



UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
INSTITUTO DE COMPUTAÇÃO - ICOMP
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA - PPGI

**MODELOS E HEURÍSTICAS PARA O PROBLEMA
DE CONTROLE DE DENSIDADE EM REDES DE
SENSORES SEM FIO PLANAS**



UNIVERSIDADE FEDERAL DO AMAZONAS - UFAM
INSTITUTO DE COMPUTAÇÃO - ICOMP
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA - PPGI

ADRIANA GOMES PEÑARANDA

**MODELOS E HEURÍSTICAS PARA O PROBLEMA
DE CONTROLE DE DENSIDADE EM REDES DE
SENSORES SEM FIO PLANAS**

Dissertação apresentada ao Programa de Pós-Graduação em Informática do Instituto de Ciência da Computação da Universidade Federal do Amazonas como requisito parcial para a obtenção do grau de Mestre em Informática.

ORIENTADOR: FABÍOLA GUERRA NAKAMURA

Manaus

Fevereiro de 2013

Agradecimentos

Em primeiro lugar, agradeço a Deus por permitir realizar mais um sonho e me dar forças nos momentos difíceis.

Agradeço à minha orientadora Prof. Dr^a. Fabiola Guerra Nakamura, por me conduzir de forma brilhante, por estar sempre disposta a me ajudar em todos os problemas e por ter acreditado que eu seria capaz de desenvolver o trabalho. Todas essas características só me fazem ter a certeza que eu não poderia ter escolhido outra orientadora senão ela.

Também gostaria de agradecer a todos que me ajudaram, direta e indiretamente, na realização deste trabalho. Aos amigos Cristian, Diego, Ludimila e Rafael e a todos os outros amigos, que me acompanham desde a graduação, pela ajuda nas disciplinas e pelos finais de semanas dedicados aos estudos. Agradeço, em especial, ao André Ricardo Melo Araújo pelo carinho, paciência, dedicação e motivação durante esses seis anos. A todos os amigos que conheci durante o mestrado e aos amigos do Laboratório de Otimização, pela ajuda no desenvolvimento da pesquisa, desde a instalação de softwares até o apoio nos eventos e conferências, e também pelas críticas e sugestões que com certeza só trouxeram contribuições para o trabalho.

Aos pais maravilhosos, Martha e Manuel, e ao irmão Hugo, por sempre me apoiarem e por proporcionarem a base da minha educação sem a qual não poderia chegar até aqui. Muito obrigada pelos ensinamentos e dedicação, saibam que os amo e sempre lembrarei de vocês em cada vitória que alcançar.

Por último, não menos importante, à secretaria, em especial, à Elienai por sempre me ajudar com os problemas administrativos. À FAPEAM, por conceder a bolsa de estudos permitindo a realização deste trabalho e à UFAM por me proporcionar passagens e diárias para que eu pudesse participar de conferências.

Resumo

As Redes de Sensores Sem Fios (RSSFs) são redes compostas por um grande número de nós de sensores. Estas redes necessitam de controle de densidade para garantir um melhor funcionamento, pois a alta concentração de nós sensores gera colisão de dados, interferências e conseqüentemente retransmissão de dados. Os nós sensores possuem limitações de energia, processamento e comunicação e por isto é interessante otimizar o consumo de energia da rede com o objetivo de estender seu tempo de vida. Esquemas de controle de densidade têm sido utilizados como recursos para prolongar o tempo de vida da rede. O Problema de Controle de Densidade em Redes de Sensores Sem Fios (PCD-RSSFs) consiste em minimizar a energia consumida pelos nós sensores ativos, escolhendo um subconjunto de nós que atenda os requisitos da aplicação e maximize a utilização dos recursos da rede. Este trabalho apresenta duas abordagens para tratar o PCD-RSSFs: Periódica e Multiperíodo. A Abordagem Periódica escolhe a melhor solução para um dado período, tendo uma visão local do tempo de vida da rede e repete este procedimento periodicamente. A Abordagem Multiperíodo consiste em definir um tempo esperado de vida da rede e dividi-lo em períodos. Para cada período a solução é escolhida levando em consideração os outros períodos, caracterizando uma visão global do tempo de vida da rede e dos períodos. Ambas as abordagens foram modeladas com Programação Linear Inteira e resolvidas por um *software* de otimização. Para a modelagem da Abordagem Periódica é proposta uma Relaxação Lagrangeana em conjunto com uma Heurística Lagrangeana onde a ideia é relaxar restrições “difíceis” com o intuito de deixar o problema mais simples de ser resolvido. Também é apresentado um Algoritmo Genético (AG) híbrido que utiliza Abordagem Periódica para gerar a solução de cada período e em seguida uma fase de refinamento baseada nos conceitos da Abordagem Multiperíodo. As heurísticas implementadas são comparadas com algoritmos da literatura e os resultados mostram que a combinação Relaxação Lagrangeana e Heurística Lagrangeana obtêm melhor desempenho tanto em consumo de energia quanto em tempo de solução. Além disso a Relaxação Lagrangeana gera limites inferiores para o PCD-RSSFs que podem ser utilizados para avaliação de outros

algoritmos de controle de Densidade.

Palavras-chaves: Redes de Sensores sem Fios, Problema de Controle de Densidade, Relaxação Lagrangeana, Programação Linear Inteira.

Abstract

Wireless Sensor Networks (WSNs) are composed of a large number of sensor nodes. These networks require density control to ensure a better functioning because the high concentration of sensor nodes generates collision data, interference, and retransmissions. In addition, sensor nodes have limited energy, processing, and communication, therefore is interesting to optimize the energy consumption of the network in order to extend its lifetime. Density control schemes have been used to prolong the network lifetime. The Density Control Problem in Wireless Sensor Networks (DCP-WSNs) minimizes the energy consumed by the sensor nodes active, choosing a subset of sensor nodes that meets the application requirements and maximize the use of network resources. This paper presents two approaches to treat DCP-WSN: Periodic and Multiperiod. The Periodic Approach always chooses the best solution for a given period, having a local view of the network lifetime and repeats this procedure periodically. The Multiperiod Approach defines an expected life time of the network and divide it into periods. For each period the solution is chosen taking into consideration the other periods, thus with an global view of the network lifetime and periods. Both approaches are modeled with Integer Linear Programming and solved by an optimization software. For the Periodic Approach model is proposed a Lagrangean Relaxation with a Lagrangean Heuristic which relax “difficults” constraints in order to make the problem easier to be solved. We also present a Genetic Algorithm Hybrid (GA) which uses the Periodic Approach to generate the solution of each period and execute a refinement stage based on concepts of the Multiperiod Approach. The proposed heuristics are compared with algorithms of the literature and results show that the Lagrangean Relaxation and Heuristic reach better energy consumption and solution time. Furthermore the Lagrangean relaxation generates lower bounds for the DCP-WSN that may be used to evaluate other algorithms Density Control.

Keywords: Wireless Sensor Networks, Density Control Problem, Lagrangean Relaxation, Integer Linear Programming.

Sumário

Agradecimentos	iii
Resumo	iv
Abstract	vi
Lista de Figuras	ix
Lista de Tabelas	x
1 Introdução	1
1.1 Motivação	1
1.2 Objetivo	3
1.3 Contribuição	3
1.4 Estrutura do Documento	4
2 Fundamentos	5
2.1 Características das RSSFs	5
2.2 Controle de Densidade x Consumo de energia	5
2.3 Características do Problema	7
2.3.1 Controle de densidade em RSSFs Homogêneas e Heterogêneas	7
2.3.2 Controle de densidade em RSSFs Planas e Hierárquicas	7
2.4 Trabalhos Relacionados	8
2.4.1 <i>Geographical Adaptive Fidelity</i>	10
2.4.2 <i>Hierarchical Geographical Adaptive Fidelity</i>	11
2.5 Considerações Finais	12
3 Abordagem Periódica	13
3.1 Definição do problema	14
3.2 Formulação Matemática	14

