados devido à necessidade de escavação para implantação dos sensores. Com isso, a conservação de energia se torna ainda mais crítica e desejável. A comunicação é mais complexa, pois as frequências utilizadas em RSSFs tradicionais não são adequadas ao ambiente subterrâneo [Trang et al., 2018]. Fatores como perda extrema de rota dos pacotes de dados, reflexão/refração quando ocorre a mudança entre meios físicos (aéreo e subterrâneo) entre outros são grandes preocupações numa RSSFST [Akyildiz and Stuntebeck, 2006].

Outra categoria de pesquisa de RSSFs trata da comunicação entre nós sensores de escala atômica e molecular. Nesse cenário, os nós sensores são identificados como nanossensores e a rede é chamada de Rede de Nanossensores Sem Fio (RNSSF). Seu

uso é geralmente para medições aplicadas a seres vivos, humanos [Zarepour et al., 2015] ou animais [Upadhayay and Agarwal, 2012], como monitoramento sobre o funcionamento de órgãos. A construção de equipamentos nessa escala é um enorme desafio, principalmente no componente de comunicação [Akyildiz et al., 2011]. A Rede de Sensores do Corpo Humano (RSCH) aparece como uma aplicação da RNSSF [Barbosa, 2008]. São ainda encontradas na literatura outras categorias como a Rede de Sensores Sem Fio Subaquática [Felemban et al., 2015] e a Rede de Sensores Sem Fio Multimídia (RSSFM) [Ozkan et al., 2019].

Nesta pesquisa, o estudo do PAS é direcionado a uma RSSFT. Porém, este estudo pode ser adaptado e se estender a outras categorias de RSSFs, desde que as características de conectividade e os tipos de nós sensores sejam factíveis na categoria de rede em questão.

1.2- Nós Sensores

Em uma RSSF, o nó da rede é chamado de nó sensor. Numa definição completa, um nó sensor é um pequeno dispositivo eletrônico com um ou mais sensores e capacidade de processamento e comunicação [Abusafia et al., 2016]. Ele tem o objetivo principal de monitorar um fenômeno físico ou químico. Em conjunto com muitos outros nós sensores, pode-se aumentar o raio de sensoriamento do fenômeno, permitindo assim uma visão global da área monitorada [Slijepcevic and Potkonjak, 2001]. O nó sensor é composto basicamente por quatro unidades: *(i)* unidade de sensoriamento, *(ii)* unidade de processamento, *(iii)* unidade de comunicação e *(iv)* unidade de energia, geralmente uma bateria [Kandris et al., 2020], organizados como ilustrado na Figura 1.

A unidade de sensoriamento pode ter um ou mais sensores diferentes em função do objetivo principal da rede. Existem sensores para medição de magnetismo, aceleração, luz, som, temperatura, pressão atmosférica, umidade entre outros [Hollar, 1996]. Esta unidade possui também o conversor analógico-digital, que transforma o sinal captado de sua forma natural, analógica, em sinais elétricos, para processamento. A unidade de comunicação é responsável pela conexão do nó sensor com a rede, entre os nós sensores e o nó coletor, e pela transmissão das informações captadas pelo sensor e

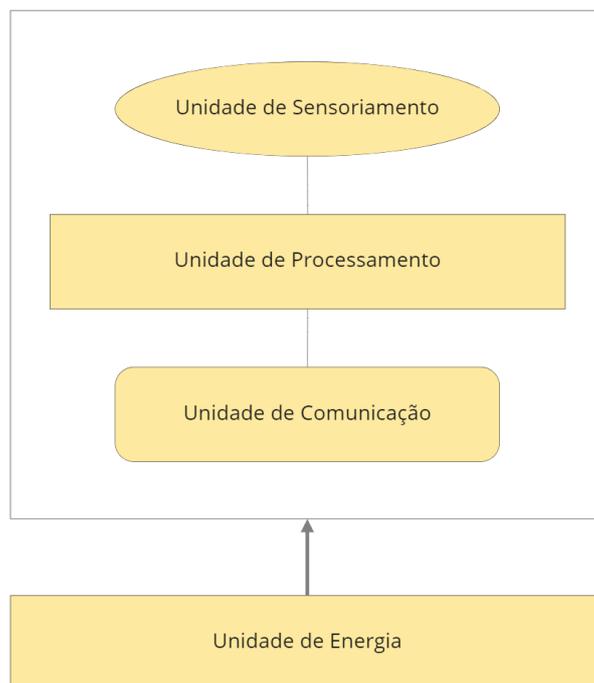


Figura 1 – Estrutura interna básica de um nó sensor.
Fonte: Adaptado de Zheng and Jamalipour [2009].

já pré-processadas, visando atingir o ponto final para armazenamento, processamento, análise e/ou tomada de decisão [Akyildiz et al., 2002]. A unidade de processamento executa instruções de funcionamento e controle para as unidades de sensoriamento e de comunicação. A unidade de energia provê a energia necessária ao funcionamento de todas as unidades do nó sensor.

A forma de transmissão mais comum entre nós sensores é via ondas de rádio. Um nó sensor pode transmitir e/ou receber informações sensoreadas. Um nó sensor pode ainda retransmitir informações recebidas de outros nós sensores. Essa retransmissão ocorre para outros nós sensores ou para um nó coletor. A configuração dos nós sensores em uma RSSF depende das características físicas do nó sensor e da topologia escolhida. Uma ligação (comunicação) entre dois nós de uma RSSF é conhecida como salto. Numa topologia onde os nós sensores se comunicam diretamente com um nó coletor ou com algum nó sensor que seja responsáveis por um agrupamento, como detalhado na Seção 1.3, a comunicação da rede é conhecida como de salto único. Já em uma topologia onde há retransmissão entre nós sensores, e estes agem como retransmissores (roteadores) pela rede, a comunicação é conhecida como de múltiplos saltos.

Esta pesquisa considera a comunicação de salto único entre nós sensores e

o nó sensor responsável pelo agrupamento. Os nós sensores têm capacidades de comunicação diferentes, permitindo que estejam mais próximos ou mais distantes dos nós sensores responsáveis pelo agrupamento.

1.3- Conectividade e Topologia

A conectividade das RSSFs é baseada nos princípios das redes *ad hoc* sem fio, ou seja, uma rede descentralizada onde a conectividade entre os nós da rede é feita dinamicamente. Na criação de uma RSSF, a alocação dos sensores pode ser determinada (também chamada de determinística ou manual), quando os nós sensores são alocados conforme uma posição conhecida/definida anteriormente à implantação da rede, ou aleatória, quando os nós sensores são alocados de forma não determinada, por exemplo, se atirados de um avião em um local de difícil acesso, como um campo de combate ou um local de desastre [Floréen et al., 2005; Boukerche and Sun, 2018].

A topologia de uma RSSF define a organização que os nós sensores assumem para estabelecer comunicação na rede, ou seja, para que a informação sobre o fenômeno sensoreado em um determinado nó sensor seja transmitida para um dispositivo computacional final. Dentre as diversas topologias possíveis [Sandeep Verma, 2013], pode-se destacar três que são comumente atreladas ao estudo e implementação de RSSFs: (i) topologia em estrela (*star topology*) [Alippi et al., 2011], (ii) topologia em árvore (*tree topology*) [Henriques et al., 2016] e (iii) topologia em malha (*mesh topology*) [Alves et al., 2019]. A Figura 2 ilustra a organização dos nós sensores e suas comunicações nas três topologias citadas.

A topologia em estrela é de menor complexidade se comparada às demais citadas. Nela, cada nó sensor transmite diretamente para um nó coletor, com o papel principal de gerenciar as informações para fora da rede ou da sub-rede, em redes baseadas em agrupamentos. Esse tipo de topologia possui um bom custo-benefício energético pelo fato dos nós sensores terem geralmente apenas transmissor (sem receptor). Entretanto, uma limitação é a distância que a rede consegue alcançar. Tal limitação ocorre porque todos os nós sensores precisam estar no alcance do nó coletor.

A topologia em árvore permite a extensão da distância entre os nós sensores.

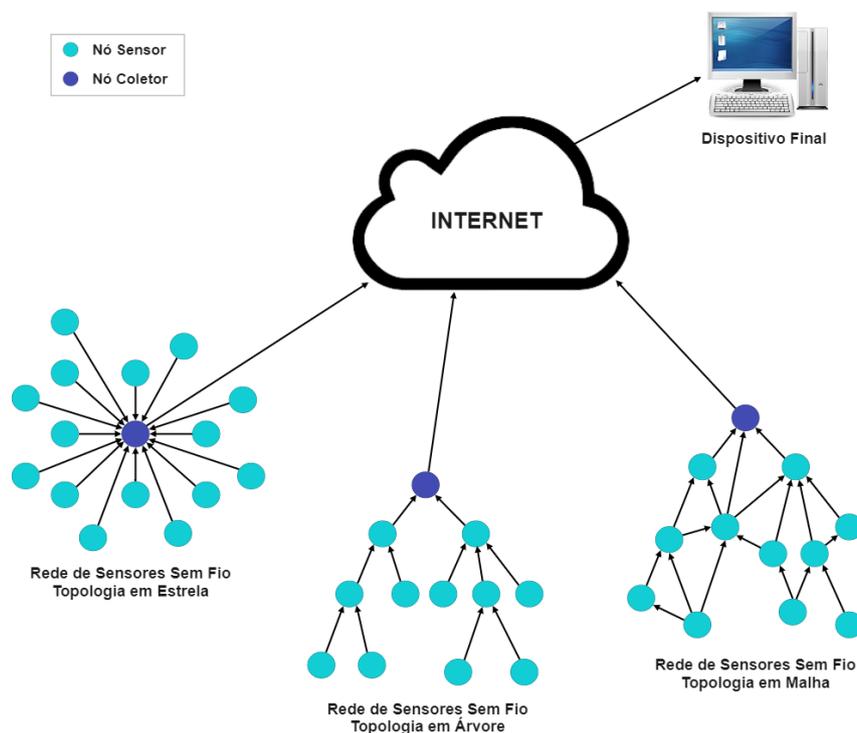


Figura 2 – Exemplo de diferentes topologias em RSSFs.
Fonte: o próprio autor.

Neste tipo de topologia, cada nó sensor pode se comunicar com outros nós sensores que fazem o papel de repetidores das informações recebidas, para os dados chegarem até o nó coletor. Ela possui um aumento de custo energético por demandar que os nós sensores também realizem a recepção de dados, e não apenas a transmissão. Outra desvantagem dessa topologia é que, caso um nó retransmissor (roteador) falhe e, consecutivamente, perca a comunicação, toda a sub-rede que transmite para esse nó também perderá comunicação com o nó coletor.

A topologia em malha possui redundância nativa das rotas de comunicação, permitindo que cada nó sensor possa se comunicar com os demais. Assim, possui diversas vias de comunicação com o nó coletor. Então, em princípio, não há prejuízo para a rede se um nó roteador falhar (perder comunicação). Entretanto, além do aumento de custo pela exigência de que todos os nós sensores tenham capacidade de recepção e transmissão, a topologia também promove aumento da latência¹ da rede devido à necessidade dos dados realizarem muitos saltos antes de chegarem ao nó coletor.

Uma topologia pode ainda agregar características das demais, formando uma

¹A latência é o tempo em que uma mensagem leva para sair do nó fonte e chegar até o nó destino.

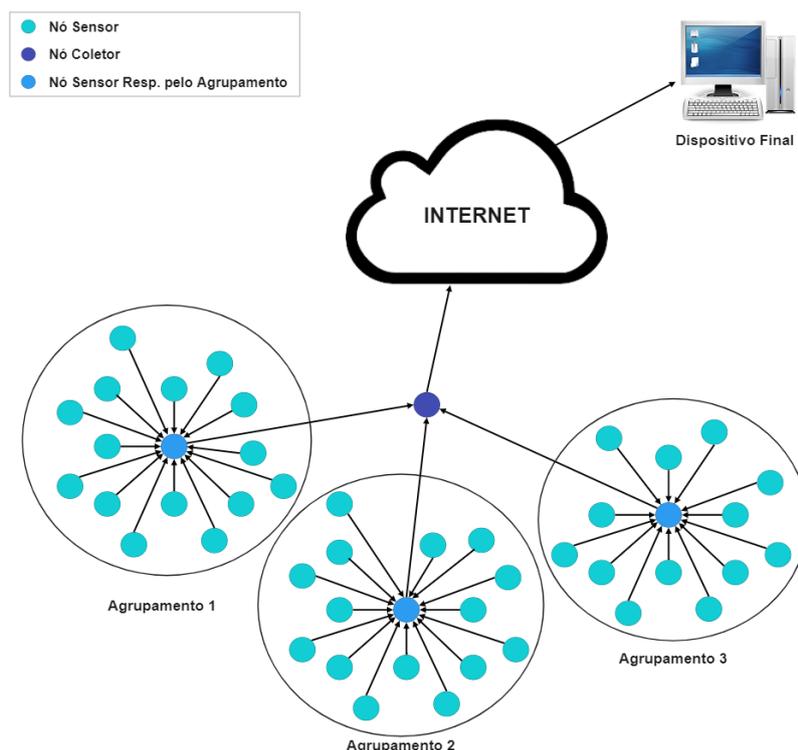


Figura 3 – Topologia em estrela com agrupamentos.
 Fonte: o próprio autor.

topologia mista. Topologias, mistas ou não, podem ser baseadas em agrupamentos (*clusters*), muito úteis para possibilitar a criação de redes maiores e diminuir problemas de infraestrutura decorrentes do crescimento da rede. Considerando uma formação de agrupamentos, uma RSSF é dividida em sub-redes, cada qual com uma topologia própria e uma extensão de comunicação que une as sub-redes com o nó coletor, como pode ser observado na Figura 3. O nó sensor principal de cada agrupamento é chamado de nó responsável pelo agrupamento (*cluster head* ou *cluster in charge*). Este nó sensor é responsável por receber e retransmitir as informações de outros nós sensores para o nó coletor, além de transmitir a própria informação sensoreada. A escolha entre diferentes tipos de topologia, e se haverá agrupamento na rede, não deve ser realizada de forma empírica ou aleatória. Tal escolha depende de fatores como: aplicação da rede, características do fenômeno a ser observado, características dos nós sensores disponíveis, características físicas do ambiente, questões físicas/químicas que podem impactar a comunicação entre outras [Shabbir and Hassan, 2017].

Esta pesquisa utiliza a topologia em estrela com agrupamentos, chamada também de topologia em estrela estendida, como ilustrada no exemplo apresentado na Figura 3.

Tanto a topologia em estrela estendida como a comunicação de salto único, descrita na Seção 1.2, seguem a especificação dos artigos-base [Brito et al., 2019, 2022].

1.4- Métodos de Otimização

Métodos de otimização são técnicas matemáticas e computacionais utilizadas para encontrar a solução ótima ou aproximada (subótima), dentro do conjunto de soluções viáveis para uma instância de um problema. Os métodos exatos têm por objetivo encontrar e certificar a solução ótima do problema. Pela premissa da garantia da otimalidade, podem não conseguir encontrar a solução para problemas de maior complexidade e/ou tamanho. As meta-heurísticas fazem parte dos métodos heurísticos, que também têm por objetivo a busca pela solução ótima, mas não garantem a otimalidade. Assim, pode-se dizer que fornecem soluções que refletem um compromisso entre qualidade e tempo computacional para determinado problema. Uma meta-heurística consiste num método de solução que organiza a interação entre procedimentos de melhoria local e estratégias de alto nível para criar um processo capaz de escapar do ótimo local e realizar uma busca robusta sobre a região factível [Hillier and Lieberman, 2010]. Meta-heurísticas possuem componentes genéricos que podem ser adaptados ao problema que se deseja resolver [Arroyo, 2002]. Existe também a Meta-Heurística Híbrida (MHH), método composto por uma meta-heurística e outros métodos, exatos ou heurísticos. O objetivo da construção de métodos híbridos é aproveitar o ponto forte de cada um dos tipos de métodos, na busca por soluções de maior qualidade [Ozkan et al., 2019].

Considerando métodos exatos, pode ser citado o artigo de Morais [2018], onde o objetivo é a otimização da comunicação interna da RSSF, maximizando o tempo de vida da rede pela minimização de custos nos agrupamentos e roteamentos. Para isso, é proposto um modelo de PLIM resolvido pelos algoritmos *Branch-and-bound* (BnB), *Branch-and-cut* (BnC) e *Column-and-row Generation*. Métodos heurísticos são mais comuns na literatura, com uso de várias técnicas diferentes. Abordagens por AG são apresentadas em Bhondekar et al. [2009] e Brito et al. [2019] e por AM em Ting and Liao [2010] e Brito et al. [2022]. Em Lee [2017], é utilizado e comparado o resultado de meta-heurísticas diferentes objetivando melhorar a alocação de energia em uma

RSSF. São utilizadas Otimização por Enxame de Partículas (OEP), Otimização por Colônia de Formigas (OCF) e Colônia Artificial de Abelhas (CAA). Por fim, o uso de MHH aparece em Ozkan et al. [2019], que define o PAS com restrição de energia e objetivo de confiabilidade da rede em duas partes. Na primeira parte, na alocação inicial dos sensores, o autor propõe um modelo de PLIM e utiliza BnB como solução. Na segunda parte, para a melhoria das soluções, utiliza abordagens diferentes, criando mais de um método para solucionar o problema: em um utiliza o AG e no outro utiliza o *Simulated Annealing* (SA).

1.5- Programação Linear Inteira Mista

A Programação Linear (PL) é uma área da otimização que objetiva maximizar ou minimizar uma função linear sujeita a um número finito de restrições lineares [Chvátal, 1983]. Na prática, a PL consiste na alocação e distribuição otimizada de recursos escassos por meio de variáveis de decisão, que representam atividades que competem por tais recursos, Função Objetivo (FO) e conjuntos de restrições [Hillier and Lieberman, 2010]. As variáveis de decisão indicam quais informações podem variar para que um melhor uso dos recursos seja verificado. As restrições fazem a tradução de limites do mundo real em equações e inequações que indicam qual é o espaço factível de soluções. Por fim, a FO quantifica a solução de um dado problema visando maximizar ou minimizar determinado critério, obtendo assim um resultado ótimo de solução. Quando as variáveis do problema assumem apenas valores discretos, trata-se de um problema de Programação Linear Inteira (PLI). Se as variáveis assumem valores discretos e contínuos, trata-se de um problema de Programação Linear Inteira Mista (PLIM) [Hillier and Lieberman, 2010].

1.6- Algoritmo Genético

O AG é uma meta-heurística que utiliza técnicas inspiradas na biologia evolutiva. No contexto do AG, um indivíduo representa uma solução para o problema a ser otimizado.

O indivíduo possui um cromossomo, que constitui o conjunto de dados que representam uma solução. Cada cromossomo é dividido em genes, que representam posições no cromossomo. O gene é responsável por armazenar um alelo, o qual armazena um dado, o menor nível de informação na representação do problema. Um grupo de indivíduos é chamado de população. A população é um conjunto de soluções para o problema abordado.

Cada indivíduo da população possui um valor de aptidão (ou apenas aptidão). A aptidão representa a qualidade da solução, constituída pelo indivíduo. Quanto maior é a aptidão de um indivíduo, maior é a qualidade da solução que ele representa. A principal ação de um AG é o processo evolutivo, que objetiva melhorar a aptidão dos indivíduos da população através dos operadores genéticos. A aplicação dos operadores genéticos gera novos indivíduos através do cruzamento e a mutação tem o objetivo de trazer maior diversidade aos indivíduos da população pela modificação de seus alelos de forma independente aos alelos originais, oriundos dos pais. A execução do processo evolutivo gera o conceito de geração, quando uma nova população surge após alterações realizadas sobre os indivíduos da população anterior.

As etapas padrões de um AG são ilustradas no fluxograma mostrado na Figura 4. A primeira etapa corresponde à geração da população inicial, grupo de indivíduos incluídos ou gerados aleatoriamente. A avaliação é a próxima etapa, responsável por calcular a aptidão de cada indivíduo. Em seguida, ocorre a seleção, etapa que seleciona pares de indivíduos da população para participar da aplicação dos operadores genéticos. Tais indivíduos são identificados como pais. As próximas etapas, o cruzamento e a mutação respectivamente, são os operadores genéticos responsáveis pela produção de indivíduos que poderão compor a população da próxima geração. Estas etapas (avaliação, seleção, cruzamento e mutação) são repetidas a cada geração até que se atinja o critério de parada, que pode ser um número limite de gerações ou a convergência da população, se essa puder ser apurada. Ao final de uma geração, o indivíduo mais apto da população atual é destacado e comparado com o indivíduo mais apto conhecido até então, e atualizado, de tal forma que o melhor indivíduo sempre é mantido durante o processo evolutivo. Ao final do processo, é esperado (desejado) que o indivíduo mais apto refira-se à solução ótima, ou então, a uma solução subótima para o problema em questão.