3.3	Modelo Periódico Relaxado	17
3.3.1	Relaxação Lagrangeana	17
3.3.2	Problema Lagrangeano	18
3.3.3	Limite Inferior	19
3.3.4	Lagrangeano Dual	22
3.3.5	Limite Superior	24
3.4	Considerações Finais	26
4	Abordagem Multiperíodo	28
4.1	Formulação Matemática	28
4.2	Considerações Finais	32
5	Algoritmo Genético	33
5.1	Algoritmo Genético Proposto	35
5.1.1	Representação da Solução	35
5.1.2	Cruzamento	35
5.2	Mutação	35
5.2.1	Funcionamento Básico	36
5.3	Considerações Finais	38
6	Resultados Computacionais	39
6.1	Instâncias	39
6.2	Parâmetros de Entrada	40
6.3	Bateria 1	41
6.4	Bateria 2	45
6.5	Bateria 3	47
6.6	Bateria 4	49
6.7	Considerações Finais	51
7	Considerações Finais	53
7.1	Conclusões	53
7.2	Trabalhos Publicados	55
7.3	Trabalhos Futuros	55
	Referências Bibliográficas	57

Lista de Figuras

1.1	Definição do Problema de Controle de densidade.	2
2.1	Provedor e consumidores de energia de um nó sensor [Nakamura, 2010]. . .	6
2.2	Divisão da área de monitoramento em grades virtuais [Xu et al., 2001] . .	10
2.3	Divisão da grade em N^2 subgrades [Inagaki & Ishihara, 2009].	11
3.1	Grafo com nós sensores e arestas pertencentes ao caminho do nó 1 ao sorvedouro m.	21
3.2	Grafo com nós sensores duplicados.	26
4.1	Comparação entre as duas abordagens	29
5.1	Funcionamento básico genético.	34
5.2	Representação de uma solução do genético para um período.	35
5.3	Operação de Cruzamento: Utiliza a máscara para indicar qual gene será copiado de cada pai. Se a $mascara_{[i]} = 1$ então o cromossomo1 recebe o gene do pai2, caso contrário recebe o gene do pai1. Se a $mascara_{[i]} = 1$ então o cromossomo2 recebe o gene do pai1, caso contrário recebe o gene do pai2.	36
5.4	Conjunto de soluções gerado com o Algoritmo Genético.	37
5.5	Fase de refinamento onde um nó sensor sai da solução do período 1 e vai para a solução do período t.	38
6.1	Grade irregular com os nós sensores dispostos na área de monitoramento após o desvio aleatório em suas coordenadas (x, y)	40
6.2	Comparação do consumo de energia com 144 nós sensores.	50
6.3	Comparação do consumo de energia com 169 nós sensores.	50

Lista de Tabelas

2.1	Características das RSSFs.	6
6.1	Divisão do que cada bateria de teste compara.	41
6.2	Descrição das instâncias da bateria 1.	42
6.3	Resultados com 144 nós sensores da bateria 1.	43
6.4	Resultados com 169 nós sensores da bateria 1.	43
6.5	Tempo de execução dos testes com 144 nós sensores da bateria 1.	44
6.6	Tempo de execução dos testes com 169 nós sensores da bateria 1.	44
6.7	Descrição das instâncias da bateria 2.	45
6.8	Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 1 períodos.	45
6.9	Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 2 períodos.	45
6.10	Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 3 períodos.	46
6.11	Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 6 períodos.	46
6.12	Descrição das instâncias da bateria 4.	47
6.13	Comparação entre o valor ótimo para a Abordagem Periódica e Abordagem Multiperíodo com 25 nós sensores.	48
6.14	Comparação entre o valor ótimo para a Abordagem Periódica e Abordagem Multiperíodo com 36 nós sensores.	48
6.15	Descrição das instâncias da bateria 4.	49
6.16	Comparação dos Tempos para 144 nós sensores.	51
6.17	Comparação dos Tempos para 169 nós sensores.	51

Capítulo 1

Introdução

1.1 Motivação

Com a popularização das redes sem fio *ad hoc* e os avanços nos dispositivos eletrônicos, deu-se origem as Redes de Sensores Sem Fios (RSSFs). As RSSFs são um tipo especial de rede móvel *ad hoc* que têm como objetivo monitorar ambientes e transmitir dados coletados a um observador. Elas possuem diversas áreas de aplicação como, por exemplo: no ambiente, fazendo rastreamento de animais; no tráfego, monitorando os veículos; na medicina, monitorando o funcionamento de órgãos; e na área militar, detectando presença de inimigos [Loureiro et al., 2002].

Estas redes são compostas por nós sensores que devido ao tamanho reduzido possuem restrições de energia, processamento e comunicação. Devido a estas restrições, as redes são formadas com maiores quantidades de nós sensores com o objetivo de se tornarem tolerantes a falhas, assim formando redes densas. Estas redes densas podem gerar colisão de pacotes e interferências, por isso um dos desafios é desenvolver estratégias que otimizem o uso da rede e prolonguem o seu tempo de vida, pois nem sempre é possível trocar ou fazer manutenção dos nós sensores [Siqueira et al., 2006]. Uma alternativa é desativar nós sensores redundantes para uso posterior. Esta estratégia além de preservar a energia dos nós sensores desativados também diminui a colisão de pacotes e interferências comuns em redes densas [Aioffi & Mateus, 2007].

A alta concentração de nós sensores por área gera dados redundantes, porém isso nem sempre é um requisito da aplicação e mesmo em casos que se faz necessário, há possibilidade de controle de densidade. O uso de mecanismos para escolher e desativar nós sensores é um recurso útil para estender o tempo de vida da rede e são comumente conhecidas como controle de densidade.

O Problema de Controle de Densidade em Redes de Sensores Sem Fios (PCD-

RSSFs) surge como um mecanismo para estender o tempo de vida da rede, que ao mesmo tempo tenta garantir a melhor utilização dos recursos da rede. O problema consiste em, dado a área de monitoramento discretizada em pontos de demanda e o conjunto de nós sensores, ativar um subconjunto de nós sensores que atenda os requisitos da aplicação, enquanto os demais serão desativados. Entre os requisitos podem ser destacados a cobertura da área, a conectividade dos nós sensores e o roteamento. O problema de cobertura refere-se a garantia da cobertura da área de monitoramento, e os problemas de conectividade e roteamento referem-se a garantia de conectividade entre os nós sensores ativos e o sorvedouro e a definição de uma rota entre cada nó sensor ativo e o sorvedouro. O subconjunto escolhido é o que melhor utiliza os recursos da rede, em geral, o que menos consome energia [Nakamura, 2010]. A Figura 1.1 ilustra o problema.

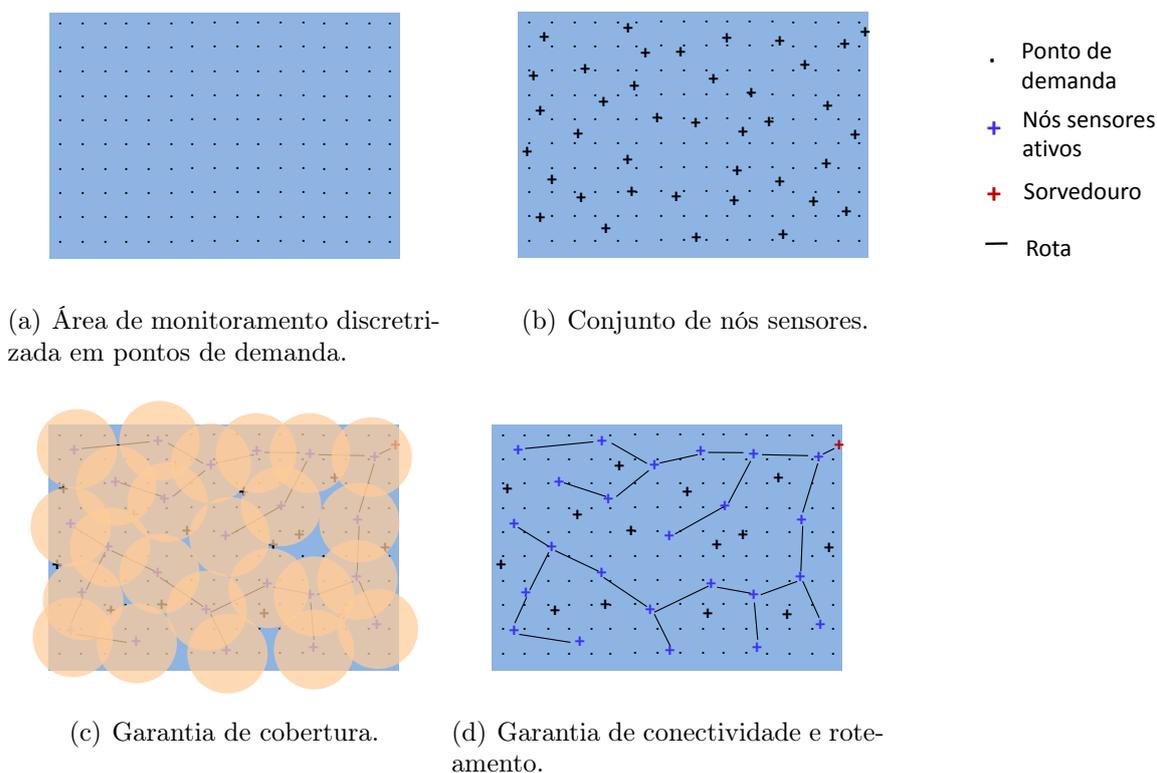


Figura 1.1. Definição do Problema de Controle de densidade.

O PCD-RSSFs é composto pelos subproblemas de conectividade, roteamento e cobertura, este último provado ser NP-Difícil por Karp (1972). O problema possui duas formas de aplicação, o que aumenta ainda mais o interesse em desenvolver soluções. Uma aplicação considera que os nós sensores já foram lançados na área de monitoramento e deseja-se saber quais nós sensores devem ficar ativos e quais devem ficar

desativados. Outra aplicação considera quais os possíveis locais que os nós sensores podem ser alocados, assim deseja-se saber em quais destes locais os nós sensores devem ser colocados.

Neste trabalho usamos duas abordagens para tratar o PCD-RSSFs: Periódica e Multiperíodo. A Abordagem Periódica escolhe a melhor solução para um dado período de tempo, tendo uma visão local do tempo de vida da rede e global dos nós, e repete este processo periodicamente. A Abordagem Multiperíodo consiste em definir um tempo esperado de vida da rede e dividi-lo em períodos. Para cada período a solução é escolhida levando em consideração os outros períodos, caracterizando visão global do tempo de vida da rede. Embora a Abordagem Multiperíodo tenha vantagem por possuir visão global da rede e dos períodos, exige maior esforço computacional para ser resolvida. Ambas podem ser modeladas com Programação Linear Inteira e utilizadas em algoritmos exatos e heurísticas.

1.2 Objetivo

O objetivo deste trabalho é desenvolver modelos e algoritmos para tratar o Problema de Controle de Densidade em Redes de Sensores Sem Fios (PCD-RSSFs). Os algoritmos e heurísticas têm como objetivo garantir a área de cobertura e a conectividade entre os nós sensores e o sorvedouro e minimizar o consumo de energia da rede. Para simular o aspecto dinâmico das RSSFs são propostas as Abordagens Periódica e Multiperíodo. Ambas são modeladas com Programação Linear Inteira e resolvidas com *software* de otimização com o intuito de avaliar o desempenho de cada abordagem. Além disso, limites inferiores são gerados com Relaxação Lagrangeana e utilizados para avaliar a Heurística Lagrangeana, o Algoritmo Genético proposto e outros algoritmos da literatura.

1.3 Contribuição

A principal contribuição deste trabalho é a criação de novas heurísticas para gerar soluções viáveis para o PCD-RSSFs. Os modelos matemáticos propostos são adaptações de dois outros encontrados na literatura, com mudanças em restrições que foram capazes de gerar resultados diferentes em métodos exatos, como a Relaxação Lagrangeana. Estas mudanças em restrições simplificam o modelo, porém ainda assim geram soluções que se aplicam ao problema. Além disso, a Relaxação Lagrangeana proposta utiliza outros algoritmos para geração de limites superiores. Também foi possível comparar

as soluções com resultados da literatura. Assim, as soluções podem funcionar como parâmetros de qualidade para outros algoritmos de controle de densidade.

1.4 Estrutura do Documento

A divisão dos capítulos e um resumo de cada um são apresentados abaixo:

Capítulo 2: Fundamentos

Neste capítulo são apresentadas as características de RSSFs e qual a relação dessas características com o PCD-RSSFs. Também são mostrados os trabalhos relacionados com destaque para dois algoritmos da literatura implementados para comparação dos algoritmos propostos.

Capítulo 3: Abordagem Periódica

Este capítulo explica a Abordagem Periódica e apresenta a modelagem matemática. Assim como, explica a Relaxação Lagrangeana e a Heurística Lagrangeana utilizada para gerar soluções viáveis.

Capítulo 4: Abordagem Multiperíodo

Este capítulo explica a Abordagem Multiperíodo e apresenta a modelagem matemática, destacando as principais diferenças entre as abordagens.

Capítulo 5: Algoritmo Genético

Neste capítulo é apresentado o Algoritmo Genético Híbrido. O algoritmo utiliza conceitos das duas abordagens e uma fase de refinamento.

Capítulo 6: Resultados

Este capítulo compara os resultados das duas abordagens, Heurística Lagrangeana, Algoritmo Genético e dois algoritmos da literatura.

Capítulo 7: Considerações Finais

Por último, este capítulo apresenta as considerações finais, trabalhos publicados e os trabalhos futuros.

Capítulo 2

Fundamentos

2.1 Características das RSSFs

As RSSFs possuem diferentes características dependendo da aplicação. Por exemplo, para monitorar o nível de poluição dos oceanos é formada uma rede móvel, pois os nós sensores jogados no ambiente se movimentam. Enquanto que no monitoramento de florestas a rede formada, na maioria dos casos, é uma rede estática [Loureiro et al., 2002]. A tabela 2.1 mostra algumas características de RSSFs.

Neste trabalho as características relevantes para a resolução do problema de controle de densidade, são organização e composição da rede, onde se tem:

- Organização plana: quando a rede não possui agrupamentos.
- Organização hierárquica: quando a rede possui agrupamentos.
- Composição homogênea: quando os nós sensores são do mesmo tipo.
- Composição heterogênea: quando a rede possui nós sensores diferentes.

2.2 Controle de Densidade x Consumo de energia

Sabendo que os nós sensores possuem limitações de energia, processamento e comunicação devido ao tamanho reduzido. Dada as dificuldades de reposição de nós sensores em áreas de difícil acesso, são desejáveis o uso de métodos que otimizem o consumo de energia [Nguyen et al., 2010]. Os consumidores de energia do nó sensor são o rádio, o processador e o sensor, e o provedor de energia é a bateria, conforme ilustrado na Figura 2.1.

Característica	Classificação
Composição	Homogêneas
	Heterogêneas
Organização	Plana
	Hierárquica
Distribuição	Regular
	Irregular
Densidade	Balanceada
	Densa
	Esparsa
Controle	Aberta
	Fechada
Coleta	Periódica
	Contínua
	Reativa
	Tempo real
Disseminação	Programada
	Contínua
	Sob demanda
	Dirigida a evento
Cooperação entre os sensores	Básica
	Infra-estrutura
	Correlação

Tabela 2.1. Características das RSSFs.

O controle de densidade é um método cujo um dos objetivos é aumentar o tempo de vida da rede [Nguyen et al., 2010]. O método aproveita a alta concentração de nós sensores por área e desativa os nós sensores redundantes preservando sua energia para uso no futuro e conseqüentemente reduzindo o consumo de energia da rede por manter um número menor de nós sensores ativo por período. Neste contexto, a alta densidade de nós sensores, também utilizada com intuito de garantir o atendimento dos requisitos da rede e torná-la tolerante a falhas, pode auxiliar a estender a vida da rede [Shang & Shi, 2005, Akyildiz et al., 2002, Cheng & Yen, 2006].

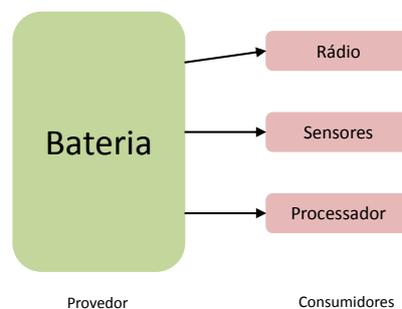


Figura 2.1. Provedor e consumidores de energia de um nó sensor [Nakamura, 2010].

2.3 Características do Problema

Nesta seção é mostrada a relação entre o problema de controle de densidade e as características de RSSFs.