Outra etapa importante considerada neste trabalho, não descrita no diagrama, é a reinicialização. Após várias gerações sem melhoria do indivíduo mais apto, a população é

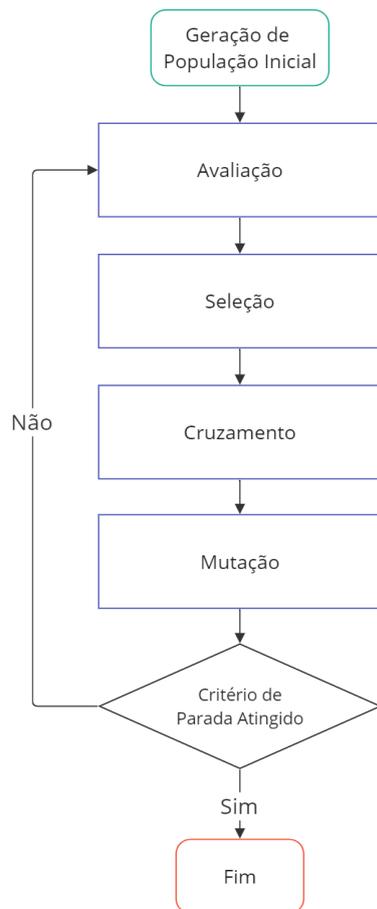


Figura 4 – Fluxograma com as etapas genéricas de um AG.
 Fonte: Adaptado de Hassanat et al. [2019].

reinicializada. A reinicialização gera uma população nova, a qual substitui a população da geração vigente, normalmente mantendo o indivíduo mais apto encontrado até então. Para diversos problemas, a reinicialização se faz necessária, pois o AG pode ter encontrado (e estar “preso” em) uma solução ótima local, ou seja, a melhor solução em um subespaço do problema, mas que não corresponde à solução ótima global, isto é, a melhor solução do problema. Com a reinicialização, este ótimo local pode ser superado, aumentando as chances de encontrar o ótimo global.

Existem diferentes técnicas de seleção em algoritmos populacionais, sendo a seleção por roleta [Srivastava and Sudarshan, 2015; Lee, 2017] e a seleção por torneio [Ting and Liao, 2010; Ozkan et al., 2019] bastante utilizadas na literatura. A seleção por roleta, conforme exemplo indicado na Figura 5, utiliza o valor de aptidão do indivíduo para aumentar ou diminuir a probabilidade de seleção. Quanto maior o valor, maior a chance de ser escolhido. O percentual de chance de seleção é gerado a partir da

porcentagem que o valor de aptidão do indivíduo possui sobre o valor de aptidão da população. O valor de aptidão da população é o somatório do valor de aptidão de todos os indivíduos da população. Já na seleção por torneio, dois indivíduos são escolhidos aleatoriamente e aquele com o maior valor de aptidão é selecionado.

Também existem diferentes opções para o operador de cruzamento, como o cruzamento de um ponto e o cruzamento multiponto. No cruzamento de um ponto, uma posição do cromossomo é escolhida para dividir os genes dos pais em duas partes, para então combiná-las e compor o cromossomo do filho. Já no cruzamento multiponto, dois ou mais pontos são escolhidos, sendo o filho gerado pela combinação das partes dos pais, conforme a divisão estabelecida pelos pontos. Neste caso, haverá no mínimo um pai que doará mais de uma parte do seu cromossomo ao filho. A mutação também possui técnicas diferentes de mudança de alelos nos genes, como a mutação de intercâmbio, quando dois genes aleatórios são escolhidos e os alelos trocados entre eles, e a mutação uniforme, quando um determinado gene escolhido tem o alelo alterado entre os alelos possíveis para aquele gene [Soni and Kumar, 2014].

Nesta pesquisa, a representação do indivíduo, a geração da população inicial e o cruzamento seguem os artigos-base [Brito et al., 2019, 2022]. A viabilização e a função de avaliação tiveram adaptações devido ao problema abordado. Já a seleção e a mutação foram alteradas com base em conhecimentos gerais da literatura como tentativa de obter melhoria na qualidade dos resultados.

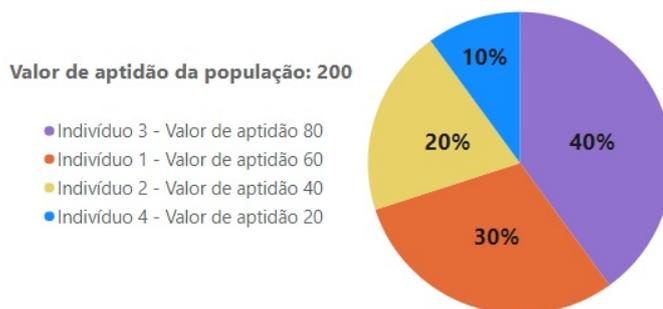


Figura 5 – Exemplo representativo da seleção por roleta indicando a chance de cada indivíduo ser selecionado, conforme o valor de aptidão de cada um frente ao valor de aptidão da população.

Fonte: O próprio autor.

2- Descrição e Formulação do Problema de Alocação de Sensores

Este capítulo apresenta detalhes sobre o PAS em estudo. A Seção 2.1 discorre sobre o PAS, a topologia e a configuração de comunicação dos nós sensores, trazendo a base necessária para o modelo matemático, descrito na Seção 2.2. Ao final, a Seção 2.3 indica os formatos de rede trabalhados nesta pesquisa e suas características.

2.1- Problema de Alocação de Sensores

O PAS traz como desafio a geração de uma topologia otimizada de uma RSSF, obtida pela alocação de nós sensores. Também é conhecido como Problema de Localização [Ishizuka and Aida, 2004] ou Implantação [Kim and Han, 2015] de Sensores. Uma das limitações ligadas às RSSFs que aparece mais frequentemente na literatura é a limitação energética dos nós sensores. Estudos sugerem mitigar a limitação energética através da geração de uma topologia que melhore o consumo de energia e aumente o tempo de vida de uma RSSF [Üster and Lin, 2011]. A topologia em estrela com agrupamentos (Figura 3) é utilizada nesta pesquisa com a existência de três tipos de nós sensores com características diferentes, identificados como X, Y e Z. O nó sensor do tipo X s_x é o nó responsável pelo agrupamento. Este tipo de nó sensor possui a função de sensor, concentra o recebimento das informações captadas por nós sensores de outros tipos e retransmite as informações até o nó coletor. O nó coletor recebe informações de cada s_x existente na rede e é o responsável por enviar a informação coletada para fora da rede, até o seu destino. Nesta pesquisa, a alocação do nó coletor não é considerada.

Os nós sensores dos tipos Y s_y e Z s_z transmitem as informações obtidas via sensor para s_x por uma conexão direta. Todo s_z possui capacidade de conexão na distância padrão, de 1 salto, e todo s_y possui a capacidade de conexão na distância que equivale a 2 saltos. Um exemplo da distância (alcance) de comunicação destes nós

sensores é ilustrado na Figura 6. O custo energético dos nós sensores é estabelecido de forma genérica, sem grandeza energética real definida. Esta generalização atende a premissa da pesquisa de não ser específica sobre características físicas de nós sensores reais. Dado os alcances e funcionalidades dos tipos de nós sensores, o custo energético de sx é o dobro do custo energético de sy e o custo energético de sy é o dobro do custo energético de sz . Estas informações estão sumarizadas na Tabela 2.

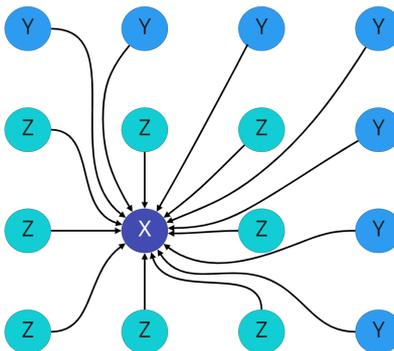


Figura 6 – Exemplo de comunicação entre os tipos de nós sensores considerados.
Fonte: Adaptado de Brito et al. [2022] pelo autor.

Tabela 2 – Características dos tipos de nós sensores.

Nó sensor	Possui sensor	Envia dados	Recebe dados	Conexão com	Alcance interno (em saltos)	Custo energético
sx	Sim	Sim	Sim	Nó coletor	-	4
sy	Sim	Sim	Não	sx	2	2
sz	Sim	Sim	Não	sx	1	1

Fonte: o próprio autor.

Um tipo de nó sensor hipotético W, que existe nos artigos-base [Brito et al., 2019, 2022], não é utilizado nesta pesquisa. Este tipo de nó sensor representa a ausência ou inatividade de um nó sensor. Esta pesquisa foca na geração/criação de uma topologia com alocação determinada dos nós sensores e, por isso, é imperativo que a rede gerada tenha indicação de todas as suas posições com os nós sensores em funcionamento. Os demais tipos de nós sensores seguem a especificação dos artigos-base.

2.2- Modelo Matemático

O conjunto de posições possíveis na rede a serem ocupadas por nós sensores é indicado por $V = \{1, 2, \dots, n\}$ e o conjunto dos tipos de nós sensores considerados neste estudo é definido por $S = \{sx, sy, sz\}$. A FO é apresentada na Equação (1), pela qual se deseja minimizar o custo total de energia da rede. Para isso, a variável binária $p_i^s = 1$ indica se um nó sensor do tipo $s \in S$ foi alocado na posição $i \in V$ da rede. Por fim, define-se c_s como o vetor de custo energético de s . Os valores utilizados podem ser visualizados na Tabela 2.

$$\min \sum_{i \in V} \sum_{s \in S} c_s p_i^s \quad (1)$$

As restrições de conectividade podem ser mapeadas originalmente pelas Inequações (2), que garantem a conectividade da rede: cada i deve ser ocupada, ou por um sx , ou por outro tipo de nó sensor (sx ou sz) que se comunique com sx , em sua vizinhança. A vizinhança de i para cada s é mapeada no conjunto de posições vizinhas C_i^s . Essa restrição, porém, é quadrática. Visando utilizar técnicas de PLIM, a restrição foi linearizada e as Inequações (2) não estão presentes no modelo final, sendo substituídas pelas restrições das Inequações (3)–(6).

s.a :

$$p_i^{sx} + \sum_{s \in S \setminus \{sx\}} p_i^s \sum_{j \in C_i^s} p_j^{sx} \geq 1 \quad \forall i \in V \quad (2)$$

Para linearização, a expressão quadrática na Inequação (2) foi substituída por variáveis de apoio α_i^s como definido nas Inequações (3). Assim, $\alpha_i^s = 1$ indica quando um sensor não é responsável pelo agrupamento, mas possui um sensor responsável pelo agrupamento em sua vizinhança. As Inequações (4), (5) e (6) restringem α_i^s de forma linear. Em seguida, temos as restrições apresentadas em (7), que garantem que apenas um s será alocado em cada i . Por fim, as restrições apresentadas em (8) e (9) indicam o domínio das variáveis p e α respectivamente. Desta forma, o modelo matemático completo é descrito por (1), como a FO, e sujeito às restrições em (3)–(9).

s.a :

$$p_i^{sx} + \sum_{s \in S \setminus \{sx\}} \alpha_i^s \geq 1 \quad \forall i \in V \quad (3)$$

$$\alpha_i^s \leq p_i^s |C_i^s| \quad \forall i \in V, s \in S \setminus \{sx\} \quad (4)$$

$$\alpha_i^s \leq \sum_{j \in C_i^s} p_j^{sx} \quad \forall i \in V, s \in S \setminus \{sx\} \quad (5)$$

$$\alpha_i^s \geq \sum_{j \in C_i^s} p_j^{sx} - (1 - p_i^s) |C_i^s| \quad \forall i \in V, s \in S \setminus \{sx\} \quad (6)$$

$$\sum_{s \in S} p_i^s = 1 \quad \forall i \in V \quad (7)$$

$$p_i^s \in \{0, 1\} \quad \forall i \in V, s \in S \quad (8)$$

$$\alpha_i^s \in \mathbb{R}_+ \quad \forall i \in V, s \in S \setminus \{sx\} \quad (9)$$

As conexões possíveis entre os nós sensores em uma rede de formato regular são primariamente entre os nós sensores próximos, nas direções horizontal, vertical e diagonal, na distância de 1 salto. Esta é a configuração de sz para se conectar a sx . Já sy possui capacidade de conexão à distância de 2 saltos, alcançando nós sensores além dos nós sensores mais próximos. As vizinhanças de sz e sy são mapeadas em C_i^s , conforme definido pelas Equações (10) e (11) e pela relação de pertinência da Expressão (12), que exclui a posição do próprio sensor de sua vizinhança. As funções \max e \min trazem respectivamente o maior e o menor valor dentre dois valores apresentados e qh_s o alcance em saltos de s . As posições horizontal e vertical de um nó sensor são representadas por h_i e v_i , descritas pelas Equações (15) e (16) e explicadas na Seção 2.3. A Figura 7 traz um exemplo da composição de vizinhança.

$$C_i^s = \{h_{\max(1, h_i - qh_s)}, \dots, h_{\min(l, h_i + qh_s)}\} \quad \forall i \in V, s \in S \setminus \{sx\} \quad (10)$$

$$C_i^s = C_i^s \cap \{v_{\max(1, v_i - qh_s)}, \dots, v_{\min(l, v_i + qh_s)}\} \quad \forall i \in V, s \in S \setminus \{sx\} \quad (11)$$

$$i \notin C_i^s \quad \forall i \in V, s \in S \setminus \{sx\} \quad (12)$$

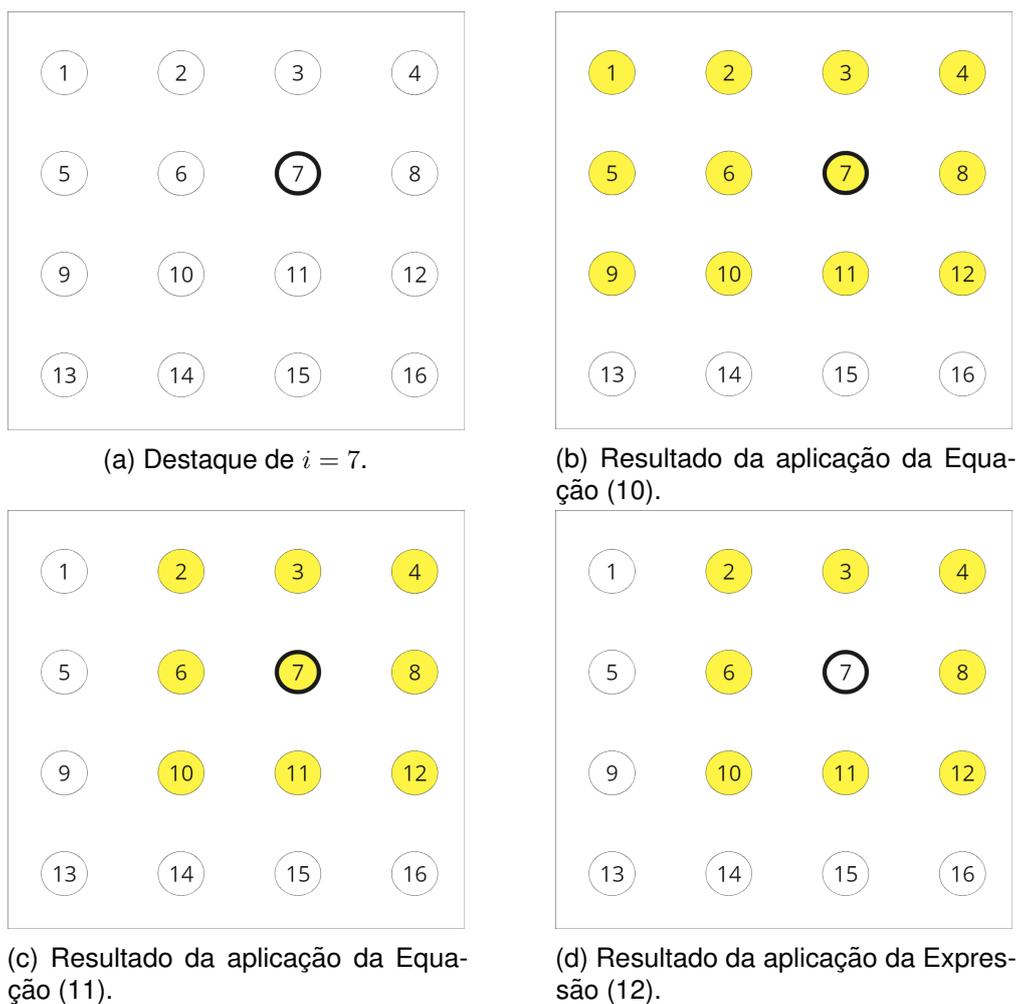


Figura 7 – Exemplo da composição de vizinhança em C_i^s para $i = 7$ e $s = sz$ numa rede de formato regular com $l = 4$.

Fonte: o próprio autor.

2.3- Formatos de Rede

Neste trabalho, são considerados três formatos distintos de rede (instâncias) para o PAS, nomeados como: (i) regular, (ii) semirregular e (iii) irregular. Em uma rede de formato regular, todos os lados possuem o mesmo tamanho. Neste formato, as possibilidades de comunicação na distância de um salto para os nós vizinhos existem nas direções horizontal, vertical e diagonal. Em um cenário real, esta estrutura indica uma RSSF quadrada sem fatores impeditivos à conexão entre os nós sensores próximos. O formato semirregular mantém a forma regular, com os lados de mesmo tamanho,

porém a comunicação possível entre nós sensores vizinhos é seletiva, podendo existir ou não. Trata-se de uma RSSF quadrada com obstáculos que impedem a comunicação entre alguns nós sensores próximos. Por fim, no formato irregular, a rede possui forma indefinida, com o posicionamento geográfico sendo indicado nó a nó, bem como a comunicação entre estes nós, assim como no formato semirregular.

No formato regular, o tamanho do lado (ou apenas lado) da rede é identificado por l e a quantidade total de nós sensores por n conforme a Equação (13). Inversamente, l pode ser definido por $\sqrt{n} = l$. A quantidade de conexões é identificada por ne . O cálculo de ne para redes de formato regular é demonstrado pela Equação (14). Nessa equação, temos a soma de duas expressões. Na primeira, relativa às conexões horizontais e verticais, o lado é multiplicado pelo lado anterior $l_{ant} = l - 1$ e multiplicado por 2, que representa o formato quadrado. Na segunda expressão, relativa às conexões na diagonal, a quantidade de quadrados mínimos internos da rede, estes formados por quatro nós sensores vizinhos, é calculado por $l_{ant} \times l_{ant}$ e multiplicado pela quantidade de conexões internas na diagonal, 2 conexões em cada quadrado mínimo interno.

$$n = l \times l \quad (13)$$

$$ne = (l \times l_{ant} \times 2) + (l_{ant} \times l_{ant} \times 2) \quad (14)$$

O conjunto de índices de l é indicado pela variável $L = \{1, 2, \dots, l\}$, importante para indicar o posicionamento dos sensores no formato regular. Ainda neste formato, o posicionamento horizontal e vertical são definidos por $\{h_i, v_i\} \in L$ respectivamente, como indicado pelo Conjunto de Equações condicionais (15) e (16). O operador módulo, que calcula o resto da divisão, é representado por mod . A alocação de um nó sensor na posição horizontal é de cima para baixo e na vertical da esquerda para a direita.

$$h_i = \begin{cases} l, & \text{se } i \text{ mod } l = 0 \\ i \text{ mod } l, & \text{caso contrário} \end{cases} \quad (15)$$

$$v_i = \begin{cases} i/l, & \text{se } i \text{ mod } l = 0 \\ [i/l] + 1, & \text{caso contrário} \end{cases} \quad (16)$$

As redes de formato regular, devido às regras de estrutura e conexão, são mapeadas matematicamente nesta pesquisa através da indicação de l . Já as redes de formatos semirregular e irregular são chamadas de não regulares, devido a variações possíveis nas

conexões e, no caso do formato irregular, também no posicionamento. Assim, a entrada de ambas diferem da regular.

As redes de formatos não regulares são mapeadas com apoio dos conceitos da teoria de grafos. Considera-se um grafo ponderado $G(V, E)$, no qual V é o conjunto dos n vértices e E é o conjunto das m arestas [Bondy and Murty, 1976]. Nesta representação, um vértice $i \in V$ representa um nó sensor e possui dados das suas coordenadas horizontal h e vertical v como informação (h, v) . O posicionamento geográfico destas estruturas seguem o padrão cartesiano. Uma aresta $(i, j) \in E$ representa uma conexão de 1 salto de distância entre os nós sensores i e $j \in V$. Exemplos dos formatos regular e não regulares podem ser visualizados na Figura 8.

Em Ozkan et al. [2019], são tratadas apenas redes de formato regular e os tamanhos são definidos para $l = \{10, 20, 30\}$ como instâncias de portes pequeno, médio e grande, respectivamente. Porém, não foi observado um padrão para portes na literatura. Assim, na ausência de uma definição padrão, são definidos três portes de redes nesta pesquisa: redes de pequeno porte, com $n = \{1, 2, \dots, 100\}$, redes de médio porte, com $n = \{101, 102, \dots, 900\}$ e redes de grande porte, com $n = \{901, 902, \dots, \infty\}$. No formato regular, redes de pequeno porte possuem $l = \{1, 2, \dots, 10\}$, de médio porte $l = \{11, 12, \dots, 30\}$ e de grande porte $l = \{31, 32, \dots, \infty\}$.

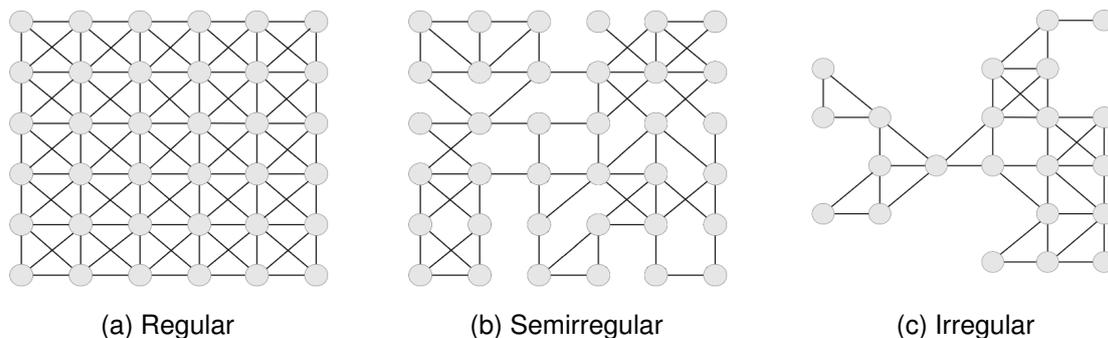


Figura 8 – Exemplos dos formatos de rede utilizados nesta pesquisa.