2.3.1 Controle de densidade em RSSFs Homogêneas e Heterogêneas

Uma RSSFs pode ser classificada como homogênea ou heterogênea, ou seja, se a rede é formada por nós sensores do mesmo tipo ou diferentes. Segundo Loureiro et al. (2002), a classificação de uma rede como homogênea ou heterogênea pode ser quanto ao tipo, dimensão e funcionalidade do nó sensor. Baseado nisto, os autores exemplificam que uma aplicação com objetivo de obter imagens e áudio pode utilizar nós sensores de imagem e nós sensores acústicos caracterizando uma rede heterogênea por possuir nós sensores diferentes, ou todos os nós sensores serem compostos, ao mesmo tempo, por sensores de imagem e acústico caracterizando uma rede homogênea por possuir nós sensores do mesmo tipo.

Uma rede é considerada homogênea se os nós sensores são iguais, já uma rede heterogênea consiste de dois ou mais tipos de nós sensores com bateria e funcionalidade diferentes [Mhatre & Rosenberg, 2004]. Do ponto de vista de redes hierárquicas, uma rede heterogênea é composta por nós sensores com baixa capacidade e nós sensores mais robustos, que servem como líder do grupo [Wu et al., 2007].

Ainda em redes hierárquicas, Machado et al. (2010) aproveitam a alta densidade de nós sensores e estabelecem redes com duas camadas. Uma camada para ficar responsável pelo sensoriamento dos dados e outra pelo processamento. Os nós sensores responsáveis pelo processamento necessitam ser mais robustos que os da camada responsável pelo sensoriamento, formando uma rede heterogênea. Nesse contexto o problema de controle de densidade consiste em determinar, para cada camada, os nós sensores que ficarão ativos.

Embora o controle de densidade também seja aplicado em redes heterogêneas é mais comum considerarem o uso em redes homogêneas por serem mais simples [Nguyen et al., 2010].

2.3.2 Controle de densidade em RSSFs Planas e Hierárquicas

Nas redes hierárquicas os nós sensores são organizados logicamente em agrupamentos, enquanto que as redes planas não possuem agrupamentos [Aioffi & Mateus, 2007]. Baseado na ideia de que o custo de transmissão é tão alto quanto o de computação, as redes

hierárquicas tiram vantagem da organização em grupos, pois diminuem a quantidade de transmissões entre os nós sensores [Bandyopadhyay & Coyle, 2003].

As RSSFs hierárquicas são divididas em grupos que normalmente levam em consideração a vizinhança geográfica [Wu et al., 2007]. Cada grupo é composto pelo líder (*Cluster Head*) e por nós sensores. O líder do grupo é o nó sensor responsável pelo gerenciamento do grupo e por transmitir os dados coletados para o sorvedouro [Turgut et al., 2002]. Com esta configuração a rede elimina a necessidade de rotas dedicadas para o envio de dados dos nós sensores até o sorvedouro, pois o líder ficará responsável por essa comunicação.

O problema de controle de densidade em redes hierárquicas consiste em determinar, para cada grupo, quais os nós sensores serão desativados de forma a maximizar o tempo de vida da rede. Alguns fatores que influenciam nessa escolha são a distância do nó sensor para o líder, a quantidade de energia residual e o total de pontos de demanda que o nó sensor cobre e que são alcançados por outros nós sensores. No caso de RSSFs planas, o problema de controle de densidade consiste em definir quais nós sensores serão ativados considerando que todos os nós sensores são responsáveis por coletar e transmitir dados, pois necessitam de uma rota dedicada até o sorvedouro.

2.4 Trabalhos Relacionados

O PCD-RSSFs lida com três problemas: cobertura, conectividade e roteamento. Estes podem ser tratados de forma individual ou conjunta. O problema de cobertura refere-se a garantia da cobertura da área de monitoramento, e os problemas de conectividade e roteamento referem-se a garantia de conectividade entre os nós sensores ativos e o sorvedouro e a definição de uma rota entre cada nó sensor ativo e o sorvedouro.

Em Aioffi e Mateus (2007) são propostas duas abordagens utilizando sorvedouro móvel e rede hierárquica. Uma abordagem considera que a comunicação entre os nós sensores é *single-hop* e outra considera comunicação *multi-hop* com limitação de saltos. Ambas as abordagens modelam o Problema de Controle de Densidade como o problema de cobertura de conjuntos e o problema de roteamento do sorvedouro como o problema do caixeiro viajante.

Em Nakamura et al. (2004,2010) e em Menezes (2004) são propostos modelos dinâmicos de Programação Linear Inteira para o controle de densidade. A ideia é definir a topologia da rede e otimizar o consumo de energia ao mesmo tempo em que atende os requisitos da aplicação. A principal diferença entre estes trabalhos é que o primeiro considera na modelagem o gasto com a operação de recepção de pacotes.

Ambos resolvem os modelos com *software* de otimização CPLEX e com métodos exatos. Os resultados confirmam que com o escalonamento de nós sensores é possível estender o tempo de vida da rede.

Em Zang e Hou (2005) é mostrado *Optimal Geographical Density Control Algorithm* (OGDC) que é um algoritmo descentralizado e localizado [Zang & Hou, 2005], baseado em um conjunto de condições ótimas sobre as quais um conjunto de nós sensores ativos é encontrado.

Siqueira et al. (2006) propõem duas abordagens que integram roteamento e controle de densidade. Ambas utilizam o algoritmo de controle de densidade OGDC e roteamento pró-ativo em árvore. A principal diferença entre as abordagens é a forma como cada problema é integrado no algoritmo.

Neste contexto, dois algoritmos conhecidos na literatura e que são utilizados para tratar o PCD-RSSFs são o GRASP e Algoritmo Genético. Como é mostrado em Andrade et al. (2009) onde é desenvolvido o algoritmo GRASP e em Andrade et al. (2010) onde é implementado um Algoritmo Genético. Os algoritmos utilizam Abordagem Multiperíodo, que é quando a busca da solução de todos os períodos é feita simultaneamente. Isto é uma vantagem pois escolher, simultaneamente, a solução de cada período permite equilibrar o atendimento dos requisitos entre os períodos, podendo estender o tempo de vida da rede.

Outra estratégia para reduzir o consumo de energia é ajustar o raio de sensoramento dos nós sensores. Nguyen et al. (2010) formam figuras geométricas predefinidas entre o raio de sensoramento dos nós sensores, preenchendo a área de monitoramento por polígonos sem que estes se sobreponham. Para isto é necessário ajustar o raio de sensoramento dos nós sensores. Nesta estratégia deseja-se preencher a área com a menor quantidade de polígonos.

Em termos de soluções distribuídas, pode-se encontrar na literatura protocolos que lidam com o escalonamento de nós sensores. Em Ye et al. (2002) é apresentado o *Probing Environment and Adaptive Sleeping* (PEAS) que é um protocolo distribuído cujo objetivo é construir e manter o funcionamento da rede [Ye et al., 2002]. O PEAS utiliza dois algoritmos: *Probing Environment*, que define quais nós sensores serão ativados; e *Adaptive Sleeping*, que determina o tempo que o nó sensor permanecerá no modo *Sleep*.

O *Geographical Adaptive Fidelity* (GAF) proposto por Xu et al. (2001) e o *Hierarchical Geographical Adaptive Fidelity* (HGAF) proposto por Inagaki & Ishihara (2009) são descritos detalhadamente abaixo e foram utilizados para comparação dos algoritmos propostos.

2.4.1 Geographical Adaptive Fidelity

O *Geographical Adaptive Fidelity* (GAF) é um algoritmo que explora a redundância dos nós sensores para reduzir o consumo de energia. Isto é feito através da identificação dos nós sensores que são equivalentes do ponto de vista de roteamento, e desligamento dos nós sensores desnecessários [Xu et al., 2001].

Para determinar a equivalência dos nós sensores são utilizadas informações de localização e grades virtuais. Estas são utilizadas devido a complexidade de encontrar nós sensores equivalentes, levando em consideração toda a área de demanda. A área é dividida e os nós sensores ficam distribuídos em pequenas grades virtuais, compostas por duas grades adjacentes A e B, tal que todos os nós sensores em A podem se comunicar com todos os nós sensores em B e vice-versa.

O tamanho das grades é definido de acordo com o alcance do raio de comunicação R , para garantir que os nós sensores de duas grades adjacentes se comuniquem, como é ilustrado na Figura 2.2.