Fonte: o próprio autor.

3- Algoritmo Genético para Solução do Problema de Alocação de Sensores

Este capítulo descreve de forma específica as etapas do AG implementado para otimizar o PAS descrito nesta pesquisa. O AG representa o método heurístico escolhido. Genericamente, o AG é descrito anteriormente, na Seção 1.6. Neste capítulo, a Seção 3.1 apresenta como os conceitos do AG foram implementados. A Seção 3.2 discute sobre a geração da população inicial. A Seção 3.3 mostra o procedimento desenvolvido para tornar viável os indivíduos da população. A Seção 3.4 define a função de avaliação. As Seções 3.5–3.8 apresentam respectivamente informações sobre a implementação das etapas de Seleção, Cruzamento, Mutação e Reinicialização. A Seção 3.9 discute sobre funções que auxiliam os processos maiores. Por último, a Seção 3.10 detalha os hiperparâmetros do AG.

3.1- Representação

Como representação do problema, uma população P é um conjunto composto por indivíduos I . Cada I representa uma topologia de RSSF viável (solução factível) para o PAS. Cada indivíduo I possui um cromossomo V composto por posições internas $V = \{1, 2, \dots, i, \dots, n\}$, chamadas genes. Cada gene $i \in V$ armazena obrigatoriamente um e apenas um alelo $s \in S$, representados com os valores naturais $\{0, 1, 2\}$ que são a codificação para $\{sx, sy, sz\}$, respectivamente. A Figura 9 mostra um exemplo de indivíduo com a codificação descrita.

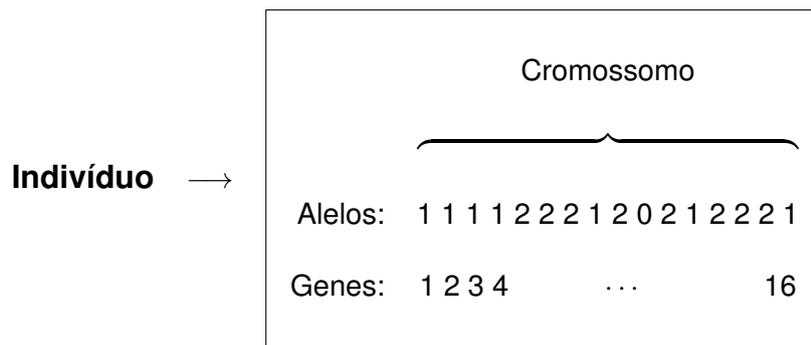


Figura 9 – Representação de um indivíduo equivalente à rede apresentada na Figura 6.
 Fonte: Adaptado de Brito et al. [2022].

3.2- Geração da População Inicial

Uma heurística construtiva aleatória é usada para gerar uma população inicial de indivíduos. O Algoritmo 1 começa com a população P vazia e gera um indivíduo I por iteração até que se complete a quantidade indicada em P_{size} , correspondente ao tamanho da população. Cada I é inicializado vazio e um s é alocado em cada i de seu cromossomo. Cada s possui uma probabilidade de ser alocado. Os hiperparâmetros $\{sxrate, syrate, szrate\}$, detalhados na Seção 3.9, indicam as probabilidades. Esta heurística, por ter uma característica aleatória, não garante que os indivíduos gerados, a princípio, representem uma solução viável, como é mandatório, conforme indicação na modelagem do problema (Seção 3.1). Então, antes da função de avaliação (Seção 3.4), um processo de viabilização é executado, conforme descrito na Seção 3.3.

 Algoritmo 1 – Gerador de População Inicial.

Entrada:
 Tamanho da população P_{size}
 Tamanho do cromossomo n
 Taxa de geração inicial de X sx_{rate}
 Taxa de geração inicial de Y sy_{rate}
 Taxa de geração inicial de Z sz_{rate}

Saída:
 População inicial P

```

1 Início
2    $P \leftarrow \emptyset$ 
3    $sumRate \leftarrow sx_{rate} + sy_{rate} + sz_{rate}$ 
4   enquanto ( $|P| \leq P_{size}$ ) faça
5      $I \leftarrow \emptyset$ 
6     para ( $i \leftarrow 1$  até  $n$ ) faça
7        $R \leftarrow RandomFrac(0, sumRate)$ 
8       se ( $R \leq sx_{rate}$ ) então
9          $I_i \leftarrow sx$ 
10      senão se ( $R \leq sx_{rate} + sy_{rate}$ ) então
11         $I_i \leftarrow sy$ 
12      senão
13         $I_i \leftarrow sz$ 
14     $P \leftarrow P \cup \{I\}$ 
  
```

Fonte: Adaptado de Brito et al. [2022].

3.3- Viabilização

A viabilização é o processo que garante que cada indivíduo represente uma solução viável para o problema, atendendo às suas restrições. Assim, visando comprovar a viabilidade ou tornar viável um indivíduo que não esteja viável, o conjunto de restrições do modelo deve ser garantido. A restrição de alocação, que indica que uma posição na rede deve ser ocupada por um e apenas um nó sensor, é garantida pela geração da população inicial, na Seção 3.2. Já a restrição de conectividade é implementada no processo de viabilização do indivíduo, descrito no Algoritmo 2. Caso I_i esteja ocupado por um s que não possua a conectividade conforme modelo do problema, a seguinte regra de viabilidade de conexão é aplicada:

- Se $I_i = sz$, aleatoriamente $I_i \leftarrow sy$ ou $I_i \leftarrow sx$;
- Se $I_i = sy$, então $I_i \leftarrow sx$.

As regras descritas acima alteram alelos e são repetidas, em etapas, até que as restrições de conectividade sejam atendidas. Assim, cada indivíduo comprova ou se torna viável e a função de avaliação é executada em seguida, para todos os indivíduos da população.

Algoritmo 2 – Processo de Viabilização de Indivíduo.

Entrada:
Indivíduo I

Saída:
Indivíduo viável I

```

1 Início
2    $fact \leftarrow false$ 
3   enquanto ( $\neg fact$ ) faça
4      $OutR \leftarrow CheckCon(I)$ 
5     se ( $|OutR| = 0$ ) então
6        $fact \leftarrow true$ 
7     senão
8       para ( $j \leftarrow 1$  até  $\frac{|OutR|}{2}$ ) faça
9          $R \leftarrow RandomInt(1, |OutR|)$ 
10         $i \leftarrow OutR[R]$ 
11        se ( $I_i = sz$ ) então
12           $I_i \leftarrow GetAnotherSensor(sz)$ 
13        senão
14           $I_i \leftarrow sx$ 

```

Fonte: o próprio autor.

3.4- Função de Avaliação

A função de avaliação é responsável por calcular o valor de aptidão *fitness* do indivíduo. O *fitness* é calculado para todo I , um a um, sempre (i) após a geração da população inicial e (ii) após a geração de uma nova população por reinicialização, para os novos indivíduos da população gerada, e (iii) para cada filho após aplicação dos operadores genéticos. A função de avaliação adotada neste estudo é o valor negativo

da FO, como descrito na Equação (17). Relembrando, e integrando o contexto do AG, a variável $p_i^s \in \{0, 1\}$ recebe o valor 1 quando há um alelo s em um gene i do indivíduo. A variável c_s representa o custo energético de s , conforme Tabela 2. Aplicando a subtração, o menor valor gerado pela FO se torna o maior valor de aptidão, se comparado à aptidão de outros indivíduos. Como a aptidão representa o quão bem-adaptado é um indivíduo na população, quanto maior o seu valor, melhor. Porém, para problemas de minimização, não é possível usar o valor da FO e atender a esta definição importante no contexto de AGs. A escolha da função de aptidão como descrita evita possíveis problemas com arredondamentos, o que ocorre quando se usa o cálculo do inverso da FO.

$$I_{fitness} = - \left(\sum_{i \in V} \sum_{s \in S} c_s p_i^s \right) \quad (17)$$

3.5- Seleção

O método de seleção utilizado é a seleção por roleta. Como este é um problema de minimização e a função de avaliação traz valores negativos, o método de seleção por roleta precisou ser adaptado. A solução implementada altera o *fitness* usado no método para o *fitSel*, calculado conforme indicado na Equação (18). Utilizam-se valores absolutos e a diferença entre as aptidões para aumentar a margem dos mais aptos, para uma qualificação maior destes indivíduos que tinham um valor absoluto menor. A variável $wFitPop$ traz o pior valor de aptidão entre todos os indivíduos da população.

$$I_{fitSel} = 2 \times |wFitPop| - |I_{fitness}| \quad (18)$$

No processo de seleção, foi adotada a estratégia de escolha de todos os indivíduos da população atual na construção da próxima geração. Assim, o hiperparâmetro com a taxa de seleção não é utilizado nesta pesquisa. Caso o procedimento de seleção escolha um indivíduo já selecionado anteriormente, recupera-se o próximo indivíduo disponível ainda não escolhido, na ordem de aptidão da maior para a menor.

O Algoritmo 3 mostra o pseudocódigo do operador de seleção. A variável P_{aux} possui os indivíduos que ainda podem ser escolhidos enquanto P possui todos os

indivíduos da população. O conjunto dos pais D é retornado ao final e seu conteúdo possui os indivíduos da população, organizado em pares de pais. Assim, a primeira e a segunda posição da lista correspondem ao primeiro par de pais $\{I_1, I_2\}$. A terceira e quarta posição ao segundo par de pais e assim por diante. As primeiras seleções têm chances maiores de gerar filhos mais aptos, devido à probabilidade do método utilizado e à disponibilidade maior de indivíduos mais aptos antes que estes indivíduos sejam escolhidos em uma seleção anterior e não estejam disponíveis para as próximas escolhas.

Algoritmo 3 – Seleção.

Entrada:
População P

Saída:
Lista de pais D

```

1 Início
2    $D \leftarrow \emptyset$ 
3    $P_{aux} \leftarrow P$ 
4   para ( $j \leftarrow 1$  até  $\lfloor \frac{|P|}{2} \rfloor$ ) faça
5     para ( $k \leftarrow 1$  até 2) faça
6        $I \leftarrow Roulette(P, P_{aux})$ 
7        $P_{aux} \leftarrow P_{aux} - \{I\}$ 
8        $D \leftarrow D \cup \{I\}$ 

```

Fonte: o próprio autor.

3.6- Cruzamento

A forma de cruzamento adotada é o cruzamento de dois pontos, como no exemplo da Figura 10. Duas posições cr_{p1} e cr_{p2} são escolhidas sobre o cromossomo de maneira equivalente para o par de pais $\{I_1, I_2\}$, escolhidos na seleção, de forma que $1 \leq cr_{p1} < cr_{p2} \leq n$. Esse operador deve ser aplicado a $n \geq 3$, que significa $l > 1$ em redes de formato regular. Considerando I_1 , todo conteúdo das posições $i \leq cr_{p1}$ e $i \geq cr_{p2}$ é copiado para cada i equivalentes no filho I_0 . Cada posição interna $cr_{p1} < i < cr_{p2}$ do indivíduo I_2 é copiado para i equivalentes em I_0 , compondo assim um cromossomo completo de um novo indivíduo. Existe ainda a probabilidade do cruzamento não ocorrer e ambos os pais seguirem para a próxima geração sem gerar um filho, através da taxa de cruzamento cz_{rate} . O Algoritmo 4 traz as etapas referentes ao cruzamento.

```

pai1: 120 200011 1201022
pai2: 220 120100 2201010

filho: 120 120100 1201022

```

Figura 10 – Exemplo de cruzamento de dois pontos.
 Fonte: Adaptado de Brito et al. [2022].

Algoritmo 4 – Cruzamento.

```

Entrada:
  Primeiro pai  $I_1$ 
  Segundo pai  $I_2$ 
  Tamanho do cromossomo  $n$ 

Saída:
  Filho  $I_0$ 

1 Início
2    $I_0 \leftarrow \emptyset$ ;
3    $cr_{p1} \leftarrow \text{RandomInt}(1, n - 2)$ 
4    $cr_{p2} \leftarrow \text{RandomInt}(cr_{p1} + 2, n)$ 
5   para ( $i \leftarrow 1$  até  $cr_{p1}$ ) faça
6      $I_0[i] \leftarrow I_1[i]$ 
7   para ( $i \leftarrow cr_{p1} + 1$  até  $cr_{p2} - 1$ ) faça
8      $I_0[i] \leftarrow I_2[i]$ 
9   para ( $i \leftarrow cr_{p2}$  até  $n$ ) faça
10     $I_0[i] \leftarrow I_1[i]$ 

```

Fonte: Adaptado de Brito et al. [2022].

3.7- Mutação

A mutação utilizada nesta pesquisa é a mutação uniforme. De acordo com uma probabilidade de escolha para mutação $m_{O_{rate}}$, o filho pode ser escolhido para mutação. Se o filho for escolhido, seus genes, um a um, são verificados com uma probabilidade de mutação m_{rate} para sofrerem mutação. A mutação troca um alelo por outro, ou seja, um tipo de nó sensor por outro de forma aleatória. A Figura 11 demonstra os alelos de um cromossomo sofrendo mutações e o Algoritmo 5 apresenta o pseudocódigo deste processo.

Antes da mutação: 1001201001201022
 ↓ ↓ ↓
 Depois da mutação: 1021201000201020

Figura 11 – Exemplo da mutação em um filho.

Fonte: Adaptado de Brito et al. [2022].

Algoritmo 5 – Mutação.

Entrada:
 Filho I_0
 Tamanho do cromossomo n

Saída:
 Filho com mutação I_0

- 1 **Início**
- 2 **para** ($i \leftarrow 1$ até n) **faça**
- 3 $R \leftarrow RandomFrac(0, 1)$
- 4 **se** ($R \leq m_{rate}$) **então**
- 5 **se** ($I_{0[i]} = sz$) **então**
- 6 $I_{0[i]} \leftarrow GetAnotherSensor(sz)$
- 7 **senão se** ($I_{0[i]} = sx$) **então**
- 8 $I_{0[i]} \leftarrow GetAnotherSensor(sx)$
- 9 **senão se** ($I_{0[i]} = sy$) **então**
- 10 $I_{0[i]} \leftarrow GetAnotherSensor(sy)$

Fonte: Adaptado de Brito et al. [2022].

3.8- Reinicialização

A reinicialização ocorre após um número pré-determinado de gerações sem que haja um novo indivíduo mais apto, se comparado ao mais apto até o momento. O hiperparâmetro com esta informação foi dividido em dois nesta pesquisa: Gen_{res1} com a quantidade de gerações até a primeira reinicialização, quando nenhuma reinicialização ocorreu a partir da geração de população inicial, e Gen_{res2} com a quantidade de gerações para as demais reinicializações, após esta primeira. Essa divisão foi realizada, pois, na primeira reinicialização, supõe-se que seja necessário menos tentativas de evolução do indivíduo mais apto, visto que a avaliação do restante dos indivíduos da população está

mais próxima do mais apto. Assim, há uma tendência de gerar um filho mais apto em menos gerações, caso haja a possibilidade de evolução. Porém, após uma reinicialização de população, a avaliação do indivíduo mais apto anterior à reinicialização (que já sofreu processos evolutivos) tende a ser maior que a dos indivíduos da nova população. A nova população precisa de mais gerações para evoluir os seus indivíduos para comparação com o mais apto anterior.

3.9- Funções Auxiliares

Existem funções que suportam os processos principais do AG implementado, descritas nas seções anteriores deste capítulo. Essas funções podem aparecer em textos ou nos algoritmos citados. Duas funções para geração de informações aleatórias são utilizadas. Ambas as funções geram números aleatórios entre o primeiro e o segundo parâmetro, sendo que *RandomInt* gera números inteiros e *RandomFrac* gera números fracionados. A função *RandomInt* é utilizada diretamente nos Algoritmos 2 e 4 e nas funções auxiliares *GetAnotherSensor* e *Roulette*, descritas posteriormente nesta seção. A função *RandomFrac* é utilizada diretamente nos Algoritmos 1 e 5 e citada indiretamente na Seção 3.6, devido ao uso do hiperparâmetro cz_{rate} . A função *GetAnotherSensor* (Algoritmos 2 e 5) retorna um nó sensor que não seja o indicado pelo parâmetro, de forma aleatória. Para isso, utiliza internamente a função *RandomInt*. A função *CheckCon* implementa a restrição de conectividade da rede. Esta função é utilizada no Algoritmo 2 e seu funcionamento é descrito na Seção 3.3. A função *Roulette* implementa o método de seleção. Recebe os parâmetros P e P_{aux} . Com a soma de todos os valores de *fitSel* de P , a função *RandomFrac* retorna um valor, que é verificado neste espaço de valores. Como os mais aptos ocupam um espaço maior na soma, possuem maior probabilidade de serem escolhidos. Em seguida, para o I que ocupa a posição escolhida em P , é verificada a sua disponibilidade em P_{aux} . Caso esteja disponível, é retornado. Caso não esteja, é retornado o próximo indivíduo disponível. Como o *fitSel* possui valores inteiros, a função *RandomInt* poderia ser usada ao invés da *RandomFrac*.

3.10- Hiperparâmetros

Os hiperparâmetros são muito importantes na qualidade do resultado de um AG. O termo “hiperparâmetro” ficou popular na área de aprendizado de máquina sendo usado para definir parâmetros que possuem relação direta com a qualidade da solução do problema, sem que haja mudança estrutural na abordagem em questão. Os hiperparâmetros implementados no AG nesta pesquisa são descritos na Tabela 3. O hiperparâmetro $P_{size} \in \mathbb{N}^*$ define o tamanho da população, ou seja, a quantidade de indivíduos da população. Este hiperparâmetro recebe valores condicionados a (i) $P_{size} \bmod 2 = 0$. Quando esta condição não é atendida, o AG aplica a instrução (ii) $P_{size} \leftarrow P_{size} + 1$. A restrição (i) e a instrução (ii) garantem o funcionamento da seleção como implementada nesta pesquisa.

O valor contido em $Gen_{num} \in \mathbb{N}^*$ define a quantidade de gerações, isto é, o número de vezes que a população passará por processos evolutivos. Os hiperparâmetros $\{Gen_{res1}, Gen_{res2}\} \in \mathbb{N}$ indicam a quantidade de gerações em sequência sem alteração do indivíduo mais apto até a reinicialização da população. O primeiro atende apenas à primeira reinicialização, enquanto o segundo atende às outras reinicializações, da segunda em diante. O hiperparâmetro $Res_{num} \in \mathbb{N}$ indica a quantidade de reinicializações de população máxima que poderá ocorrer ao longo da execução.

Há também hiperparâmetros que garantem probabilidade às ações de evolução, ligados aos operadores genéticos. O hiperparâmetro $cz_{rate} \in \mathbb{R}_+$ é descrito na Seção 3.6 e os hiperparâmetros $\{m_{o_{rate}}, m_{rate}\} \in \mathbb{R}_+$ na Seção 3.7. Na geração da população inicial ou da população reiniciada, os indivíduos recebem os alelos conforme a probabilidade contida em $\{sx_{rate}, sy_{rate}, sz_{rate}\} \in \mathbb{R}_+$ para sx , sy e sz respectivamente. Estes hiperparâmetros têm os valores $sx_{rate} + sy_{rate} + sz_{rate} > 0$ e aparecem descritos na Seção 3.2.

Tabela 3 – Relação de hiperparâmetros do AG.

Hiperparâmetro	Descrição	Entidade
<i>P_{size}</i>	Tamanho da população	População
<i>Gen_{num}</i>	Quantidade de gerações	Geração
<i>Gen_{res1}</i>	Quantidade de gerações até a primeira reinicialização	Geração
<i>Gen_{res2}</i>	Quantidade de gerações até uma reinicialização (da segunda em diante)	Geração
<i>Res_{num}</i>	Quantidade de reinicializações	Reinicialização
<i>cz_{rate}</i>	Taxa de cruzamento	Indivíduo
<i>mO_{rate}</i>	Taxa de escolha do indivíduo para mutação	Indivíduo
<i>m_{rate}</i>	Taxa de mutação	Gene
<i>sx_{rate}</i>	Taxa de geração inicial de X	Gene
<i>sy_{rate}</i>	Taxa de geração inicial de Y	Gene
<i>sz_{rate}</i>	Taxa de geração inicial de Z	Gene

Fonte: o próprio autor

4- Resultados

Este capítulo traz informações e resultados da otimização do PAS descrito nesta pesquisa, denominado apenas como PAS, pelas abordagens exata e heurística, para instâncias de pequeno, médio e grande portes, de formatos regular e não regulares. Uma RSSF disponível para otimização ou já otimizada é denominada instância (ou instância de rede) e possui a diferença entre abordagens, portes e formatos informados, sempre que necessário. A Seção 4.1 apresenta informações sobre tecnologias utilizadas e sobre o ambiente, estrutura e definições gerais da execução e resultados da otimização. A Seção 4.2 mostra informações referentes à otimização do PAS pela abordagem exata, para redes de formato regular. Em seguida, a Seção 4.3 apresenta e discute a otimização dos hiperparâmetros do AG. A Seção 4.4 é semelhante à Seção 4.2, descrevendo informações da otimização do PAS, mas com aplicação do AG. A Seção 4.5 compara as informações da otimização em instâncias de formato regular entre as abordagens (exata e heurística). A Seção 4.6 discorre sobre a otimização das instâncias de formatos não regulares e compara a otimização em todos os formatos (regular, semirregular e irregular), de ambas as abordagens. Por último, a Seção 4.7 apresenta e discute resultados de otimização, com alocação otimizada dos nós sensores, de instâncias comparadas pela Seção 4.6.

4.1- Estrutura e Execução da Otimização

Para otimização do PAS pelo método exato, é utilizado um *Solver*, um software específico para resolução de problemas matemáticos. O *Solver* escolhido foi o IBM CPLEX, versão 20.1. Um algoritmo é responsável pela entrada e saída dos parâmetros do modelo e da instância e pela execução do *Solver*. Após receber via parâmetros as variáveis de decisão, restrições e FO, o *Solver* define a melhor forma possível de resolver o problema. O *Solver* permite nativamente o processamento paralelo, mas foi configurado para processamento sequencial, para equivalência com o AG, já que o

AG não foi implementado com paralelismo. No intuito de obter melhores configurações para os hiperparâmetros do AG, foi utilizado o programa *Iterated Racing for Automatic Algorithm Configuration* (iRace) [López-Ibáñez et al., 2016].

Tanto o algoritmo responsável pela utilização do *Solver* como o AG foram desenvolvidos na linguagem C++ no IDE Microsoft Visual Studio Community 2019, versão 16.11.5, com Visual C++ 2019 e Microsoft .NET Framework versão 4.8.09032. O iRace é uma biblioteca na linguagem R e foi utilizada nesta pesquisa a partir de um algoritmo desenvolvido também em linguagem R, no IDE RStudio versão 2022.02.1 *build* 461. Foi utilizado o sistema operacional Windows 11 Home, 64 bits versão 22H2 em um computador com processador Intel i7-8565U com 4 núcleos de 1,80 GHz e 8 *threads* e memória RAM de 8 GB, tanto para desenvolvimento como para otimização.

Para redes de formato regular, a instância é gerada nos algoritmos de ambas abordagens, pela informação contida em l . Já para redes de formatos não regulares, a instância da rede é informada aos algoritmos por meio de arquivo com informações $G(V, E)$. As otimizações foram realizadas 30 vezes para cada instância de cada abordagem/porte/formato descrita na pesquisa. Para todas as otimizações realizadas, foram calculadas a média (M_e) e a mediana¹ (M_d) do tempo de execução, sendo a comparação entre métodos diferentes feitas pela média, pois não foram encontrados resultados extremos (*outliers*) que justificassem outra opção.

Os resultados apresentados sempre informam o valor de n e a quantidade de nós sensores de cada tipo: $\{nx, ny, nz\}$ para $\{sx, sy, sz\}$ respectivamente. Como a função de avaliação no AG gera como valor de aptidão o negativo da FO, é necessário um valor que padronize a comparação. Essa comparação entre os dois métodos é realizada pelo valor da FO de ambas as abordagens. O valor da FO do AG pode ser calculado com base nos resultados $bFitPop$ e $bFitGA$. O valor $bFitPop$ é o valor correspondente à maior aptidão de algum ou vários indivíduos evoluídos pelas gerações, ao término de uma otimização pelo AG. Já $bFitGA$ corresponde à maior aptidão entre as otimizações do AG de uma determinada instância. Pode ser utilizado o módulo $|bFitGA|$ ou o negativo $-bFitGA$ para obtenção do valor da FO para o AG, identificado como *subopt*. O valor da FO aparece nos resultados da abordagem exata e nas comparações entre as abordagens. Nesses casos, a abordagem exata apresenta o valor ótimo *opt*, como resultado da FO, enquanto o AG apresenta o valor subótimo *subopt*, podendo aparecer também a média e o desvio-padrão

¹A informação de mediana é interessante como estatística, por ser menos sensível aos *outliers*, quando comparada com a média.

(D_p). Já o valor de aptidão é informado nos resultados do AG, quando não comparado com a abordagem exata. São informados o valor de maior aptidão $bFitGA$ entre as diversas otimizações ($bFitPop$) e também a média e o desvio-padrão da amostra.

Foi estipulado o limite de 22 minutos no tempo de otimização para instâncias de formato regular de ambas as abordagens, para comparar o limite de geração de resultados para o PAS. Quando este limite é ultrapassado, a instância em questão e as posteriores não são mais registradas oficialmente, mesmo que uma instância posterior tenha otimização no tempo limite. Como esta pesquisa foca em alocação inicial de nós sensores de uma RSSF, o limite poderia ser maior, podendo chegar a dias (ou mesmo semanas) se necessário. Porém, o tempo disponível para a pesquisa foi determinante nesta limitação de tempo. O limite original era de 20 minutos, mas foi alterado com a inclusão de 2 minutos (10%) pela observação dos resultados da abordagem exata, para incluir resultados que variaram próximos aos 20 minutos. Apesar deste limite, é possível acompanhar o comportamento dos métodos sobre o crescimento na rede e realizar dezenas de otimizações, trazendo resultados mais confiáveis. Já na comparação entre formatos de instâncias, a quantidade de nós sensores é estipulada como forma de comparação e o tempo não é limitado.

4.2- Otimização por Método Exato em Instâncias de Formato Regular

Ao todo, em instâncias de formato regular, a abordagem exata gerou, no limite de tempo definido, otimização em 70 instâncias diferentes, representando cada instância com l em $3 \leq l \leq 72$. Para $l > 72$, foram testados $l = \{73, 74, \dots, 80\}$ e apenas $l = 75$ foi otimizado abaixo do tempo limite. Porém, como definido, $l = 73$ ultrapassou o tempo limite, sendo $l = 72$ a última instância válida para esta pesquisa. Logo, $l = \{3, 4, \dots, 72\}$ resulta em $n = \{9, 16, \dots, 5184\}$. As informações sobre a otimização podem ser visualizadas na Tabela 4. A Figura 12 traz gráficos indicando a média de tempo total da otimização conforme o aumento das instâncias, sendo o Gráfico 12a com instâncias $3 \leq l \leq 32$ e o Gráfico 12b com instâncias otimizadas no tempo limite definido. Assim, é possível a visualização das variações iniciais no tempo de otimização com mais acuidade, pois os resultados totais limitam a visualização gráfica desta informação em instâncias menores.

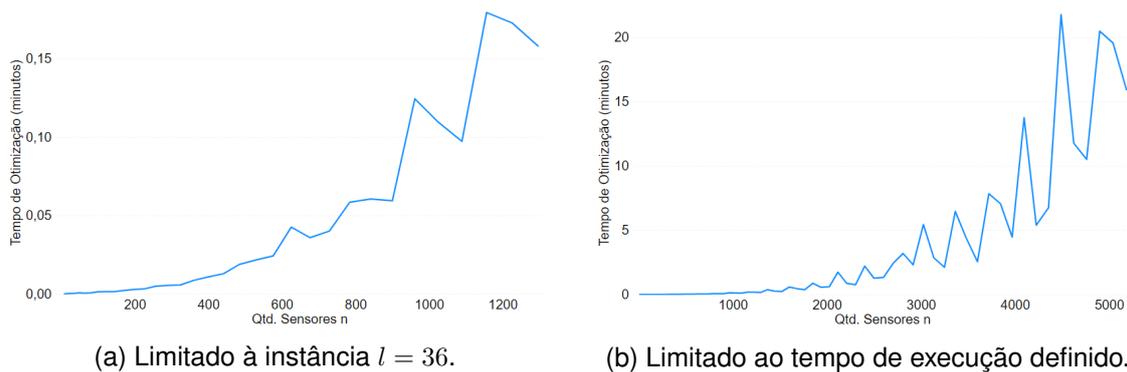


Figura 12 – Gráficos com a relação da quantidade de sensores pelo tempo na otimização do PAS pela abordagem exata em instâncias de formato regular.

Fonte: o próprio autor.

As informações da otimização (Tabela 4) mostram que a abordagem exata otimizou instâncias com resultados ótimos entre 9 e 5184 nós sensores no tempo estipulado. Este resultado abrange instâncias de portes pequeno, médio e grande. Nesse contexto, dados e comportamentos interessantes foram observados e são descritos a seguir.

Os valores da FO apresentam, aparentemente, uma relação matemática passível de modelagem conforme o aumento de l . Alguns detalhes podem ser citados: o sy aumenta em 1 a cada $l+3$ e o sx aumenta incrementalmente também, seguindo tendência a ser mapeada. Como n é relacionado a l , e l sendo conhecido desde o início, então $n - sy - sx = sz$. Desta forma, seria possível mapear nx , ny e nz para qualquer tamanho de instância. Sobre a alocação otimizada dos sensores em cada posição da rede, não houve uma observação direta que indicasse a possibilidade da geração de uma formulação matemática que resolvesse o problema em tempo polinomial para qualquer tamanho de rede. Porém, a quantidade de cada tipo de sensor sendo conhecida gera uma possibilidade extra para estudo da viabilidade de alocação otimizada em tempo polinomial.

Outra informação importante obtida é que a abordagem exata levou mais tempo para otimizar o PAS quando teve alocação de sy . Mesmo em redes de porte maior, quando sy não é alocado, isto é, quando a rede possui a solução ótima apenas pela alocação de sx e sz , o tempo total de otimização é geralmente menor se comparado a uma rede menor com alocação de sy . Para este cenário, na Tabela 5, foram separados e consolidados os detalhes dos registros de execução do *Solver* das instâncias $l = \{40, 41\}$ e $l = \{64, 65\}$. É possível visualizar que a diferença de tempo de otimização ocorre pela execução da técnica de BnC, realizada como segunda etapa da otimização quando o

resultado ótimo não é encontrado na primeira etapa, através da técnica busca dinâmica (*dynamic search*). Como esperado, na maioria das vezes, a primeira etapa leva mais tempo para instâncias maiores, devido ao esforço para organizar e atingir o ponto inicial sobre uma instância maior.

Tabela 4 – Resultados das execuções da abordagem exata em instâncias de formato regular até o limite do tempo estipulado.

Lado <i>l</i>	Total <i>n</i>	Valor da FO <i>opt</i>	Alocação Otimizada			Tempo de Otimização		
			X <i>sx</i>	Y <i>sy</i>	Z <i>sz</i>	M _d (seg)	M _e (seg)	M _e (min)
3	9	12	1	0	8	0,009	0,013	0,0002
4	16	24	2	2	12	0,020	0,021	0,0004
5	25	37	4	0	21	0,018	0,026	0,0004
6	36	48	4	0	32	0,028	0,030	0,0005
7	49	70	6	3	40	0,045	0,051	0,0009
8	64	91	9	0	55	0,040	0,040	0,0007
9	81	108	9	0	72	0,053	0,052	0,0009
10	100	140	12	4	84	0,081	0,086	0,0014
11	121	169	16	0	105	0,090	0,092	0,0015
12	144	192	16	0	128	0,089	0,095	0,0016
13	169	234	20	5	144	0,130	0,135	0,0023
14	196	271	25	0	171	0,177	0,177	0,0029
15	225	300	25	0	200	0,196	0,198	0,0033
16	256	352	30	6	220	0,300	0,302	0,0050
17	289	397	36	0	253	0,326	0,331	0,0055
18	324	432	36	0	288	0,344	0,350	0,0058
19	361	494	42	7	312	0,528	0,530	0,0088
20	400	547	49	0	351	0,657	0,658	0,0110
21	441	588	49	0	392	0,778	0,780	0,0130
22	484	660	56	8	420	1,131	1,134	0,0189
23	529	721	64	0	465	1,297	1,306	0,0218
24	576	768	64	0	512	1,457	1,459	0,0243
25	625	850	72	9	544	2,563	2,559	0,0426
26	676	919	81	0	595	2,151	2,157	0,0359
27	729	972	81	0	648	2,405	2,411	0,0402
28	784	1064	90	10	684	3,507	3,511	0,0585
29	841	1141	100	0	741	3,631	3,637	0,0606
30	900	1200	100	0	800	3,606	3,570	0,0595
31	961	1302	110	11	840	7,470	7,465	0,1244
32	1024	1387	121	0	903	6,615	6,583	0,1097
33	1089	1452	121	0	968	5,842	5,840	0,0973
34	1156	1564	132	12	1012	10,433	10,762	0,1794
35	1225	1657	144	0	1081	10,306	10,370	0,1728
36	1296	1728	144	0	1152	9,484	9,482	0,1580
37	1369	1850	156	13	1200	22,057	22,482	0,3747
38	1444	1951	169	0	1275	14,995	15,114	0,2519
39	1521	2028	169	0	1352	14,049	14,100	0,2350
40	1600	2160	182	14	1404	33,857	34,579	0,5763
41	1681	2269	196	0	1485	26,604	27,111	0,4519
42	1764	2352	196	0	1568	21,573	21,840	0,3640
43	1849	2494	210	15	1624	51,035	52,135	0,8689
44	1936	2611	225	0	1711	32,593	33,577	0,5596
45	2025	2700	225	0	1800	35,262	35,903	0,5984
46	2116	2852	240	16	1860	104,472	104,339	1,7390
47	2209	2977	256	0	1953	52,015	51,960	0,8660
48	2304	3072	256	0	2048	45,074	45,311	0,7552
49	2401	3234	272	17	2112	132,489	132,488	2,2081
50	2500	3367	289	0	2211	74,958	75,507	1,2585
51	2601	3468	289	0	2312	76,003	79,523	1,3254
52	2704	3640	306	18	2380	145,533	145,753	2,4292
53	2809	3781	324	0	2485	187,932	191,588	3,1931
54	2916	3888	324	0	2592	136,400	138,354	2,3059
55	3025	4070	342	19	2664	325,278	326,582	5,4430
56	3136	4219	361	0	2775	170,915	171,163	2,8527
57	3249	4332	361	0	2888	126,433	126,761	2,1127
58	3364	4524	380	20	2964	388,231	388,037	6,4673
59	3481	4681	400	0	3081	262,493	262,834	4,3806
60	3600	4800	400	0	3200	152,735	152,802	2,5467
61	3721	5002	420	21	3280	469,948	470,772	7,8462
62	3844	5167	441	0	3403	422,491	424,189	7,0698
63	3969	5292	441	0	3528	268,005	268,200	4,4700
64	4096	5504	462	22	3612	827,206	826,516	13,7753
65	4225	5677	484	0	3741	323,110	323,523	5,3921
66	4356	5808	484	0	3872	405,259	405,340	6,7557
67	4489	6030	506	23	3960	1305,290	1307,424	21,7904
68	4624	6211	529	0	4095	706,038	706,692	11,7782
69	4761	6348	529	0	4232	630,284	630,990	10,5165
70	4900	6580	552	24	4324	1228,480	1230,164	20,5027
71	5041	6769	576	0	4465	1170,010	1174,978	19,5830
72	5184	6912	576	0	4608	955,259	956,814	15,9469

Fonte: o próprio autor.

Tabela 5 – Comparação entre os registros de execução do *Solver* em redes de formato regular de lados sequenciais onde o maior lado obteve o resultado em menor tempo.

Lado	Comparação 1		Comparação 2	
	40	41	64	65
Qtd. Sensores	1600	1681	4096	4225
Valor da FO	2160	2269	5504	5677
Tempo Otm. Inicial (nó raiz)	23,42 segundos (30546,48 marcações)	26,50 segundos (33498,61 marcações)	643,08 segundos (629393,60 marcações)	322,38 segundos (332774,60 marcações)
Tempo BnC	10,45 segundos (11734,21 marcações)	-	184,13 segundos (173514,26 marcações)	-
Tempo Otm. (nó raiz+BnC)	33,88 segundos (42280,69 marcações)	26,50 segundos (33498,61 marcações)	827,20 segundos (802907,86 marcações)	322,38 segundos (332774,60 marcações)
Tempo Total (entrada+otm+saída)	34,56 segundos (0,576 minutos)	27,12 segundos (0,452 minutos)	828,20 segundos (13,80 minutos)	323,52 segundos (5,392 minutos)

Fonte: o próprio autor.

4.3- Otimização dos Hiperparâmetros do AG

A otimização de hiperparâmetros é uma etapa importante na solução do PAS pelo AG. O objetivo é descobrir valores para os hiperparâmetros do modelo que melhorem a qualidade da otimização. A otimização dos hiperparâmetros utiliza testes estatísticos que identificam e descartam de futuras otimizações as configurações com desempenho ruim [López-Ibáñez et al., 2016]. As opções de testes estatísticos possíveis neste trabalho foram: o *Friedman test* e o *Student's t-test*. Em suma, o primeiro teste estatístico descrito usa o ranking das configurações, das melhores para as piores, para exclusão das configurações com pior desempenho. A segunda opção de teste estatístico descrito usa o desempenho médio das configurações para o mesmo fim. No *Student's t-test*, é possível ajustar intervalos de confiança através da correção de Bonferroni e da correção de Holm. Essas correções têm o objetivo de diminuir inferências equivocadas.

A correção de Bonferroni é um método independente e conservador, com aplicação realizada para cada hipótese individualmente, objetivando a diminuição do erro do tipo I, isto é, a redução da rejeição da hipótese nula quando ela é verdadeira. A hipótese nula é uma hipótese sobre determinados fatos estatísticos que se deseja provar como falsa através de testes estatísticos adequados. A correção de Holm, mais poderosa e versátil, além da diminuição do erro do tipo I, tenta reduzir erros do tipo II, que consistem em falhas em não rejeitar uma hipótese falsa. Nesta pesquisa, foi utilizado o *Student's test* com a correção de Bonferroni na otimização dos hiperparâmetros. Seria ideal que a correção de

Holm fosse também testada, mas não foi possível no tempo disponível da pesquisa. As configurações de otimização dos hiperparâmetros foram listadas na Tabela 6 e explicadas a seguir.

A primeira configuração de hiperparâmetros aparece na coluna Inicial. Esta configuração teve como base conhecimentos da literatura. A otimização foi realizada para instância de formato regular $l = 10$ e gerou a configuração da coluna Base. Com a configuração da coluna Base, foram otimizadas instâncias de formato regular $l = \{10, 15, 20\}$ gerando resultados que constam respectivamente nas colunas Otm10, Otm15 e Otm20. Com estas três configurações, foram feitas uma bateria de testes para $l = \{10, 15, 20\}$ e se constatou que a configuração da coluna Otm15 obteve desempenho melhor em comparação às outras, mesmo para $l = \{10, 20\}$. Logo, esta configuração foi utilizada para execução de todas as instâncias de formatos regular e não regulares do AG.

Tabela 6 – Configuração de valores para os hiperparâmetros.

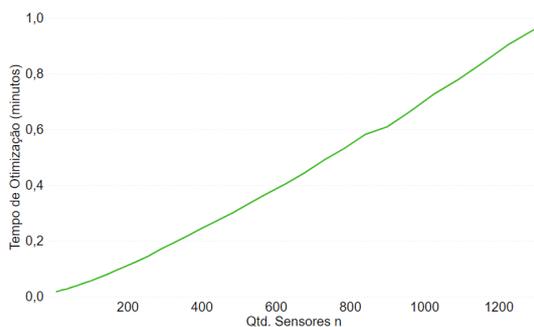
Parâmetro	Configurações				
	Inicial	Base	Otm10	Otm15	Otm20
P_{size}	713	929	1003	1408	1316
Gen_{num}	11467	19465	25153	5491	16337
Gen_{res1}	1248	825	1831	856	1350
Gen_{res2}	4331	662	4149	627	555
Res_{num}	382	39	502	290	596
cZ_{rate}	0,5517	0,6610	0,8602	0,7607	0,4284
mO_{rate}	0,0148	0,0492	0,1426	0,0817	0,0061
m_{rate}	0,0148	0,0221	0,0085	0,0071	0,0045
sx_{rate}	0,1083	0,1750	0,1978	0,2613	0,3564
sy_{rate}	0,0481	0,0442	0,0679	0,0454	0,1026
sZ_{rate}	0,7384	0,8210	0,9119	0,9329	0,9206

Fonte: o próprio autor.

4.4- Otimização por Método Heurístico em Instâncias de Formato Regular

Para instâncias de formato regular, o AG gerou otimização para 133 instâncias diferentes representando cada instância como l em $3 \leq l \leq 135$. Logo, $l = \{3, 4, \dots, 135\}$ resulta em $n = \{9, 16, \dots, 17424\}$. Não foram testadas instâncias $l > 135$, como informação adicional, pois a tendência da evolução do tempo de otimização foi bem estável até o

limite definido. A Figura 13 mostra a evolução do tempo de otimização pelo aumento do tamanho das instâncias. Assim como na abordagem exata, a figura com os resultados possui dois gráficos, 13a e 13b, com a mesma configuração (da abordagem exata): o primeiro traz uma limitação na quantidade de instâncias, para visualizar a tendência das instâncias iniciais, e o segundo traz os resultados no limite de tempo definido. As informações da otimização podem ser vistas na Tabela 7.



(a) Limitado à instância $l = 36$.



(b) Limitado ao tempo de execução definido.

Figura 13 – Gráficos com a relação da quantidade de sensores pelo tempo na otimização do PAS pelo AG em instâncias de formato regular.

Fonte: o próprio autor.

Tabela 7 – Resultados das execuções do AG em instâncias de formato regular até o limite do tempo estipulado.