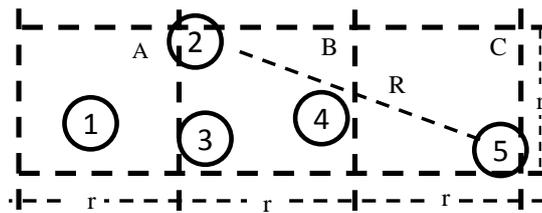


Figura 2.2. Divisão da área de monitoramento em grades virtuais [Xu et al., 2001]

Sabendo que uma grade virtual é formada por duas grades adjacentes, temos que o tamanho do lado de uma grade é:

$$r^2 + (2r)^2 \leq R^2 \quad (2.1)$$

Ou

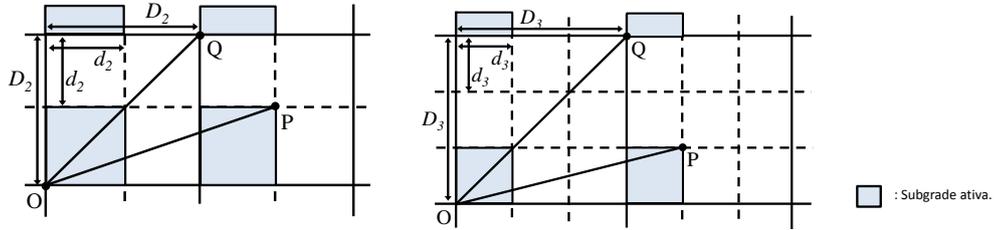
$$r \leq R/\sqrt{5} \quad (2.2)$$

Com o tamanho das grades definido é possível identificar a qual pertence cada nó sensor. Em cada grade deve ser ativado um nó sensor, fixando a quantidade de nós sensores ativos.

2.4.2 Hierarchical Geographical Adaptive Fidelity

O GAF pode ativar nós sensores desnecessários devido a grande quantidade de grades [Inagaki & Ishihara, 2009]. Por isso, Inagaki e Ishihara (2009) propõem uma variação do GAF, chamada *Hierarchical Geographical Adaptive Fidelity* (HGAF), com o intuito de diminuir o número de nós sensores ativos. O algoritmo aumenta o tamanho da grade e divide, cada grade, em N^2 subgrades. A Figura 2.3 mostra a divisão das grades para $N = 2$, que indica dividir a grade em 4 subgrades, e $N = 3$ que indica dividir a grade em 9 subgrades.

O HGAF considera que os nós sensores em grades adjacentes devem se alcançar e cada grade deve ativar um nó sensor em uma subgrade com posição equivalente à grade adjacente.



(a) Divisão da grade para $N = 2$. (b) Divisão da grade para $N = 3$.

Figura 2.3. Divisão da grade em N^2 subgrades [Inagaki & Ishihara, 2009].

Para garantir a comunicação, a distância entre os nós sensores em grades adjacentes não deve ser maior que o raio de comunicação R . Nesse caso temos:

$$(d_N)^2 + ((N + 1)d_N)^2 \leq R^2 \quad (2.3)$$

Assim, o tamanho do lado da subgrade d_N e o lado da grade D_N são:

$$d_N \leq \frac{1}{\sqrt{(N + 1)^2 + 1}} R \quad (2.4)$$

$$D_N \leq \frac{N}{\sqrt{(N + 1)^2 + 1}} R \quad (2.5)$$

Para $N \geq 3$ o tamanho da grade é:

$$\sqrt{2}D_N \leq R \quad (2.6)$$

Com o tamanho das grades definido é possível identificar a qual grade e subgrade pertence cada nó sensor. Para cada grade é definida uma subgrade, com posição equivalente à subgrade da grade adjacente, onde deve ser ativado um nó sensor, por isso a quantidade de nós sensores ativos é fixa.

2.5 Considerações Finais

Este capítulo apresentou as características das RSSFs e quais destas características foram consideradas no PCD-RSSF explorado neste trabalho. Também é destacada a relação entre o PCD-RSSF e o consumo de energia em uma rede de sensores e como o problema é abordado em cenários diferentes. O capítulo ainda lista os trabalhos relacionados com destaque para os Algoritmos GAF e HGAF que foram utilizados nos testes. O capítulo seguinte apresenta a Abordagem Periódica para o PCD-RSSFs e a modelagem matemática proposta para este caso.

Capítulo 3

Abordagem Periódica

Neste capítulo o Problema de Controle de Densidade em Redes de Sensores sem Fio (PCD-RSSFs) é tratado com a Abordagem Periódica. A Abordagem Periódica consiste em definir para um determinado período de tempo qual a melhor solução para o PCD-RSSFs e repetir o processo periodicamente, dada as condições atuais da rede. Entende-se por condições atuais da rede o pré-processamento dos dados referente ao conjunto de nós sensores disponíveis (nós sensores com energia residual) e o conjunto de pontos de demanda ainda alcançados por nós sensores disponíveis.

A Abordagem Periódica não tem visão global dos períodos, pois para cada intervalo de tempo é escolhida a melhor solução, assim diz-se que a cada período a abordagem resolve o problema estático. Essa característica prioriza, sempre que possível, a garantia máxima da cobertura da área de monitoramento a cada período. Assim, a tendência é que nos primeiros períodos tenhamos o menor consumo de energia possível e que as falhas na cobertura ocorram nos últimos períodos.

O PCD-RSSFs proposto neste trabalho foi modelado com Programação Linear Inteira. O modelo foi baseado em duas modelagens encontradas na literatura e resolvido pelo *software* de otimização CPLEX [Documentation, 2012]. A principal diferença do modelo proposto e dos modelos da literatura é a expansão da restrição de cobertura que indica que um nó sensor inativo para sensoriamento não deve atender um ponto de demanda.

Também é proposta a Relaxação Lagrangeana que é um método exato cuja restrições “difíceis” são relaxadas com o intuito de tornar o problema mais simples de ser resolvido e gerar limites. Para isto utiliza-se uma Heurística Lagrangeana que gera soluções para o Modelo Matemático com as restrições relaxadas.

3.1 Definição do problema

A ideia do controle de densidade é determinar quando e quais nós sensores devem ficar ativos e quais devem ficar no modo de economia de energia [Shang & Shi, 2005]. Em outras palavras, o PCD-RSSFs consiste em determinar um subconjunto de nós sensores, que atendam os requisitos da rede, para ficarem ativos enquanto os demais serão desativados.

Neste trabalho os requisitos são garantir a cobertura e conectividade, e o recurso, a ser otimizado, é a energia. Pode-se definir, formalmente, o PCD-RSSFs como:

Dada uma área de monitoramento A , um conjunto de nós sensores S , um conjunto de sorvedouros M , um conjunto de pontos de demanda D , o problema de controle de densidade consiste em garantir, se possível, para cada ponto de demanda $d \in D$ na área A que pelo menos um nó sensor $s \in S$ o cubra, que exista uma rota entre cada nó sensor ativo $s \in S$ e o sorvedouro $m \in M$ e que o subconjunto de nós sensores ativos minimize o consumo de energia da rede [Nakamura, 2010].

3.2 Formulação Matemática

O problema como definido anteriormente tem uma característica estática, pois gera a melhor solução em um dado instante de tempo. Para cada solução escolhida os nós sensores disponíveis para o próximo período e os pontos de demanda são atualizados. Ou seja, os nós sensores que não podem mais ficar ativos saem do conjunto de nós sensores e os pontos de demanda que nenhum nó sensor alcança são retirados do conjunto de pontos de demanda e ao final são computados com uma penalidade de não cobertura. Para definir quais nós sensores ainda podem ser usados, é utilizado um parâmetro “ n ” que indica a quantidade de períodos que o nó sensor pode ficar ativo.

A área de monitoramento é discretizada em pontos de demanda, pois este conceito permite avaliar e quantificar a cobertura em um espaço discreto. O modelo considera que os nós sensores possuem um número de identificação único e conhecem sua localização. A área de cobertura de um nó sensor é um círculo de raio R , onde R é o raio de sensoriamento. Assim, se a distância entre um ponto de demanda e um nó sensor é menor ou igual a R então o nó sensor cobre o ponto de demanda. Para quantificar o consumo de energia dos nós sensores, é definido que a aplicação requer sensoriamento contínuo e disseminação periódica.

A Abordagem Periódica proposta foi baseada na formulação do modelo matemático de Menezes (2004) e Nakamura (2010). A principal diferença, entre a modelagem proposta e as modelagens da literatura, está na restrição de cobertura que indica que

um nó sensor inativo não deve atender um ponto de demanda. Esta restrição foi expandida, pois desta forma observou-se que é possível gerar limites mais justos no método exato proposto.