Lado <i>l</i>	Total <i>n</i>	<i>bFitGA</i>	Aptidão			Alocação Otimizada			Tempo de Otimização		
			<i>M_e</i>	<i>D_p</i>		<i>X_{sx}</i>	<i>Y_{sy}</i>	<i>Z_{sz}</i>	<i>M_d</i> (seg)	<i>M_e</i> (seg)	<i>M_e</i> (min)
3	9	-12	-12,00	0,00	1	0	8	1,05	1,02	0,018	
4	16	-24	-24,00	0,00	2	2	12	1,21	1,22	0,020	
5	25	-37	-37,00	0,00	4	0	21	1,43	1,43	0,024	
6	36	-48	-48,00	0,00	4	0	32	1,60	1,58	0,027	
7	49	-70	-70,67	0,66	6	3	40	1,98	1,96	0,033	
8	64	-91	-91,17	0,38	9	0	55	2,34	2,35	0,039	
9	81	-108	-112,33	2,80	9	0	72	2,85	2,77	0,047	
10	100	-142	-144,13	1,42	12	6	82	3,34	3,35	0,056	
11	121	-169	-172,87	2,01	16	0	105	4,00	4,00	0,067	
12	144	-201	-207,07	2,74	17	6	121	4,72	4,76	0,079	
13	169	-240	-243,90	2,06	20	11	138	5,61	5,60	0,094	
14	196	-276	-284,30	3,88	25	5	166	6,55	6,56	0,109	
15	225	-318	-326,47	3,54	28	9	188	7,55	7,57	0,126	
16	256	-367	-374,23	3,87	34	9	213	8,71	8,78	0,145	
17	289	-417	-423,20	3,75	40	8	241	10,16	10,04	0,169	
18	324	-467	-476,97	4,57	44	11	269	11,54	11,49	0,192	
19	361	-525	-532,77	4,45	46	26	289	13,02	12,95	0,217	
20	400	-584	-593,70	3,74	54	22	324	14,68	14,65	0,245	
21	441	-645	-656,23	4,29	59	27	355	16,30	16,26	0,272	
22	484	-709	-722,03	6,12	63	36	385	18,04	17,98	0,301	
23	529	-784	-793,87	4,53	73	36	420	20,09	19,95	0,335	
24	576	-855	-869,37	5,99	78	45	453	22,16	22,19	0,369	
25	625	-928	-945,23	7,32	84	51	490	24,22	24,12	0,404	
26	676	-1013	-1025,30	8,51	97	46	533	26,57	26,69	0,443	
27	729	-1096	-1112,77	7,52	107	46	576	29,35	29,19	0,489	
28	784	-1188	-1198,93	6,50	115	59	610	31,88	31,93	0,531	
29	841	-1279	-1292,57	7,64	122	72	647	34,92	34,96	0,582	
30	900	-1367	-1387,67	11,03	130	77	693	36,56	36,50	0,609	
31	961	-1462	-1484,80	8,91	138	87	736	39,82	39,18	0,664	
32	1024	-1571	-1589,80	9,22	155	82	787	43,49	43,01	0,725	
33	1089	-1673	-1696,47	10,69	160	104	825	46,60	46,36	0,777	
34	1156	-1784	-1810,00	11,14	180	88	888	50,25	49,65	0,837	
35	1225	-1897	-1924,70	12,80	191	99	935	54,18	53,81	0,903	
36	1296	-2014	-2040,27	13,18	204	106	986	57,49	56,67	0,958	
37	1369	-2140	-2161,73	10,57	220	111	1038	62,14	61,93	1,036	
38	1444	-2265	-2284,03	11,13	229	134	1081	65,72	65,17	1,095	
39	1521	-2396	-2416,23	14,58	255	110	1156	70,81	70,07	1,180	
40	1600	-2524	-2545,27	12,36	261	141	1198	75,12	74,10	1,252	
41	1681	-2654	-2686,00	15,46	271	160	1250	80,25	79,38	1,337	
42	1764	-2795	-2826,40	15,84	294	149	1321	86,64	85,06	1,444	
43	1849	-2949	-2972,57	11,18	311	167	1371	92,08	90,95	1,535	
44	1936	-3077	-3113,37	15,97	318	187	1431	99,80	99,51	1,663	
45	2025	-3240	-3267,23	16,01	345	180	1500	105,64	105,46	1,761	
46	2116	-3397	-3421,77	15,13	361	198	1557	113,07	113,73	1,884	
47	2209	-3554	-3585,23	14,57	384	193	1632	120,47	119,97	2,008	
48	2304	-3684	-3741,00	18,66	391	207	1706	127,33	127,18	2,122	
49	2401	-3880	-3910,20	17,29	425	204	1772	132,21	132,63	2,203	
50	2500	-4043	-4075,77	18,68	454	181	1865	135,78	137,41	2,263	
51	2601	-4211	-4258,57	19,58	466	212	1923	142,76	142,77	2,379	
52	2704	-4392	-4431,97	18,54	493	209	2002	149,80	151,01	2,497	
53	2809	-4569	-4615,13	21,49	498	266	2045	155,49	156,46	2,592	
54	2916	-4770	-4799,70	14,60	527	273	2116	162,07	163,40	2,701	
55	3025	-4944	-4984,87	19,07	560	239	2226	168,92	169,79	2,815	
56	3136	-5135	-5183,63	19,99	574	277	2285	175,92	176,48	2,932	
57	3249	-5325	-5374,00	22,64	607	255	2387	182,17	181,12	3,036	
58	3364	-5526	-5572,87	19,74	629	275	2460	190,33	192,00	3,172	
59	3481	-5732	-5779,43	18,67	659	274	2548	196,83	197,68	3,281	
60	3600	-5939	-5989,50	24,83	672	323	2605	207,10	209,95	3,452	
61	3721	-6169	-6198,40	22,89	703	339	2679	213,27	215,12	3,555	
62	3844	-6361	-6409,17	24,67	728	333	2783	221,82	223,70	3,697	
63	3969	-6580	-6628,93	25,89	765	316	2888	231,92	232,75	3,865	
64	4096	-6798	-6848,80	25,48	781	359	2956	241,41	242,72	4,024	
65	4225	-7022	-7073,60	26,36	811	364	3050	248,54	251,06	4,142	
66	4356	-7245	-7309,23	24,51	844	357	3155	260,42	262,52	4,340	
67	4489	-7504	-7544,87	26,27	871	402	3216	267,94	269,47	4,466	
68	4624	-7724	-7777,77	27,45	907	379	3338	279,72	281,58	4,662	
69	4761	-7953	-8024,73	38,17	932	396	3433	294,36	298,22	4,906	
70	4900	-8210	-8270,07	26,13	971	397	3532	296,80	299,98	4,947	
71	5041	-8467	-8511,93	22,56	1007	405	3629	305,88	310,38	5,098	
72	5184	-8724	-8771,03	21,51	1037	429	3718	316,56	318,40	5,276	
73	5329	-8951	-9033,80	35,70	1057	451	3821	333,37	335,22	5,556	
74	5476	-9197	-9274,87	36,99	1094	439	3943	344,25	349,17	5,737	
75	5625	-9488	-9541,47	24,24	1149	416	4060	358,00	361,20	5,967	

Tabela 7 - continuação da página anterior.

76	5776	-9760	-9813,37	33,38	1162	498	4116	365,96	372,00	6,099
77	5929	-10025	-10078,17	29,95	1202	490	4237	376,16	378,72	6,269
78	6084	-10273	-10346,15	28,59	1229	502	4353	384,61	387,85	6,410
79	6241	-10517	-10627,33	30,79	1264	484	4493	364,06	365,86	6,068
80	6400	-10833	-10902,23	31,75	1313	494	4593	385,02	383,64	6,417
81	6561	-11122	-11200,37	34,47	1342	535	4684	409,17	409,73	6,819
82	6724	-11415	-11495,77	29,84	1399	494	4831	419,07	419,85	6,984
83	6889	-11718	-11782,37	36,08	1435	524	4930	445,11	441,31	7,419
84	7056	-12019	-12079,43	27,38	1473	544	5039	453,21	450,29	7,553
85	7225	-12323	-12383,77	28,30	1496	610	5119	459,60	461,15	7,660
86	7396	-12615	-12684,03	40,75	1521	656	5219	471,19	470,29	7,853
87	7569	-12923	-12976,23	32,53	1594	572	5403	494,20	493,97	8,237
88	7744	-13199	-13299,90	34,54	1612	619	5513	507,30	507,28	8,455
89	7921	-13552	-13609,03	32,11	1657	660	5604	518,22	520,42	8,637
90	8100	-13875	-13932,20	30,26	1708	651	5741	533,73	535,89	8,895
91	8281	-14185	-14243,07	33,83	1716	756	5809	534,86	535,68	8,914
92	8464	-14515	-14578,77	34,34	1780	711	5973	544,33	547,28	9,072
93	8649	-14837	-14893,00	34,15	1848	644	6157	551,24	555,46	9,187
94	8836	-15210	-15224,80	15,61	1887	713	6236	549,60	548,11	9,160
95	9025	-15537	-15582,20	35,81	1926	734	6365	579,43	577,98	9,657
96	9216	-15882	-15905,80	26,57	1973	747	6496	593,41	593,47	9,890
97	9409	-16233	-16250,20	16,04	2013	785	6611	601,60	600,88	10,027
98	9604	-16590	-16624,80	32,41	2091	713	6800	607,18	607,42	10,120
99	9801	-16914	-16965,00	56,53	2106	795	6900	627,37	635,60	10,456
100	10000	-17257	-17312,00	31,07	2139	840	7021	645,99	646,53	10,766
101	10201	-17628	-17674,00	36,16	2225	752	7224	641,09	638,49	10,685
102	10404	-18002	-18020,00	17,38	2267	797	7340	667,33	680,17	11,122
103	10609	-18361	-18386,00	25,77	2305	837	7467	697,54	699,45	11,626
104	10816	-18754	-18788,80	25,07	2368	834	7614	713,98	711,40	11,900
105	11025	-19095	-19123,80	22,99	2417	819	7789	725,80	731,69	12,097
106	11236	-19419	-19493,80	43,54	2460	803	7973	757,50	752,90	12,625
107	11449	-19817	-19897,00	53,36	2485	913	8051	728,18	744,79	12,136
108	11664	-20269	-20295,40	18,08	2575	880	8209	783,78	781,69	13,063
109	11881	-20569	-20680,20	69,32	2581	945	8355	783,93	791,41	13,065
110	12100	-21002	-21072,80	58,58	2645	967	8488	812,17	813,99	13,536
111	12321	-21418	-21440,00	29,94	2707	976	8638	807,31	811,24	13,455
112	12544	-21852	-21890,40	34,31	2769	1001	8774	846,33	840,32	14,105
113	12769	-22197	-22286,60	50,58	2825	953	8991	818,38	846,80	13,640
114	12996	-22613	-22671,60	39,77	2863	1028	9105	892,97	900,59	14,883
115	13225	-23030	-23103,60	69,70	2923	1036	9266	895,49	898,08	14,925
116	13456	-23436	-23494,40	35,22	2999	983	9474	908,07	910,45	15,135
117	13689	-23851	-23899,20	41,72	3044	1030	9615	940,17	950,97	15,669
118	13924	-24279	-24330,20	33,40	3078	1121	9725	937,21	946,93	15,620
119	14161	-24738	-24779,00	35,98	3152	1121	9888	961,60	979,27	16,027
120	14400	-25164	-25209,00	42,95	3239	1047	10114	986,40	990,56	16,440
121	14641	-25510	-25608,20	98,80	3269	1062	10310	999,98	994,59	16,666
122	14884	-25972	-26028,60	35,83	3336	1080	10468	997,78	991,14	16,630
123	15129	-26453	-26512,80	60,08	3405	1109	10615	1012,48	1012,75	16,875
124	15376	-26883	-26942,40	54,42	3464	1115	10797	1053,99	1062,05	17,566
125	15625	-27321	-27344,20	25,53	3552	1040	11033	1075,65	1072,15	17,928
126	15876	-27813	-27832,00	19,99	3589	1170	11117	1090,61	1084,66	18,177
127	16129	-28197	-28246,40	36,16	3621	1205	11303	1099,03	1095,33	18,317
128	16384	-28666	-28754,80	65,50	3688	1218	11478	1112,33	1108,48	18,539
129	16641	-29080	-29169,80	65,65	3730	1249	11662	1130,63	1131,41	18,844
130	16900	-29630	-29662,80	30,96	3799	1333	11768	1159,08	1163,24	19,318
131	17161	-30041	-30131,20	61,57	3865	1285	12011	1169,80	1183,51	19,497
132	17424	-30500	-30552,20	56,25	3921	1313	12190	1195,02	1218,22	19,917
133	17689	-31012	-31073,00	59,30	4011	1290	12388	1246,31	1225,21	20,772
134	17956	-31436	-31524,20	59,81	4064	1288	12604	1259,52	1259,15	20,992
135	18225	-31947	-31973,40	22,90	4117	1371	12737	1239,75	1230,34	20,662

Fonte: o próprio autor.

4.5- Comparação entre Instâncias de Formato Regular

Os principais pontos de comparação entre as abordagens foram: a qualidade do resultado e o tempo médio de otimização. A comparação considera a composição estrutural do AG, como descrito no Capítulo 3, e o conjunto de hiperparâmetros utilizados em sua execução, como descritos na Seção 4.3 deste capítulo.

A qualidade do resultado em redes de formato regular é medida pela comparação entre os valores das FOs de mesma instância de ambas as abordagens. Visto que a abordagem exata garante o valor ótimo da FO, a distância entre os valores das FOs das abordagens indicam o valor de perda de qualidade relativo ao valor da FO do AG. Na Figura 14, a perda de qualidade corresponde à área entre as linhas do Gráfico 14a. Com o devido mapeamento da tendência, será possível prever valores subótimos de FO de instâncias de tamanhos maiores que as que constam nesta pesquisa. O Gráfico 14b mostra todos os resultados de FO de ambas as abordagens. Como o AG não garante o resultado ótimo, este precisa estar muito bem ajustado para obter qualidade em seus resultados, especialmente para instâncias maiores (grande porte). Essa é a importância da pesquisa sobre estruturas internas mais aderentes ao problema e da otimização de hiperparâmetros.

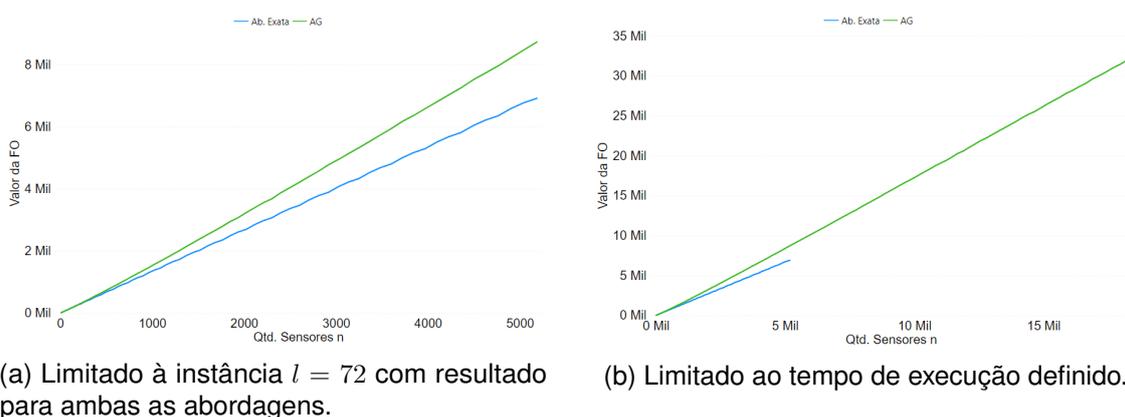


Figura 14 – Gráficos comparativos entre abordagens, relacionando a quantidade de sensores com o valor da FO. Mostra a perda de qualidade do AG com o aumento da quantidade de sensores.

Fonte: o próprio autor.

Sobre o tempo médio de otimização, a abordagem exata se manteve com um tempo ínfimo inicialmente, mas teve um crescimento acentuado em seguida, em relação

ao AG. Já o AG manteve o aumento constante do tempo até o limite estipulado, otimizando praticamente o dobro de instâncias que abordagem exata conseguiu otimizar, no mesmo limite de tempo. Estes valores podem ser observados no gráfico da Figura 15. Como esperado, o fato da abordagem exata certificar o resultado ótimo leva a uma maior complexidade de resolução, culminando em mais tempo necessário conforme o aumento das instâncias.

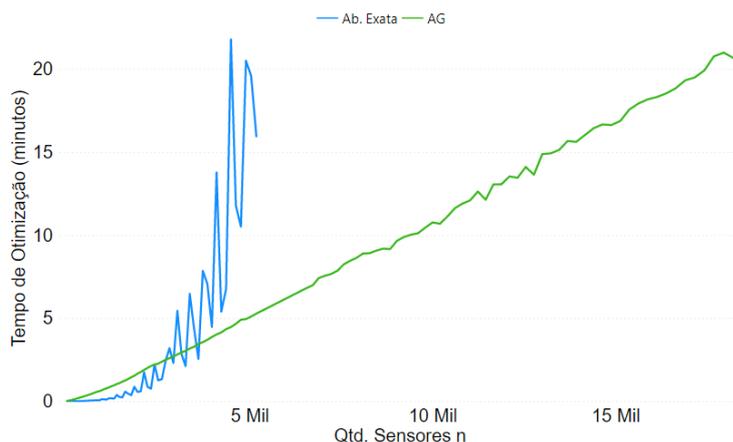


Figura 15 – Gráfico comparativo entre abordagens, relacionando a quantidade de sensores pelo tempo de otimização do PAS em redes de formato regular.

Fonte: o próprio autor.

4.6- Otimização em Instâncias de Formatos Não Regulares e Comparação entre Instâncias de todos os Formatos

Para instâncias de formatos não regulares, foram utilizadas 6 instâncias, sendo 3 de formato semirregular e 3 de formato irregular, variando entre portes pequeno, médio e grande. As instâncias criadas para os formatos não regulares, quando de mesmo porte, possuem a mesma quantidade de nós sensores n e quantidade de conexões ne . As instâncias de pequeno porte de formatos não regulares possuem $n = 25$ e $ne = 28$ cada. Estas instâncias equivalem a uma instância $l = 5$ de formato regular. As instâncias de porte médio de formatos não regulares possuem $n = 225$ e $ne = 286$ cada e equivalem a uma instância $l = 15$ de formato regular. Por último, as instâncias de grande porte de formatos não regulares possuem $n = 1225$ e $ne = 1565$ cada e equivalem a uma

Tabela 8 – Resultados da execução da abordagem exata em instâncias de formatos não regulares.

Formato	Total <i>n</i>	Valor da FO <i>opt</i>	Alocação Otimizada			Tempo de Otimização		
			X <i>sx</i>	Y <i>sy</i>	Z <i>sz</i>	M _d (seg)	M _e (seg)	M _e (min)
Semirregular	25	44	5	4	16	0,02	0,03	0,00
Irregular	25	44	4	7	14	0,02	0,02	0,00
Semirregular	225	394	42	43	140	0,12	0,12	0,00
Irregular	225	393	41	45	139	0,14	0,15	0,00
Semirregular	1225	2143	227	237	761	0,74	0,84	0,01
Irregular	1225	2149	226	246	753	0,84	0,84	0,01

Fonte: o próprio autor.

Tabela 9 – Resultados da execução do AG em instâncias de formatos não regulares.

Formato	Total <i>n</i>	Valor de Aptidão			Alocação Otimizada			Tempo de Otimização		
		<i>bFitGA</i>	M _e	D _p	X <i>sx</i>	Y <i>sy</i>	Z <i>sz</i>	M _d (seg)	M _e (seg)	M _e (min)
Semirregular	25	-44	-45,23	0,63	5	4	16	1,52	1,52	0,03
Irregular	25	-44	-44,97	0,67	4	7	14	1,42	1,42	0,02
Semirregular	225	-431	-441,60	6,69	65	11	149	27,48	27,94	0,47
Irregular	225	-425	-436,83	5,76	62	14	149	23,67	24,16	0,40
Semirregular	1225	-2882	-2955,73	43,13	465	52	708	772,86	774,82	12,91
Irregular	1225	-2824	-2895,67	33,95	455	38	732	743,11	757,28	12,62

Fonte: o próprio autor.

instância $l = 35$ de formato regular. Esse esforço na correspondência entre instâncias visa deixar a comparação o mais justa possível. As informações de otimização em instâncias não regulares podem ser vistas nas Tabelas 8 e 9 que apresentam os resultados da abordagem exata e do AG respectivamente. A comparação entre instâncias de todos os formatos abordados nesta pesquisa pode ser vista em duas tabelas: a Tabela 10 demonstra a comparação entre valores da FO e a Tabela 11 demonstra a comparação entre tempos de otimização.

A comparação dos valores da FO entre diferentes formatos traz as seguintes informações. A abordagem exata gerou resultados ótimos para todas as instâncias otimizadas. Assim, o foco passa a ser a qualidade do resultado do AG em relação à abordagem exata e ao próprio AG, entre formatos diferentes. Para o pequeno porte, não houve diferenças significativas entre os valores da abordagem exata e do AG. Porém, neste porte, o AG alcançou o resultado ótimo para instância de formato regular, mas não atingiu para instâncias de formatos não regulares, por pouco. Em seguida, para o médio porte, a perda de qualidade entre diferentes formatos passa a ser mais visível. A diferença no valor da FO entre abordagens é o dobro em formatos não regulares, em

Tabela 10 – Comparação entre valores da FO em instâncias de portes pequeno, médio e grande.

Porte	Formato / Valor da FO								
	Regular			Semirregular			Irregular		
	Ab. Ex.	AG	Dif.	Ab. Ex.	AG	Dif.	Ab. Ex.	AG	Dif.
Pequeno	37,0	37,0	0,0	44,0	45,2	1,2	44,0	45,0	1,0
Médio	300,0	326,5	26,5	394,0	441,6	47,6	393,0	436,8	43,8
Grande	1657,0	1924,7	267,7	2143,0	2955,7	812,7	2149,0	2895,7	746,7

Fonte: o próprio autor.

comparação com o formato regular. O formato irregular tem uma qualidade um pouco maior que o formato semirregular. Por fim, para o grande porte, a perda de qualidade entre formatos ficou mais evidente ainda, assim como a qualidade maior na otimização do formato irregular que no semirregular, pelo AG.

A comparação entre tempos de otimização mostra que a abordagem exata, para as instâncias descritas, superou em rapidez todos os tempos de otimização do AG. A abordagem exata obteve tempos menores ainda nas instâncias de formatos não regulares, se comparadas à instância de formato regular. O crescimento acentuado do tempo descrito na Figura 15 não foi impactante, pois este crescimento ocorre de forma crítica em instâncias maiores que as utilizadas nesta comparação. Diferente da abordagem exata, o AG teve piora no tempo de otimização em instâncias de formatos não regulares, comparadas com instâncias de formato regular.

Tabela 11 – Comparação entre tempos de otimização em instâncias de portes pequeno, médio e grande.

Porte	Formato / Tempo de Otimização (segundos)								
	Regular			Semirregular			Irregular		
	Ab. Exata	AG	Difer.	Ab. Exata	AG	Difer.	Ab. Exata	AG	Difer.
Pequeno	0,03	1,43	1,41	0,03	1,52	1,49	0,02	1,42	1,40
Médio	0,20	7,55	7,35	0,12	27,94	27,82	0,15	24,16	24,01
Grande	10,37	54,18	43,81	0,84	774,82	773,98	0,84	757,28	756,44

Fonte: o próprio autor.

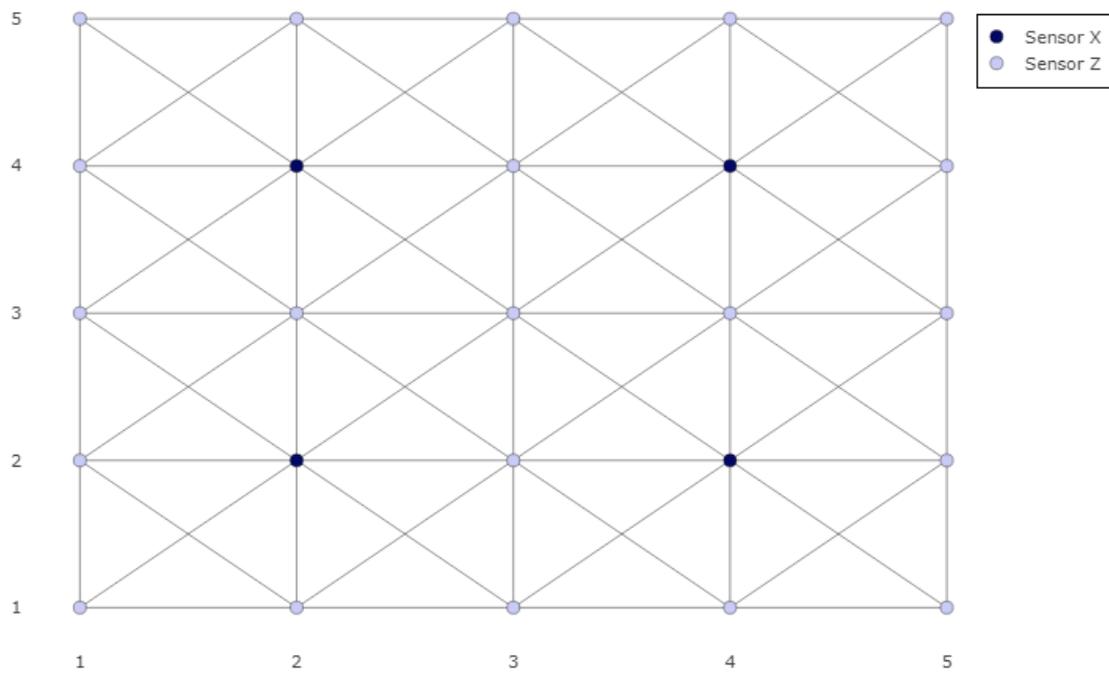
Tanto no valor da FO como no tempo de otimização, instâncias de formato irregular apresentam desempenho melhor que instâncias de formato semirregular. Isso mostra que o PAS em uma instância esparsa é menos complexo que em uma instância concentrada. Sobre a alta perda de qualidade indicada nos valores da FO do AG em redes de formatos não regulares, possíveis respostas podem ser indicadas. Seria importante otimizar os hiperparâmetros com instância maiores dos formatos não regulares. A otimização dos

hiperparâmetros foi realizada em instâncias de pequeno e médio portes de formato regular. Outro ponto seria a revisão na estrutura do algoritmo que implementa o AG, pois é possível haver algo desregulado na entrada pelo grafo das instâncias de formatos não regulares. Essa revisão visa verificar também o tempo de otimização.

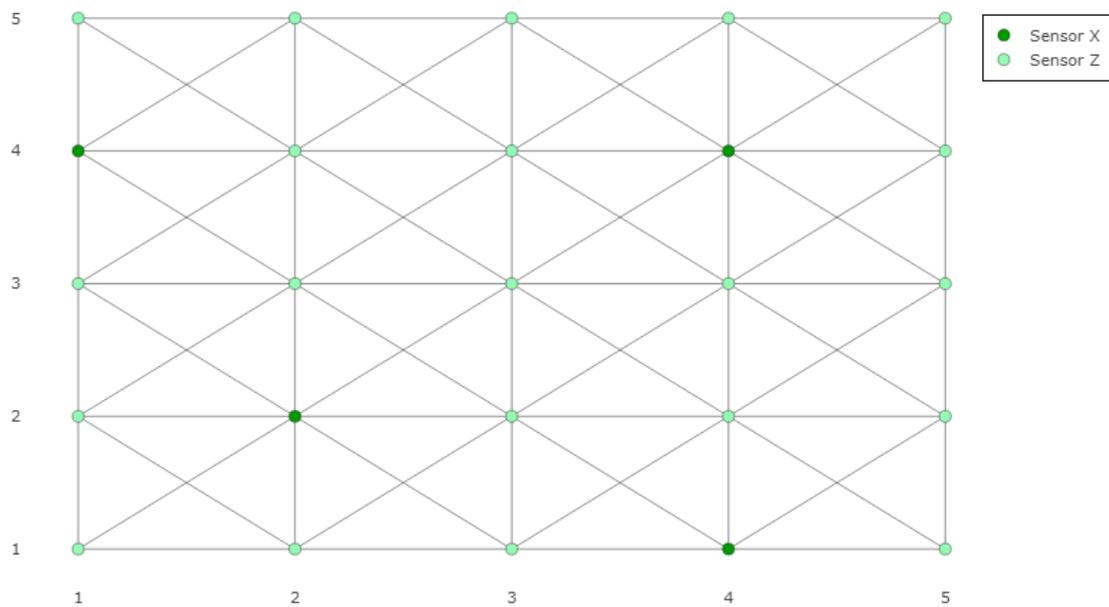
4.7- Alocação Otimizada dos Sensores

O objetivo da otimização de um PAS é a alocação (otimizada) dos nós sensores em uma RSSF. Nesta pesquisa, para a abordagem exata, foram realizadas alocações otimizadas para 70 instâncias de formato regular e 6 instâncias de formatos não regulares. Para o AG, foram realizadas alocações otimizadas para 133 instâncias de formato regular e 6 instâncias de formatos não regulares. No total, foram utilizadas 215 instâncias. A quantidade dos resultados da alocação otimizada dos nós sensores, porém, são em número muito maior. Enquanto as alocações realizadas pela abordagem exata possuem o resultado igual para mesma instância, as alocações realizadas pelo AG em mesma instância podem diferir entre si, mesmo quando atingem o mesmo valor da FO. Por esse motivo, foram selecionadas para demonstração instâncias que fizessem mais sentido com os detalhes da pesquisa.

Assim, todas as instâncias que aparecem na comparação entre redes de formatos regular e não regulares das Tabelas 10 e 11 são mostradas a seguir. As Figuras 16, 17 e 18 mostram a alocação otimizada em instâncias de pequeno, médio e grande portes de formato regular, com as instâncias $l = \{5, 15, 35\}$. As Figuras 19, 20 e 21 trazem a alocação otimizada dos nós sensores em instância de pequeno, médio e grande portes de formato semirregular, com instâncias equivalentes às de formato regular. Por último, as Figuras 22, 23 e 24 trazem alocação otimizada dos nós sensores para instância de pequeno, médio e grande portes de formato irregular, com instâncias também equivalentes às de formato regular. Todas as figuras trazem a alocação otimizada pela abordagem exata (a) e pelo AG (b). As alocações pelo AG apresentadas correspondem a uma das alocações possíveis, resultante de uma das várias otimizações realizadas.

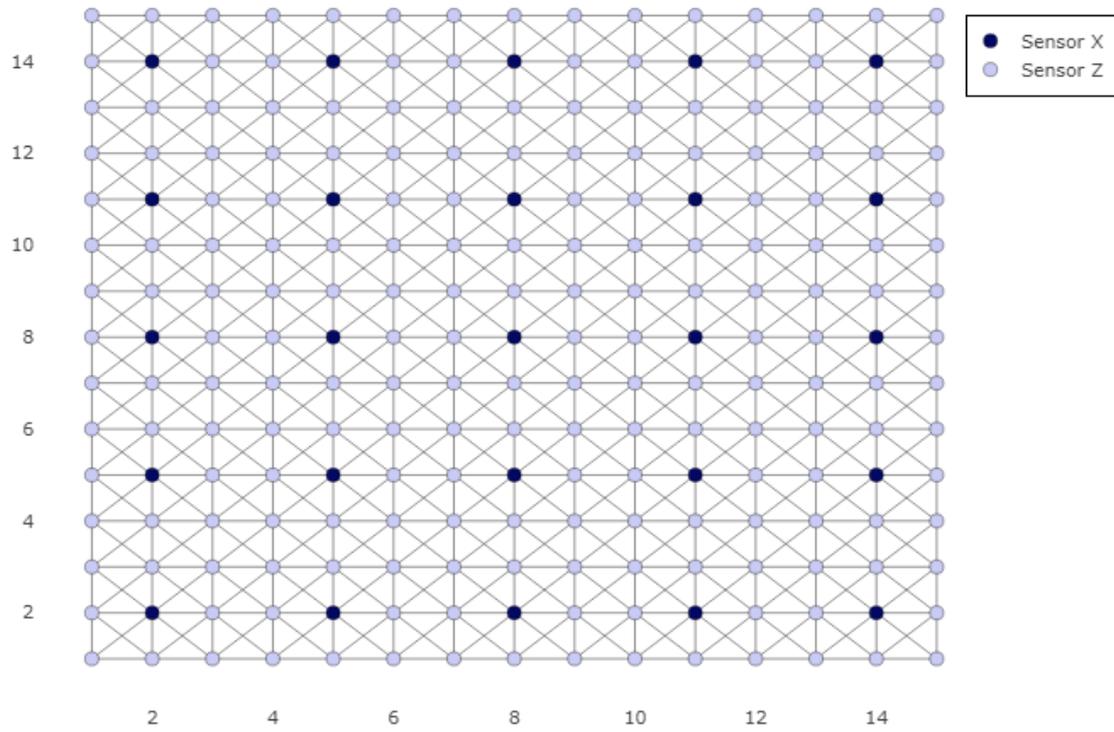


(a) Otimizada pela abordagem exata.

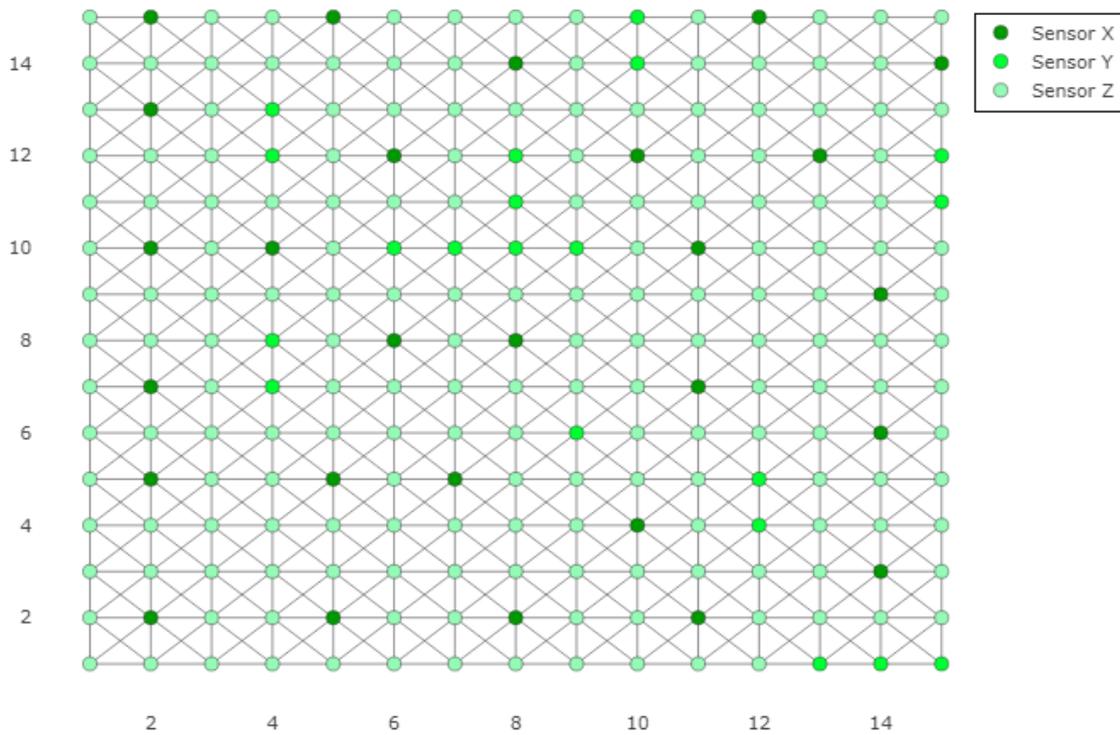


(b) Otimizada pelo AG.

Figura 16 – Instâncias de formato regular de pequeno porte ($l = 5$).
 Fonte: o próprio autor.

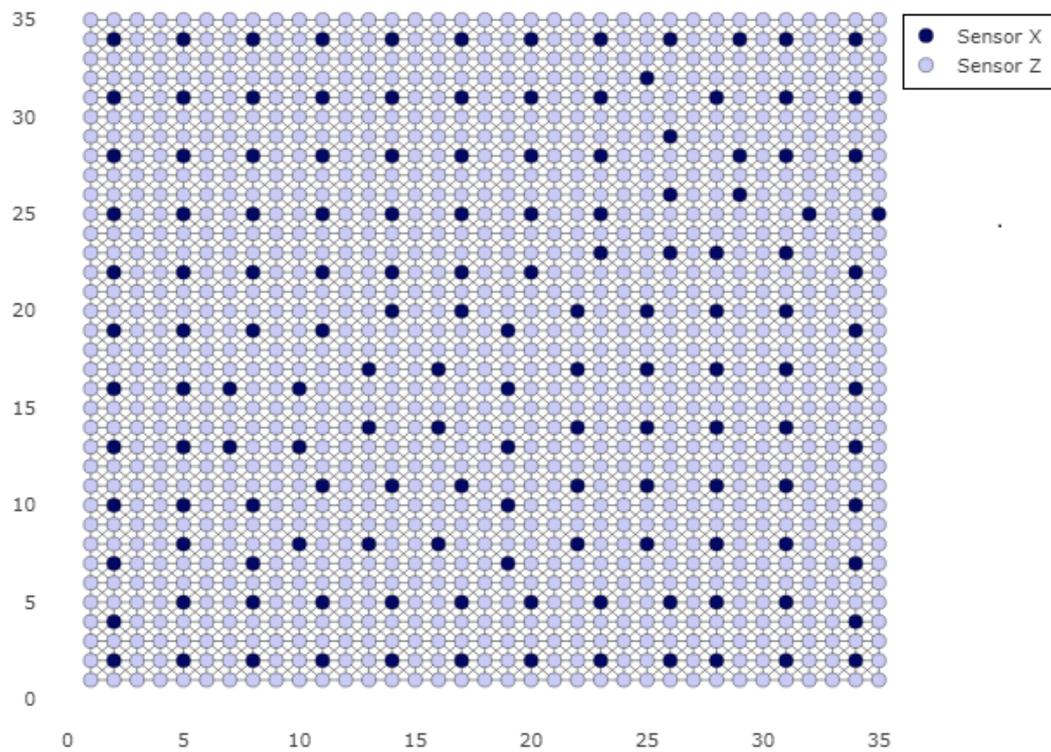


(a) Otimizada pela abordagem exata.

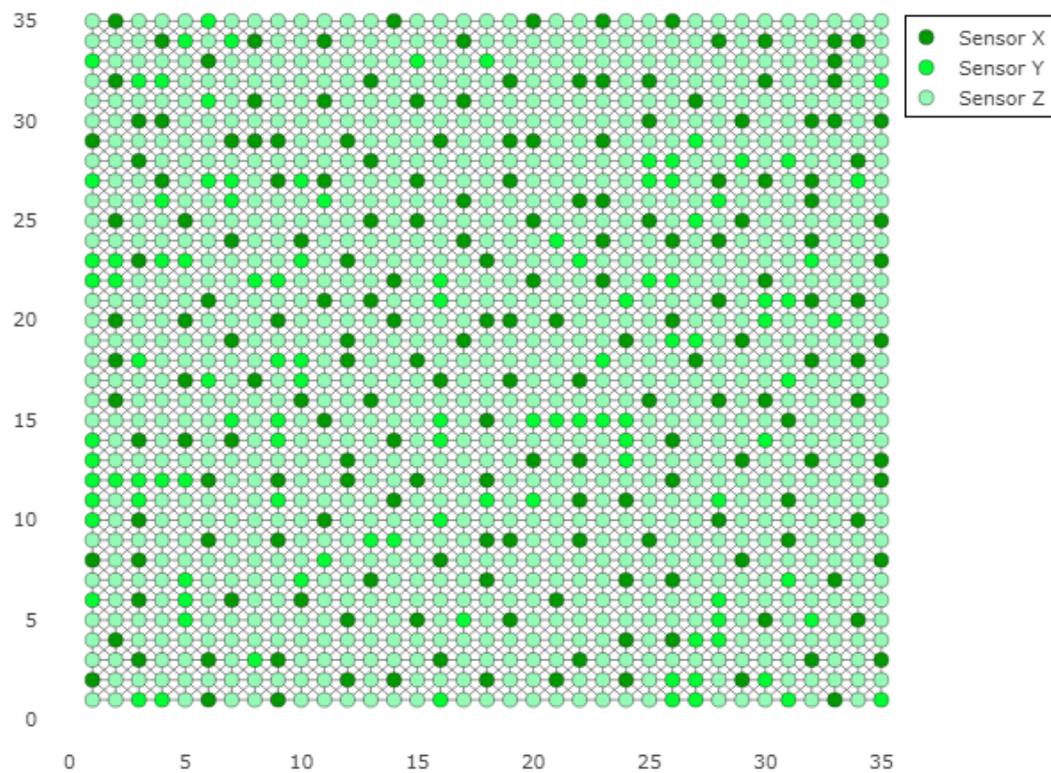


(b) Otimizada pelo AG.

Figura 17 – Instâncias de formato regular de médio porte ($l = 15$).
 Fonte: o próprio autor.



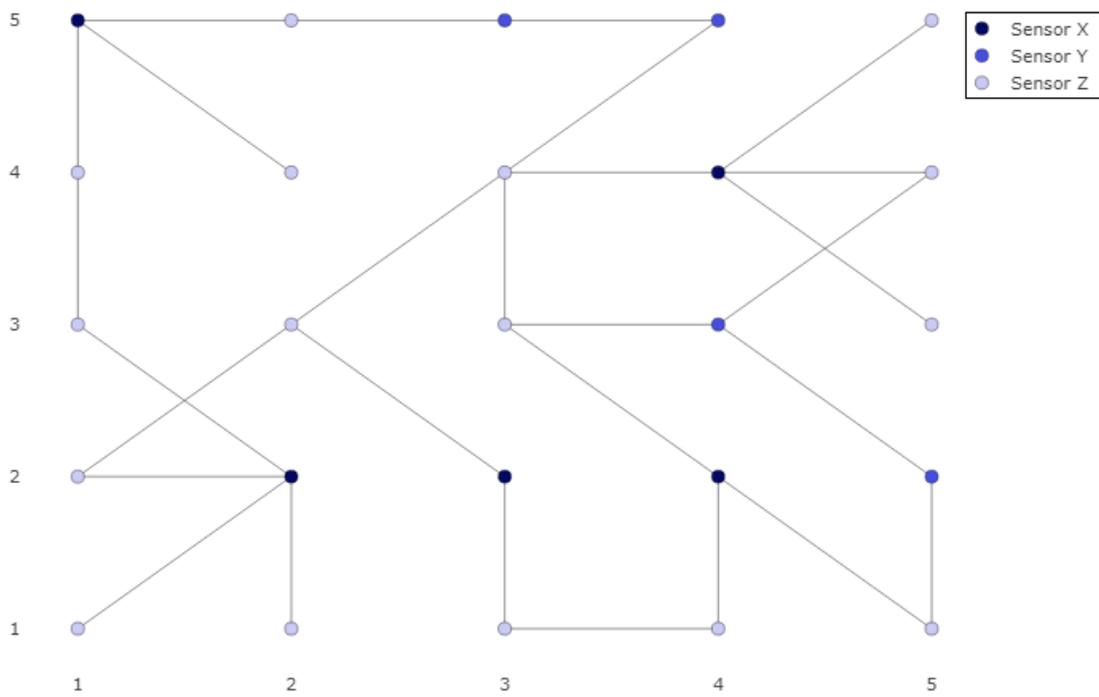
(a) Otimizada pela abordagem exata.