Os parâmetros utilizados na formulação são:

S conjunto de nós sensores.

D conjunto de pontos de demanda.

M conjunto de nós sensores que são sorvedouros.

A^s conjunto de arcos que conectam sensores com outros sensores.

A^m conjunto de arcos que conectam sensores com sorvedouros.

I^j conjunto de arcos (i, j) que entram em um nó sensor $j \in S$.

O^i conjunto de arcos (i, j) que saem de um nó sensor $i \in S$.

C_{lj} Matriz de conectividade que possui valor 1 se o nó sensor l alcança o ponto de demanda j e 0 caso contrário.

EA_i energia de ativação do nó sensor $i \in S$.

EM_i energia de manutenção do nó sensor $i \in S$.

ET_{ij} energia de transmissão entre os nós sensores i e j , $\{i, j\} \in \{A^s \cup A^m\}$.

EH Penalidade de não cobertura.

Fazendo $d(l, j)$ a distância entre o nó sensor l e o ponto de demanda j . A matriz de conectividade C_{lj} é composta pelos arcos (l, j) onde $d(l, j)$ é menor ou igual ao raio de sensoriamento do nó sensor l . Fazendo $d(i, j)$ a distância entre os nós sensores i e j . Os conjuntos A^s e A^m são compostos pelos arcos cuja $d(i, j)$ é menor ou igual ao raio de comunicação do nó sensor i . Para quantificar a energia de transmissão é utilizada a distância euclidiana entre dois nós sensores, se a distância for menor ou igual ao raio de comunicação então os dois nós sensores se alcançam.

As variáveis do modelos são:

x_{ij} variáveis que possuem valor 1 se o nó sensor i está cobrindo o ponto de demanda j e 0 caso contrário.

z_{lij} variáveis que possuem valor 1 se o arco (i, j) está no caminho entre o nó sensor l e o nó sorvedouro e 0 caso contrário.

y_i variável binária que recebe 1 se o nó i está ativo e 0 caso contrário.

h_j variáveis que possuem valor 1 se o ponto de demanda j não está coberto e 0 caso contrário.

A formulação proposta é apresentada abaixo. A função objetivo (3.1) minimiza o consumo de energia da rede. A solução ótima para a formulação matemática indica o conjunto de nós sensores que garantem a melhor cobertura possível e a conectividade dos nós sensores, a um menor custo de energia. O segundo termo da função objetivo penaliza pontos de demanda não cobertos. Este somatório é introduzido na função objetivo para tornar o PCD-RSSFs mais flexível permitindo falhas na cobertura.

$$\begin{aligned} \text{Min} \quad & \sum_{l \in S} (EA_l y_l + EM_l y_l + \sum_{(i,j) \in A^s \cup A^m} ET_{ij} z_{ij}) \\ & + \sum_{j \in D} EH h_j \end{aligned} \quad (3.1)$$

As restrições (3.2), (3.3), e (3.4) tratam o problema de cobertura. As restrições (3.2) garantem que pelo menos um nó sensor deve cobrir cada ponto de demanda, a variável h_j é incluída na restrição possibilitando a não cobertura de um ponto de demanda. As restrições (3.3) garantem que um nó sensor inativo para sensoriamento não deve atender um ponto de demanda. As restrições (3.4) indicam os limites para as variáveis x e h .

$$\sum_{l \in S} (x_{lj} C_{lj}) + h_j \geq 1, \forall j \in D \quad (3.2)$$

$$x_{lj} C_{lj} \leq y_l, \forall l \in S, \forall j \in D \quad (3.3)$$

$$0 \leq x, h \leq 1 \quad (3.4)$$

As restrições (3.5), (3.6), (3.7) e (3.8) estão relacionadas ao problema de conectividade. As restrições (3.5) e (3.6) garantem a conservação de fluxo entre cada sensor $l \in S$ ativo e o nó sorvedouro m e as restrições (3.7) e (3.8) garantem que o fluxo só é possível entre os nós sensores ativos.

$$\begin{aligned} \sum_{(i,j) \in I^j(A^s)} z_{ij} - \sum_{(j,k) \in O^j(A^s \cup A^m)} z_{jk} = 0, \\ \forall j \in (S - \{l\}), \forall l \in S \end{aligned} \quad (3.5)$$

$$\begin{aligned} \sum_{(i,j) \in I^j(A^s)} z_{ij} - \sum_{(j,k) \in O^j(A^s \cup A^m)} z_{jk} = -y_l, \\ \forall j = l, \forall l \in S \end{aligned} \quad (3.6)$$

$$\sum_{j \in SUM} z_{lij} \leq |S|y_i, \forall l \in S, \forall i \in S \quad (3.7)$$

$$\sum_{i \in S} z_{lij} \leq |S|y_j, \forall l \in S, \forall j \in S \quad (3.8)$$

As restrições (3.9) garantem a quantidade mínima de nós sensores que devem ficar ativos. Estas restrições são inclusas com o objetivo de melhorar a garantia de cobertura. É calculada pela formula representada na restrição (3.9) onde A é a dimensão da área de monitoramento e r^2 é o raio de sensoriamento.

$$\sum_{l \in S} y_l \geq A/\pi r^2 \quad (3.9)$$

As restrições (3.10) definem as variáveis y e z como booleanas.

$$y, z \in \{0, 1\} \quad (3.10)$$

A principal diferença deste modelo para o proposto em Nakamura (2010) é a utilização do parâmetro “n” para indicar se um nó sensor ainda pode ser ativado. Para isto é definido um valor inteiro para “n” e este indica a quantidade de períodos que um nó sensor pode ficar ativo, assim se um nó sensor já ficou ativo por “n” períodos então este já não pode ser utilizado. Esta informação é processada antes de cada período na atualização dos nós sensores disponíveis estando implícita na modelagem. Com a utilização do parâmetro “n” o modelo é simplificado e ainda fornece soluções válidas para o PCD-RSSFs.

Em comparação com o modelo proposto em Menezes (2004) a principal diferença ocorre nas restrições 3.3 onde a mesma é expandida, tornando as restrições mais justas. Os testes feitos mostraram que, para a Relaxação Lagrangeana proposta, são gerados limites inferiores melhores.

3.3 Modelo Periódico Relaxado

3.3.1 Relaxação Lagrangeana

O método de Relaxação Lagrangeana é utilizado para resolver problemas de otimização combinatória [Maculan & Fampa, 2006]. A ideia do método é escolher um conjunto de restrições para serem relaxadas e adicioná-las à função objetivo. A relaxação destas restrições torna o problema mais “fácil” de ser resolvido e gera limites para o problema original [Fisher, 2004]. Para cada restrição relaxada é associado um multiplicador de

lagrange cuja função é penalizar o não atendimento desta restrição. Para problemas de minimização a Relaxação Lagrangeana fornece limites inferiores e para problemas de maximização fornece limites superiores.

Dois aspectos devem ser levados em consideração para obtenção de bons limites. Um é em relação a quais restrições escolher e outro em como gerar os multiplicadores de lagrange. Como já mencionado, as restrições escolhidas devem ser as que facilitem a resolução do problema. O problema de gerar os multiplicadores de lagrange é chamado de Lagrangeano Dual. Para resolvê-lo existem alguns métodos como, por exemplo, o subgradiente [Held et al., 1974], geração de colunas [Wolf, 1960], plano de corte [Cheney & Goldstein, 1959] e centros analíticos [Goffin & Vial, 2005]. Neste trabalho é utilizado o método subgradiente.

3.3.2 Problema Lagrangeano

O PCD-RSSFs é composto pelos subproblemas: cobertura, conectividade e roteamento. Sabe-se que o problema de cobertura é NP-difícil e não possui algoritmo ótimo que o resolva em tempo polinomial [Karp, 1972]. Por este motivo e por ser mais flexível foi escolhido relaxar as restrições que permitem falha na cobertura. Depois de vários testes, também, foi escolhido relaxar restrições que envolvem conectividade. As restrições relaxadas foram 3.3, 3.7 e 3.8. Para as restrições relaxadas foram aplicados os seguintes multiplicadores de lagrange:

$$\alpha_j \geq 0, \forall l \in S, \forall j \in D \quad (3.11)$$

$$\beta_{li} \geq 0, \forall l \in S, \forall i \in S \quad (3.12)$$

$$\gamma_{lj} \geq 0, \forall l \in S, \forall j \in S \quad (3.13)$$

Desta forma a função objetivo do modelo relaxado, chamado de Problema Lagrangeano, é representado como:

$$\begin{aligned} Z_{RL} = Min & \sum_{l \in S} (EA_l y_l + EM_l y_l + \sum_{(i,j) \in A^s \cup A^m} ET_{ij} z_{ij}) \\ & + \sum_{l \in S} \sum_{j \in D} (x_{lj} C_{lj} \alpha_j - y_l \alpha_j) \\ & + \sum_{l \in S} \sum_{i \in S} \sum_{j \in SUM} (z_{lij} \beta_{li} - |S| y_i \beta_{li}) \\ & + \sum_{l \in S} \sum_{j \in S} \sum_{i \in S} (z_{lij} \gamma_{lj} - |S| y_j \gamma_{lj}) \end{aligned}$$

$$+ \sum_{j \in D} EHh_j \quad (3.14)$$

Sujeito às restrições (3.2), (3.4), (3.5), (3.6), (3.9) e (3.10).

Reordenando os índices e agrupando as variáveis temos:

$$\begin{aligned} Z_{RL} = & \text{Min} \sum_{l \in S} [EA_l y_l + EM_l y_l + \sum_{(i,j) \in A^s \cup A^m} ET_{ij} z_{lij}] \\ & + \sum_{i \in S} \sum_{j \in S \cup M} z_{lij} \beta_{li} + \sum_{j \in S} \sum_{i \in S} z_{lij} \gamma_{lj} \\ & - |S| \sum_{i \in S} (\beta_{li} + \gamma_{li}) y_i - y_l \sum_{j \in D} \alpha_{lj} \\ & + \sum_{j \in D} x_{lj} C_{lj} \alpha_{lj} \\ & + \sum_{j \in D} EHh_j \end{aligned} \quad (3.15)$$

Sujeito às restrições (3.2), (3.4), (3.5), (3.6), (3.9) e (3.10).

3.3.3 Limite Inferior

O Problema Lagrangeano pode ser dividido em duas partes. Uma referente ao custo das variáveis y (Cy) que engloba as variáveis z , e outro referente ao custo das variáveis x (Cx). Assim, a função objetivo pode ser reescrita como:

$$Z_{RL} = \text{Min} \sum_{l \in S} [Cy(l) + Cx(l)]$$

Cx é o custo referente a cobertura dos pontos de demanda alcançados por cada nó sensor e a penalidade de não cobertura de pontos de demanda.

$$Cx(l) = \text{Min} \left\{ \sum_{j \in D} x_{lj} C_{lj} \alpha_{lj} + \sum_{j \in D} EHh_j \right\}$$

Sujeito a (3.2) e (3.4).

O algoritmo utilizado para resolver este subproblema é similar ao proposto em Nakamura (2010). O algoritmo escolhe para cada ponto de demanda j o nó sensor de menor custo. Isto significa escolher o nó sensor com menor valor de α_{lj} desde que o nó sensor l alcance o ponto de demanda j . É interessante notar que um nó sensor com α_{lj} maior que a penalidade de cobertura (EH) não traz benefícios ao ser ativado e nesse caso é melhor deixar o ponto de demanda descoberto. Para cada ponto de demanda descoberto é aplicada a penalidade (EH).

Cy é o custo para ativar um nó sensor y_l e é utilizado para a escolha de quais nós sensores devem ficar ativos. Refere-se ao custo gasto com energia de ativação, energia de manutenção e energia de transmissão.

$$Cy(l) = \text{Min}\{EAly_l + EMly_l + \sum_{(i,j) \in A^s \cup A^m} ET_{ij}z_{lij} \\ + \sum_{i \in S} \sum_{j \in SUM} z_{lij}\beta_{li} + \sum_{j \in S} \sum_{i \in S} z_{lij}\gamma_{lj} \\ - |S| \sum_{i \in S} (\beta_{li} + \gamma_{li})y_i - y_l \sum_{j \in D} \alpha_{lj}\}$$

Sujeito a (3.5), (3.6), (3.9) e (3.10).

O subproblema Cy pode ser separado em três problemas. Um é resolvido obtendo o caminho mínimo de cada nó sensor (Cam) e os outros dois são resolvidos por inspeção (BGy e Ay). O Algoritmo 1 mostra como é calculado o custo de cada nó sensor.

Algoritmo 1: Função Cy que calcula o custo de cada nó sensor.

Entrada: S

- 1** para cada $l \in S$ faça
 - 2** | $CustoNo_l = Cam(l) - BGy(l) - Ay(l);$
 - 3** fim para cada
-

O subproblema Cam é representado pela seguinte formulação:

$$Cam(l) = \text{Min}\{ \sum_{(i,j) \in A^s \cup A^m} ET_{ij}z_{lij} + \sum_{i \in S} \sum_{j \in SUM} z_{lij}\beta_{li} + \sum_{j \in S} \sum_{i \in S} z_{lij}\gamma_{lj} \}$$

Sujeito a (3.5), (3.6) e (3.10).

Para resolvê-lo é utilizado um algoritmo de caminho mínimo, onde para cada aresta (i, j) pertencente ao caminho de l até o sorvedouro é aplicado os valores correspondentes a energia de transmissão ET_{ij} e aos multiplicadores β_{li} e γ_{lj} , como ilustrado na Figura 3.1.

O segundo subproblema BGy é representado pela seguinte formulação:

$$BGy(l) = \text{Min}\{|S| \sum_{i \in S} (\beta_{li} + \gamma_{li})y_i\}$$

Sujeito a (3.10).

Esse subproblema é resolvido por inspeção e demonstrado pelo Algoritmo 2. O somatório é referente aos benefícios que os valores β_{li} e γ_{li} de um nó sensor i ativo trazem para o nó sensor l . Porém como se deseja saber qual o benefício que um nó

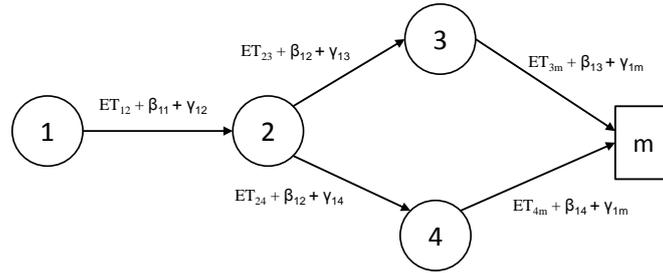


Figura 3.1. Grafo com nós sensores e arestas pertencentes ao caminho do nó 1 ao sorvedouro m.

sensor l irá trazer se for ativo, então é calculada a influência que o nó sensor l terá nos valores dos demais nós sensores i , se for ativado.

Algoritmo 2: Resolve o subproblema BG_y .

Entrada: l

Saída: $Soma_l$

- 1 $Soma_l \leftarrow 0$;
 - 2 **para cada** $i \in S$ **faça**
 - 3 | $Soma_l \leftarrow Soma_l + [|S|(\beta_{il} + \gamma_{il})]$;
 - 4 **fim para cada**
 - 5 **retorna** $Soma_l$
-

O subproblema Ay também é resolvido por inspeção e é representado pela seguinte formulação:

$$Ay(l) = Min\{y_l \sum_{j \in D} \alpha_{lj}\}$$

Sujeito a (3.10).

O algoritmo consiste em somar todos α_{lj} de um nó sensor l . Vale ressaltar que como se deseja saber o benefício de se ativar o nó sensor l então é considerado que $y_l = 1$.

Com o valor de cada subproblema de C_l é possível calcular o custo de ativação de cada nó sensor l . Com o custo de todos os nós sensores é formada uma lista. Desta lista são ativados os nós sensores com menor custo até que a restrição (3.9) seja atendida. Após alcançar a quantidade mínima de nós sensores, são ativados os nós sensores que possuem custo negativo. Ao final tem-se um conjunto de nós sensores ativos.