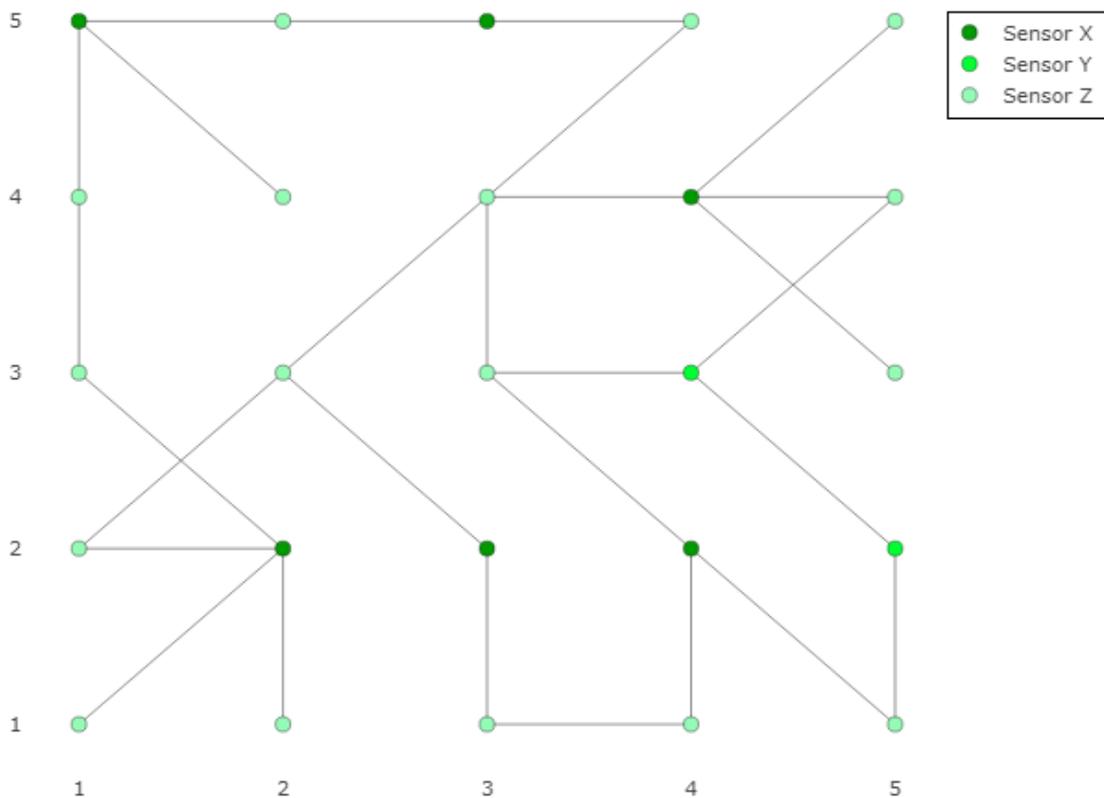
(b) Otimizada pelo AG.

Figura 18 – Instâncias de formato regular de grande porte ($l = 35$).

Fonte: o próprio autor.

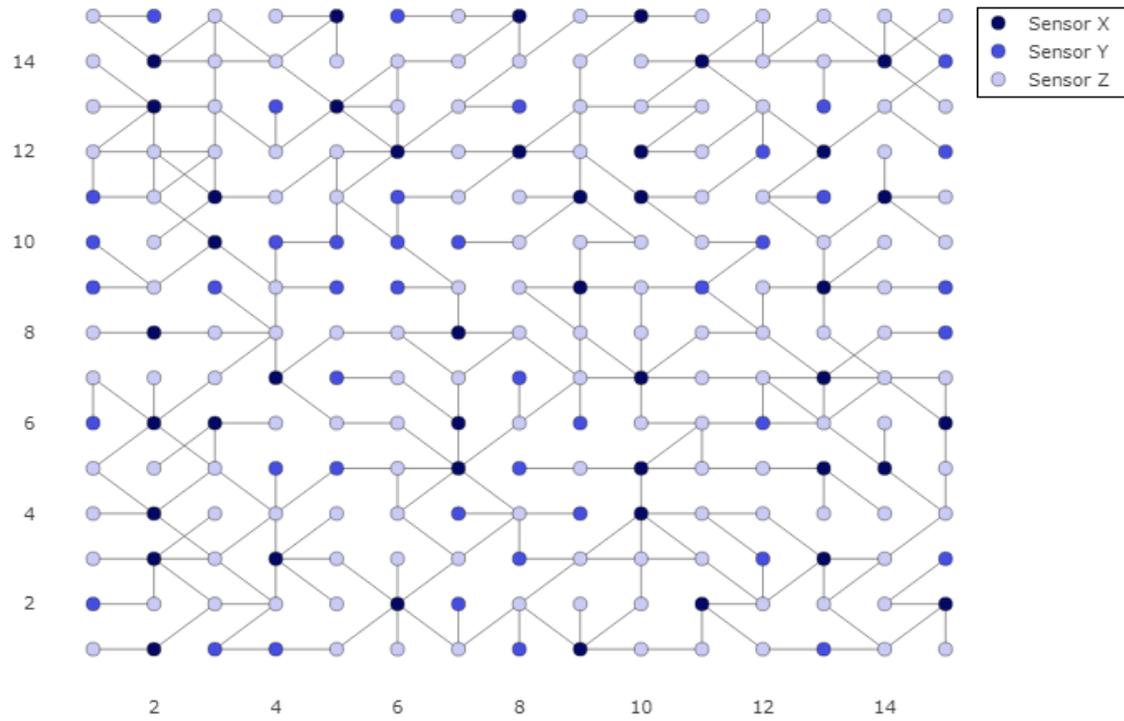


(a) Otimizada pela abordagem exata.

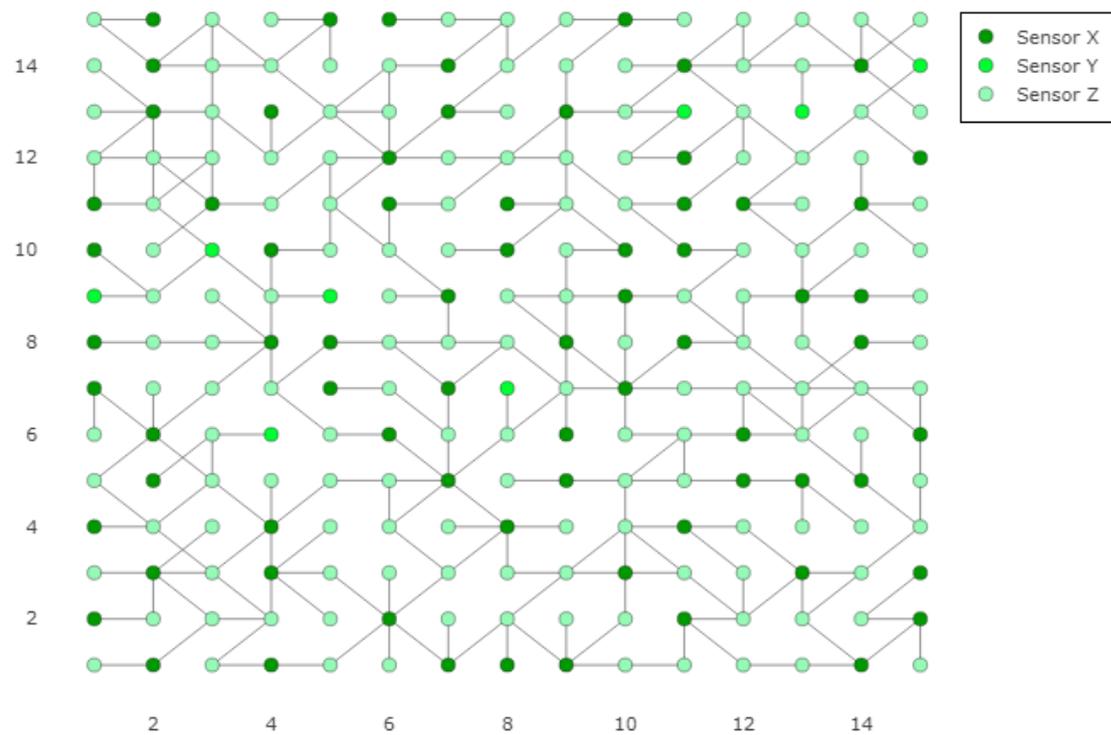


(b) Otimizada pelo AG.

Figura 19 – Instâncias de formato semirregular de pequeno porte (equivalente a $l = 5$).
Fonte: o próprio autor.

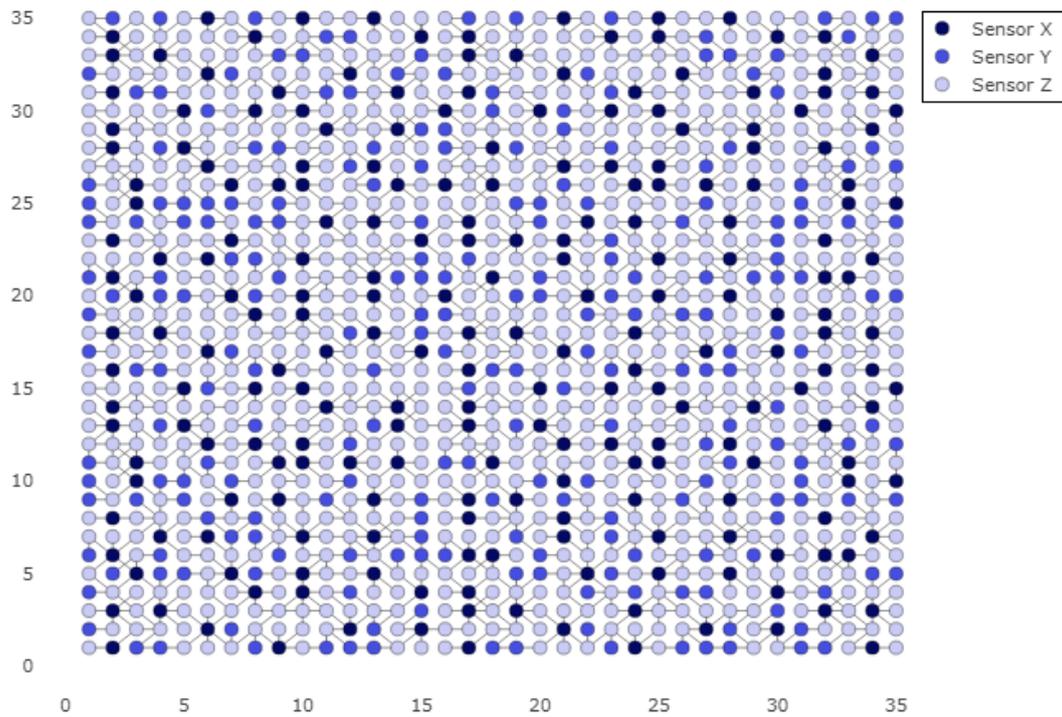


(a) Otimizada pela abordagem exata.

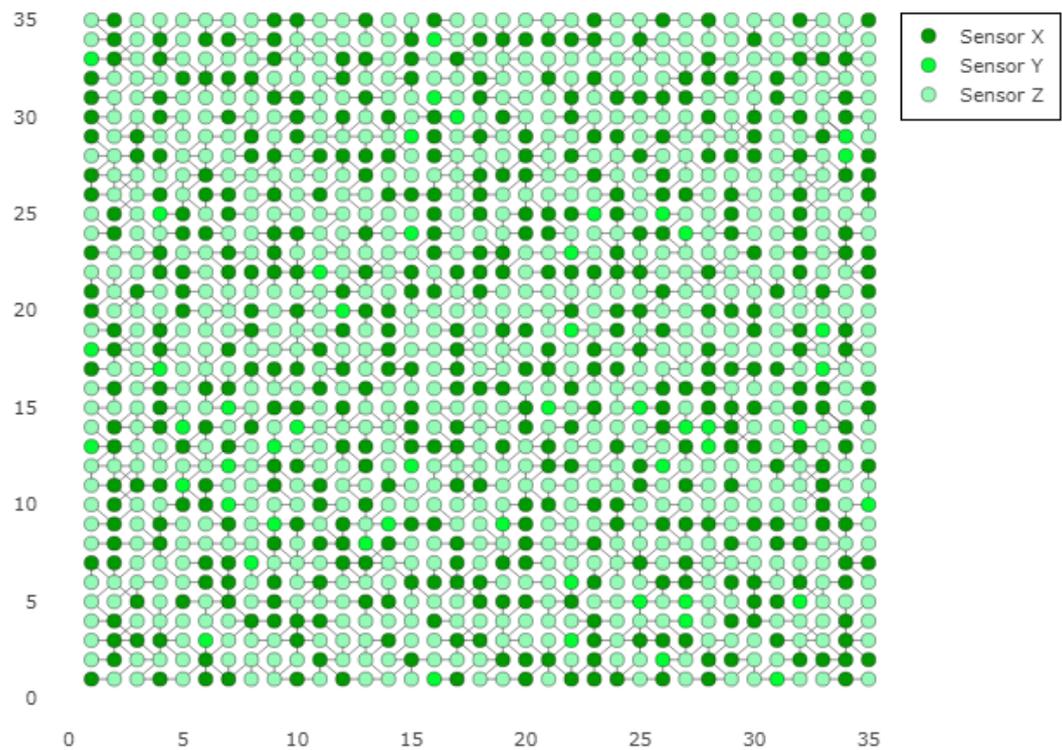


(b) Otimizada pelo AG.

Figura 20 – Instâncias de formato semirregular de médio porte (equivalente a $l = 15$).
 Fonte: o próprio autor.

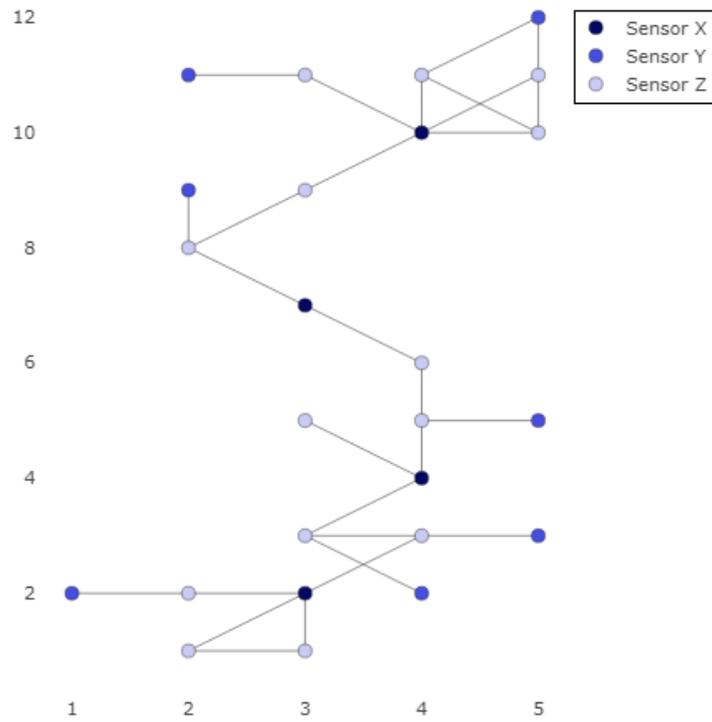


(a) Otimizada pela abordagem exata.

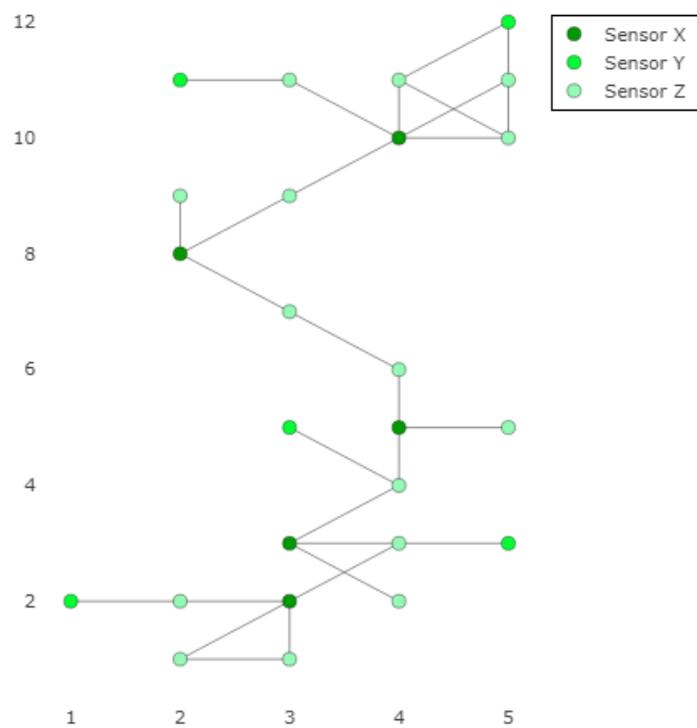


(b) Otimizada pelo AG.

Figura 21 – Instâncias de formato semirregular de grande porte (equivalente a $l = 35$).
 Fonte: o próprio autor.

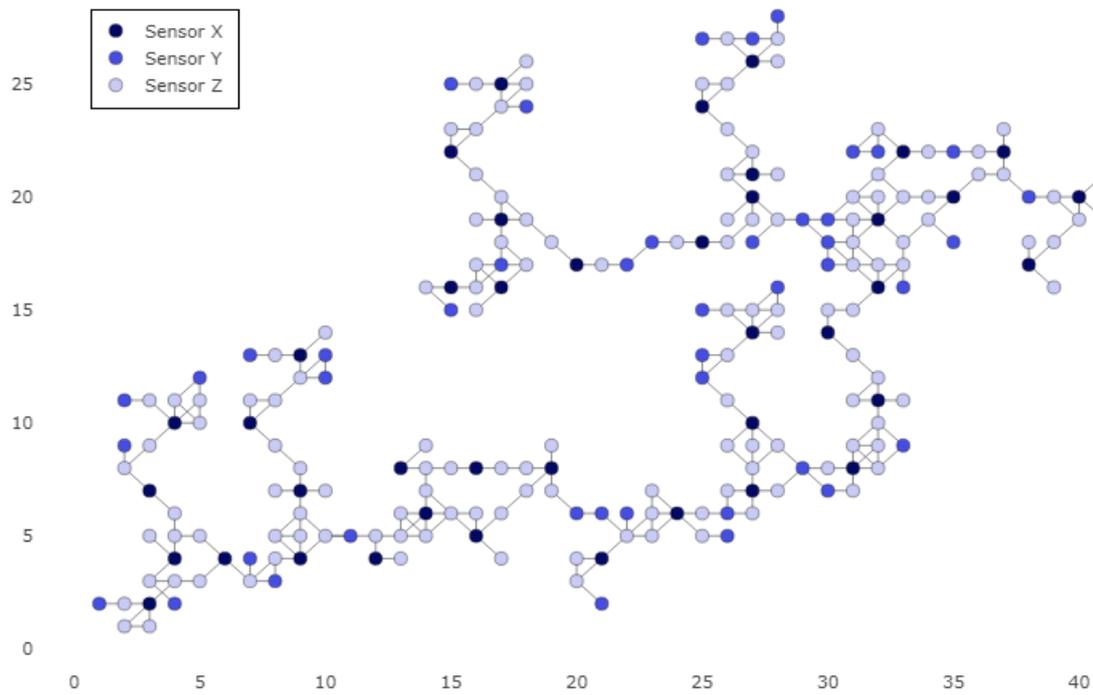


(a) Otimizada pela abordagem exata.

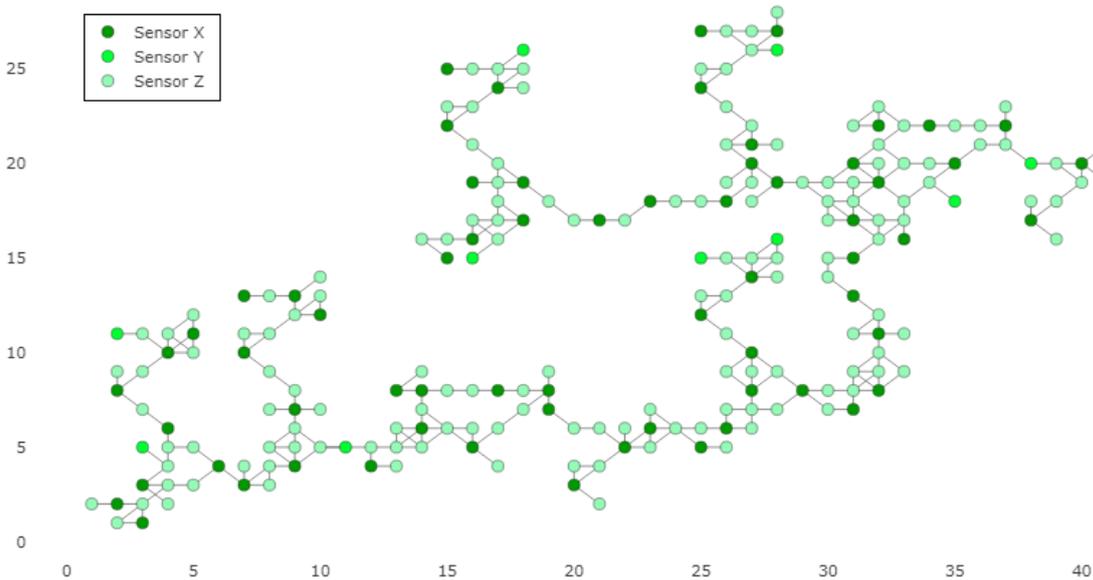


(b) Otimizada pelo AG.

Figura 22 – Instâncias de formato irregular de pequeno porte (equivalente a $l = 5$).
 Fonte: o próprio autor.

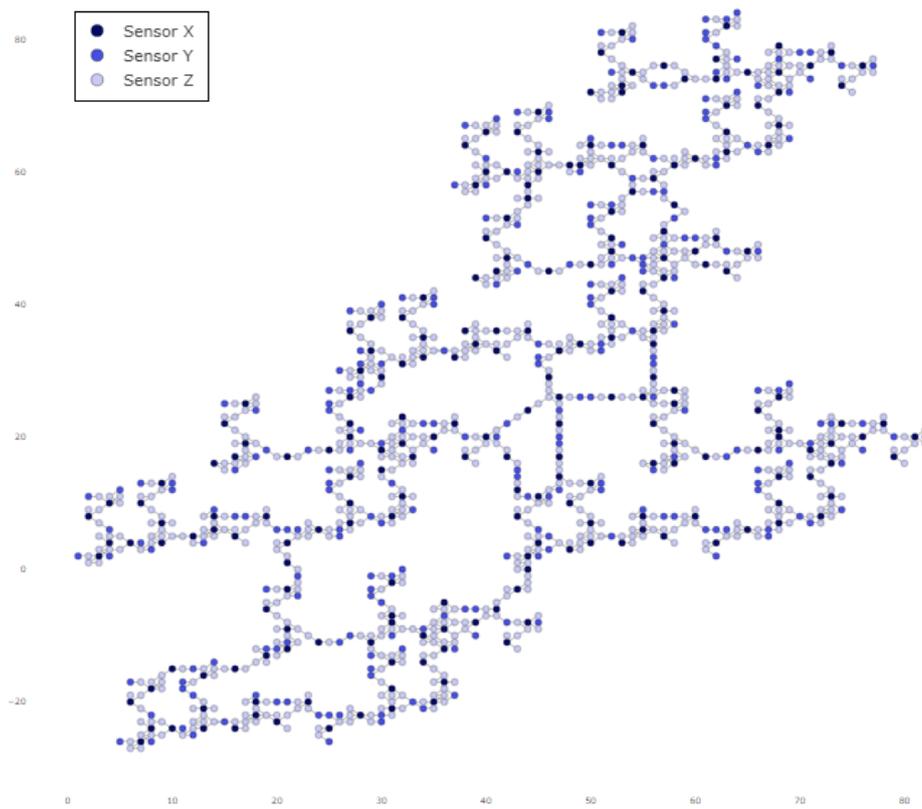


(a) Otimizada pela abordagem exata.

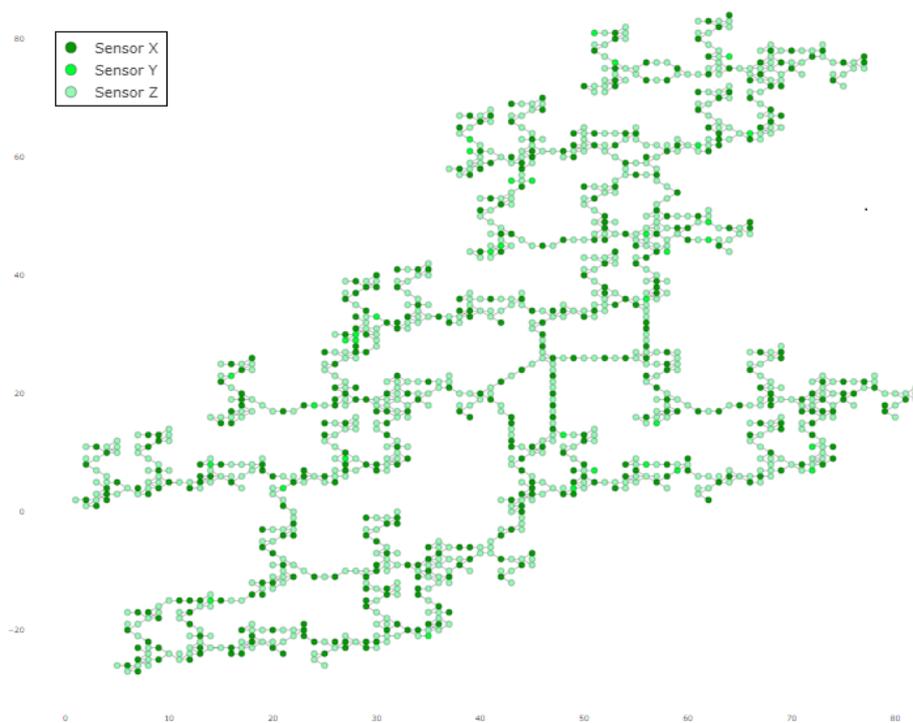


(b) Otimizada pelo AG.

Figura 23 – Instâncias de formato irregular de médio porte (equivalente a $l = 15$).
 Fonte: o próprio autor.



(a) Otimizada pela abordagem exata.



(b) Otimizada pelo AG.

Figura 24 – Instâncias de formato irregular de grande porte (equivalente a $l = 35$).
Fonte: o próprio autor.

5- Conclusão e Trabalhos Futuros

Esta pesquisa teve como objetivo geral a comparação entre os resultados de métodos de otimização para o Problema de Alocação de Sensores (PAS). Foi definido que esta comparação seria entre um método exato e um heurístico. O problema proposto partiu dos artigos-base de Brito et al. [2019, 2022]. Manteve-se o AG dos artigos-base citados, como método heurístico, e o método exato foi tratado via *Solver*. O problema foi alterado para se adequar melhor à comparação entre os métodos. O modelo matemático do problema foi criado e detalhado e os hiperparâmetros do AG foram destacados e otimizados por técnicas estatísticas. Também foram otimizadas instâncias grandes. Além disso, a otimização englobou instâncias de rede de formatos não regulares, semirregular e irregular, via grafos.

O desenvolvimento do modelo matemático ampliou a pesquisa dos artigos-base citados e permitiu a implementação da abordagem exata, que gerou resultados ótimos em instâncias de portes pequeno, médio e grande para o PAS. Independente da comparação, este resultado foi muito positivo, por superar os tamanhos de instâncias encontrados em vários artigos na literatura para PAS similares. No tempo limite estipulado, foram alcançados resultados ótimos para instâncias de rede de formato regular com até 5184 nós sensores, uma rede quadrada com contendo 72 sensores de lado. Tratando-se de redes de formato regular, para o PAS estudado, no tempo limite, é imperativo que a abordagem exata seja utilizada. Como o aumento do tempo de otimização é muito acentuado nas últimas instâncias, mesmo com um tempo maior disponível, é previsível que não será possível a otimização em instâncias muito maiores. Desta forma, a partir desse tamanho, o AG começa a ser uma opção válida.

O AG alcançou quase o dobro de instâncias otimizadas no mesmo tempo limite que a abordagem exata, além de ter um crescimento constante e linear no tempo de execução, mostrando que poderia ter ainda muitas execuções caso o tempo fosse estendido. Esta pesquisa mostra o aumento na perda de qualidade do AG conforme o aumento do tamanho das instâncias. Numa aplicação real, caso a qualidade não seja aceitável, há ações a serem feitas. Para os hiperparâmetros, ações interessantes seriam (i) otimizar os hiperparâmetros em instâncias maiores; (ii) aumentar o conjunto de configurações

disponível para otimização dos hiperparâmetros (*budgets*); e (iii) redução da quantidade de hiperparâmetros. Sobre o AG, poderia ser testadas diferentes estruturas internas: método de seleção, método de cruzamento e método de mutação.

Como trabalhos futuros, esta pesquisa evidencia pontos necessários de aprofundamento ou evolução, tais quais:

- Exploração dos motivos das variações de desempenho na abordagem exata, quando instâncias maiores são otimizadas em menor tempo que instâncias menores;
- Exploração de tempos limites maiores em ambos os métodos;
- Exploração da otimização dos hiperparâmetros alinhada a possíveis alterações de estrutura do AG;
- Exploração dos formatos não regulares como foco de pesquisa.

Além das questões citadas, existem sugestões de trabalhos futuros baseados na evolução técnica e no conhecimento trazidos por este trabalho, para encontrar ou se conectar a novos ramos de pesquisa. Estas são citadas a seguir:

- Trabalhar a comparação entre métodos em um PAS multiobjetivo;
- Incluir redes com conexões pelo posicionamento geográfico;
- Modelagem de redes além de duas dimensões.

Referências Bibliográficas

- Abusafia, A., Al Aghbari, Z., and Kamel, I. (2016). Phenomena Detection in Mobile Wireless Sensor Networks. *Journal of Network and Systems Management*, 24(1):92–115.
- Akyildiz, I. F., Jornet, J. M., and Pierobon, M. (2011). Nanonetworks: A new frontier in communications. *Communications of the ACM*, 54(11):84–89.
- Akyildiz, I. F. and Stuntebeck, E. P. (2006). Wireless underground sensor networks: Research challenges. *Ad Hoc Networks*, 4(6):669–686.
- Akyildiz, I. F., Su, W., Sankarasubramaniam, Y., and Cayirci, E. (2002). Wireless sensor networks: A survey. *Computer Networks*, 38(4):393–422.
- Alippi, C., Camplani, R., Galperti, C., and Roveri, M. (2011). A robust, adaptive, solar-powered WSN framework for aquatic environmental monitoring. *IEEE Sensors Journal*, 11(1):45–55.
- Alves, L. H. S., Antunes, E., Ferreira, R., and Nacif, J. A. M. (2019). A Mesh Sensor Network based on Bluetooth: Comparing Topologies to Crop Monitoring. In *SIMPÓSIO BRASILEIRO DE ENGENHARIA DE SISTEMAS COMPUTACIONAIS (SBESC)*, pages 125–130.
- Arroyo, J. E. C. (2002). *Heurísticas e metaheurísticas para otimização combinatória multiobjetivo*. Tese de doutorado, UNICAMP.
- Barbosa, T. M. G. d. A. (2008). *Uma arquitetura de redes de sensores do corpo humano*. Tese de doutorado, Universidade de Brasília.
- Bhondekar, A. P., Vig, R., Singla, M. L., Ghanshyam, C., and Kapur, P. (2009). Genetic Algorithm Based Node Placement Methodology For Wireless Sensor Networks. *Proceedings of the International MultiConference of Engineers and Computer Scientists*, 1:7.
- Bondy, J. A. and Murty, U. S. R. (1976). *Graph Theory With Applications*. Elsevier Science Publishing Co. Inc., 5 edition.

- Boukerche, A. and Sun, P. (2018). Connectivity and coverage based protocols for wireless sensor networks. *Ad Hoc Networks*, 80:54–69.
- Brito, J. A. G. D., Junior, J. R. D. P., Henriques, F. D. R., and Assis, L. S. D. (2019). Topology control optimization of wireless sensor networks for IoT applications. *Proceedings of the 25th Brazillian Symposium on Multimedia and the Web, WebMedia 2019*, pages 477–480.
- Brito, J. A. G. D., Totte, D. R. M., Silva, F. O., Junior, J. R. D. P., Henriques, F. D. R., Haddad, D. B., and Assis, L. S. D. (2022). Memetic Algorithm Applied to Topology Control Optimization of a Wireless Sensor Network. *Wireless Networks*, pages 1–21.
- Castaño, F., Rossi, A., Sevaux, M., and Velasco, N. (2018). An exact approach to extend network lifetime in a general class of wireless sensor networks. *Information Sciences*, 433-434:274–291.
- Chee-Yee Chong and Kumar, S. (2003). Sensor networks: Evolution, opportunities, and challenges. *Proceedings of the IEEE*, 91(8):1247–1256.
- Chen, H., Li, X., and Zhao, F. (2016). A reinforcement learning-based sleep scheduling algorithm for desired area coverage in solar-powered wireless sensor networks. *IEEE Sensors Journal*, 16(8):2763–2774.
- Chvátal, V. (1983). *Linear Programming*. W. H. Freeman and Company.
- Djedouboum, A. C., Ari, A. A. A., Gueroui, A. M., Mohamadou, A., and Aliouat, Z. (2018). Big data collection in large-scale wireless sensor networks. *Sensors (Switzerland)*, 18(12):1–34.
- Eshaftri, M. (2017). *Adaptative Energy Management Mechanisms for Cluster Based Routing*. Tese de doutorado, Edinburgh Napier University.
- Felemban, E., Shaikh, F. K., Qureshi, U. M., Sheikh, A. A., and Qaisar, S. B. (2015). Underwater Sensor Network Applications: A Comprehensive Survey. *International Journal of Distributed Sensor Networks*, 2015.
- Floréen, P., Kaski, P., Kohonen, J., and Orponen, P. (2005). Exact and approximate balanced data gathering in energy-constrained sensor networks. *Theoretical Computer Science*, 344(1):30–46.

- Ghosh, A. and Das, S. K. (2008). Coverage and connectivity issues in wireless sensor networks: A survey. *Pervasive and Mobile Computing*, 4(3):303–334.
- Gu, Y., Liu, H., and Zhao, B. (2007). Target coverage with QoS requirements in wireless sensor networks. *Proceedings The 2007 International Conference on Intelligent Pervasive Computing, IPC 2007*, pages 35–38.
- Hassanat, A., Almohammadi, K., Alkafaween, E., Abunawas, E., Hammouri, A., and Prasath, V. B. S. (2019). Choosing Mutation and Crossover Ratios for Genetic Algorithms - A Review with a New Dynamic Approach. *Information (Switzerland)*, 10.
- Henriques, F. D. R., Lovisolo, L., and Rubinstein, M. G. (2016). DECA: distributed energy conservation algorithm for process reconstruction with bounded relative error in wireless sensor networks. *Eurasip Journal on Wireless Communications and Networking*, 2016(1).
- Henriques, F. D. R., Lovisolo, L., and Silva, E. A. B. D. (2019). Rate-distortion performance and incremental transmission scheme of compressive sensed measurements in wireless sensor networks. *Sensors (Switzerland)*, 19(2).
- Hillier, F. S. and Lieberman, G. J. (2010). *Introduction to Operations Research*. McGraw-Hill.
- Hollar, S. E.-A. (1996). *COTS Dust*. Master thesys, University of California, Berkeley.
- Hussain, S. and Islam, O. (2007). An energy efficient spanning tree based multi-hop routing in wireless sensor networks. *IEEE Wireless Communications and Networking Conference, WCNC*, pages 4386–4391.
- Ishizuka, M. and Aida, M. (2004). Performance study of node placement in sensor networks. *Proceedings - International Conference on Distributed Computing Systems*, 24:598–603.
- Javaid, M., Haleem, A., Rab, S., Pratap Singh, R., and Suman, R. (2021). Sensors for daily life: A review. *Sensors International*, 2(July):100121.
- Jondhale, S. R., Maheswar, R., and Lloret, J. (2022). Fundamentals of Wireless Sensor Networks. In *EAI/Springer Innovations in Communication and Computing*, pages 1–19. John Wiley & Sons.

- Kandris, D., Nakas, C., Vomvas, D., and Koulouras, G. (2020). Applications of Wireless Sensor Networks: An Up-to-Date Survey. *Applied System Innovation*, 3(1):14.
- Kim, H. and Han, S. W. (2015). An efficient sensor deployment scheme for large-scale wireless sensor networks. *IEEE Communications Letters*, 19(1):98–101.
- Lee, J. (2017). Optimal power allocating for correlated data fusion in decentralized WSNs using algorithms based on swarm intelligence. *Wireless Networks*, 23(5):1655–1667.
- Li, W. and Gong, W. (2021). An improved multioperator-based constrained differential evolution for optimal power allocation in WSNs. *Sensors*, 21(18).
- López-Ibáñez, M., Dubois-Lacoste, J., Pérez Cáceres, L., Birattari, M., and Stützle, T. (2016). The irace package: Iterated racing for automatic algorithm configuration.
- Mao, S., Cheng, X., Hou, Y. T., and Sherali, H. D. (2006). Multiple description video multicast in wireless ad hoc networks. *Mobile Networks and Applications*, 11(1 SPEC. ISS.):63–73.
- Morais, V. W. C. D. (2018). *Projeto de Redes de Sensores Sem Fio: Formulações e Algoritmos Exatos*. PhD thesis, Universidade Federal de Minas Gerais.
- Ozkan, O., Ermis, M., and Bekmezci, I. (2019). Reliable wireless multimedia sensor network design: comparison of hybrid metaheuristics and a matheuristic. *Computational and Applied Mathematics*, 38(3).
- Ribeiro, W. G. (2012). *Aplicação de Metaheurísticas para o Problema de Cobertura e Roteamento em Redes de Sensores Sem Fio*. Dissertação de mestrado, Universidade Federal de Viçosa.
- Sadi, Y. and Ergen, S. C. (2013). Optimal power control, rate adaptation, and scheduling for UWB-based intravehicular wireless sensor networks. *IEEE Transactions on Vehicular Technology*, 62(1):219–234.
- Sandeep Verma (2013). Network Topologies in Wireless Sensor Networks: A Review 1. *International Journal of Electronics & Communication Technology*, 4(3):1–5.
- Shabbir, N. and Hassan, S. R. (2017). Routing Protocols for Wireless Sensor Networks (WSNs). *Wireless Sensor Networks - Insights and Innovations*, pages 197–228.

- Silva, B., Fisher, R. M., Kumar, A., and Hancke, G. P. (2015). Experimental Link Quality Characterization of Wireless Sensor Networks for Underground Monitoring. *IEEE Transactions on Industrial Informatics*, 11(5):1099–1110.
- Singh, S. K., Singh, M. P., and Singh, D. K. (2010). A Survey of Energy-Efficient Hierarchical Cluster-Based Routing in Wireless Sensor Networks. *Int. J. of Advanced Networking and Applications*, 570(02):2–570.
- Slijepcevic, S. and Potkonjak, M. (2001). Power Efficient Organization of Wireless Sensor Networks. In *IEEE international conference on communications*, volume 2, pages 472–476, Los Angeles, CA.
- Soni, N. and Kumar, T. (2014). Study of Various Mutation Operators in Genetic Algorithms. *International Journal of Computer Science and Information Technologies (IJCSIT)*, 5(3):4519–4521.
- Srinivasa Rao, P. C. and Banka, H. (2017). Energy efficient clustering algorithms for wireless sensor networks: novel chemical reaction optimization approach. *Wireless Networks*, 23(2):433–452.
- Srivastava, A. and Mishra, P. K. (2021). A Survey on WSN Issues with its Heuristics and Meta-Heuristics Solutions. *Wireless Personal Communications*, 121(1):745–814.
- Srivastava, J. R. and Sudarshan, T. S. (2015). Energy-efficient cache node placement using genetic algorithm in wireless sensor networks. *Soft Computing*, 19(11):3145–3158.
- Thike, A. M., Lupin, S., Chakirov, R., and Vagapov, Y. (2016). Topology Optimisation of Wireless Sensor Networks. *MATEC Web of Conferences*, 82.
- Ting, C.-K. and Liao, C.-C. (2010). A memetic algorithm for extending wireless sensor network lifetime. *Information Sciences*, 180(24):4818–4833.
- Tossa, F., Abdou, W., Ansari, K., Ezin, E. C., and Gouton, P. (2022). Area Coverage Maximization under Connectivity Constraint in Wireless Sensor Networks. *Sensors*, 22(5):1–20.
- Trang, H. T. H., Dung, L. T., and Hwang, S. O. (2018). Connectivity analysis of underground sensors in wireless underground sensor networks. *Ad Hoc Networks*, 71:104–116.

- Upadhayay, V. and Agarwal, S. (2012). Application of Wireless Nano Sensor Networks for Wild Lives. *International Journal of Distributed and Parallel systems*, 3(4):173–181.
- Üster, H. and Lin, H. (2011). Integrated topology control and routing in wireless sensor networks for prolonged network lifetime. *Ad Hoc Networks*, 9(5):835–851.
- Xie, S. and Wang, Y. (2014). Construction of tree network with limited delivery latency in homogeneous wireless sensor networks. *Wireless Personal Communications*, 78(1):231–246.
- Yang, L., Zhu, H., Wang, H., Kang, K., and Qian, H. (2019). Data censoring with network lifetime constraint in wireless sensor networks. *Digital Signal Processing: A Review Journal*, 92:73–81.
- You, F., Castro, P. M., and Grossmann, I. E. (2009). Dinkelbach's Algorithm as an Efficient Method for Solving a Class of MINLP Models for Large-Scale Cyclic Scheduling Problems. *Computers & Chemical Engineering*, 33(11):1–29.
- Zanjireh, M. M., Shahrabi, A., and Larijani, H. (2013). ANCH: A New Clustering Algorithm for Wireless Sensor Networks. In *2013 27th International Conference on Advanced Information Networking and Applications Workshops*, pages 450–455. IEEE.
- Zarepour, E., Hassan, N., Hassan, M., Chou, C. T., and Warkiani, M. E. (2015). Design and analysis of a wireless nanosensor network for monitoring human lung cells. *BodyNets International Conference on Body Area Networks*.
- Zhang, D.-g., Zheng, K., Zhang, T., and Wang, X. (2014). A novel multicast routing method with minimum transmission for WSN of cloud computing service. *Soft Computing*, 19(7):1817–1827.
- Zheng, J. and Jamalipour, A. (2009). *Wireless Sensor Networks: A Networking Perspective*. IEEE.