3.3.4 Lagrangeano Dual

A Relaxação Lagrangeana gera limites inferiores para problemas de minimização, então quanto maior for a solução do Problema Lagrangeano melhor será o limite inferior. O problema de gerar multiplicadores de lagrange que encontre valores maiores para o limite inferior é chamado de Lagrangeano Dual e é representado como:

$$Z_{LD} = Max Z_{RL}$$

O método utilizado para geração dos multiplicadores de lagrange é o subgradiente. Esse método foi escolhido por ser simples de implementar e barato computacionalmente. Consiste de um processo iterativo onde a cada iteração um conjunto novo de multiplicadores de lagrange é gerado, assim, na n-iteração temos:

$$\alpha_{lj}^{n+1} = Max(0, \alpha_{lj}^n + p^n g_{\alpha_{lj}^n}^n(x^n, y^n)), \forall l \in S, \forall j \in D \quad (3.16)$$

$$\beta_{li}^{n+1} = Max(0, \beta_{li}^n + p^n g_{\beta_{li}^n}^n(z^n, y^n), \forall l \in S, \forall i \in S \quad (3.17)$$

$$\gamma_{lj}^{n+1} = Max(0, \gamma_{lj}^n + p^n g_{\gamma_{lj}^n}^n(z^n, y^n), \forall l \in S, \forall j \in S \quad (3.18)$$

Onde $g_{\alpha_{lj}^n}^n$, $g_{\beta_{li}^n}^n$ e $g_{\gamma_{lj}^n}^n$ são os componentes do vetor gradiente $\delta = (g_{\alpha_{lj}^n}^n, g_{\beta_{li}^n}^n, g_{\gamma_{lj}^n}^n)$ e indica a direção de subida. Cada componente é definido como segue:

$$g_{\alpha_{lj}^n}^n = \sum_{l \in S} [\sum_{j \in D} (x_{lj} C_{lj}) - y_l] \quad (3.19)$$

$$g_{\beta_{li}^n}^n = \sum_{l \in S} \sum_{i \in S} [\sum_{j \in SUM} (z_{lij}) - |S| y_i] \quad (3.20)$$

$$g_{\gamma_{lj}^n}^n = \sum_{l \in S} \sum_{j \in S} [\sum_{i \in S} (z_{lij}) - |S| y_j] \quad (3.21)$$

O p^n é o tamanho do passo e é definido como:

$$p^n = \theta \frac{1.05 * LS - Z_{RL}(\alpha^n, \beta^n, \gamma^n)}{\|\delta^n\|^2} \quad (3.22)$$

Onde θ é um valor definido entre $0 < \theta \leq 2$. Inicialmente $\theta = 2$ e caso nas últimas n iterações o valor do limite inferior não obtiver melhora então θ deve ser dividido por 2 [Maculan & Fampa, 2006]. LS é o melhor Limite Superior, para o problema original, encontrado até o momento e esse é multiplicado por 1.05 para acelerar o processo de convergência. Z_{RL} é o valor da função objetivo do modelo relaxado e representa a solução com os multiplicadores α^n , β^n e γ^n . E por último temos a norma euclidiana δ^n do vetor gradiente. O Algoritmo 3 apresenta o funcionamento básico do método

subgradiente.

Algoritmo 3: Método Subgradiente.

Saída: Z_{LS}

```

1   $\pi \leftarrow 2$ ;
2   $n \leftarrow 0$ ;
3   $N \leftarrow 0$ ;
4   $Z_{LS} \leftarrow +\infty$ ;
5   $Z_{LI} \leftarrow -\infty$ ;
6  para cada  $l \in S$  faça
7      para cada  $j \in D$  faça
8           $\alpha_{lj} \leftarrow 0$ ;
9      fim para cada
10     para cada  $i \in S$  faça
11          $\beta_{li} \leftarrow 0$ ;
12          $\gamma_{li} \leftarrow 0$ ;
13     fim para cada
14 fim para cada
15 enquanto  $n < n_{max}$  faça
16      $n \leftarrow n + 1$ ;
17      $Z_{RL}(\alpha_{lj}, \beta_{li}, \gamma_{li})$ ;
18     se  $Z_{RL} > Z_{LI}$  então
19          $Z_{LI} \leftarrow Z_{RL}$ ;
20          $\text{Novo}Z_{LS} \leftarrow \text{HeuristicaLagrangeana}(x^n, y^n, z^n)$ ;
21         se  $\text{Novo}Z_{LS} < Z_{LS}$  então
22              $Z_{LS} \leftarrow \text{Novo}Z_{LS}$ ;
23              $\text{CalcularGAPdualidade}()$ ;
24             se  $\text{GAP} = 0$  então
25                 Achou Ótimo;
26                 Concluir Procedimento;
27             fim se
28         fim se
29      $N \leftarrow 0$ ;
30 fim se
31 senão
32      $N \leftarrow N + 1$ ;
33     se  $N = N_{max}$  então
34          $N \leftarrow 0$ ;
35          $\pi \leftarrow \pi/2$ ;
36         se  $\pi \leq 1 \times 10^{-3}$  então
37             Concluir Procedimento;
38         fim se
39     fim se
40 fim se
41  $n \leftarrow n + 1$ ;
42  $\text{CalcularVetorSubGradiente}()$ ;
43  $\text{CalcularValorPasso}()$ ;
44  $\text{AtualizarMultiplicadoresLagrange}()$ ;
45 fim enqto
46 retorna  $Z_{LS}$ 

```

3.3.5 Limite Superior

A Relaxação Lagrangeana é um método exato onde são relaxadas uma ou mais restrições do Modelo Matemático. Para encontrar soluções para o Modelo Matemático relaxado é utilizada uma heurística. Esta heurística pode partir da solução gerada no limite inferior ou não. No primeiro caso a heurística é conhecida na literatura como Heurística Lagrangeana. Neste trabalho utilizamos como entrada a solução gerada no limite inferior e ao viabilizarmos as restrições relaxadas encontramos uma solução viável ou o limite superior para o problema.

A Heurística Lagrangeana proposta é dividida em três partes. A primeira verifica quais nós estão disponíveis para ativação, a segunda viabiliza as restrições de cobertura e a terceira viabiliza as restrições de conectividade.

A primeira função identifica os nós sensores disponíveis através da verificação de quais nós sensores possuem conectividade até o sorvedouro, incluindo os nós sensores ativos no limite inferior e os que não estão ativos e ainda podem ser usados. Este processo é explicado no Algoritmo 4.

Algoritmo 4: Verifica nós sensores disponíveis para ativação.

Saída: S_{disp}

- 1 $S^a \leftarrow$ Conjunto de nós ativos no LI;
- 2 $S \leftarrow$ Conjunto de nós sensores;
- 3 $S_{disp} \leftarrow \emptyset$;
- 4 **para cada** $l \in S^a$ **faça**
- 5 $Caminho_l \leftarrow VerificaConectividade(l)$;
- 6 **se** $Caminho_l = \emptyset$ **então**
- 7 $y_l \leftarrow 0$;
- 8 **fim se**
- 9 **senão**
- 10 $S_{disp} \leftarrow S_{disp} + \{l\}$;
- 11 **fim se**
- 12 **fim para cada**
- 13 $S_{dispAux} \leftarrow S - S^a$;
- 14 **para cada** $l \in S_{dispAux}$ **faça**
- 15 $Caminho_l \leftarrow VerificaConectividade(l)$;
- 16 **se** $Caminho_l \neq \emptyset$ **então**
- 17 $S_{disp} \leftarrow S_{disp} + \{l\}$;
- 18 **fim se**
- 19 **fim para cada**
- 20 **retorna** S_{disp}

A ideia do algoritmo é verificar para cada nó ativo no limite inferior se o mesmo

possui um caminho até o sorvedouro. Este caminho pode conter nós sensores que não estão ativos, mas que ainda podem ser ativados. Caso um nó não tenha caminho até o sorvedouro, ele é desativado. Para os demais nós sensores, não ativados no limite inferior, é verificado se estes possuem um caminho até o sorvedouro e se ainda podem ser utilizados. Ao final teremos um conjunto de nós sensores disponíveis que podem ser escolhidos para garantir a cobertura.

O Algoritmo 5 ilustra o procedimento de ajuste da cobertura. O algoritmo parte da solução gerada no limite inferior e o primeiro passo é verificar quais pontos de demanda ainda não foram cobertos. Em seguida, para os nós sensores desativados é verificado quantos pontos de demanda descobertos cada nó cobre. O nó que mais cobre pontos de demanda é o ativado e o conjunto de pontos de demanda descobertos é atualizado. Esse processo é repetido até que todos os pontos de demanda sejam cobertos ou não existam mais nós sensores disponíveis para serem ativados.

Algoritmo 5: Garantir Cobertura

Entrada: S^a //Conjunto de nós sensores ativos no LI.

Saída: S^a

```

1 Descoberto  $\leftarrow$  Conjunto de Pontos de demanda descoberto;
2  $S^d \leftarrow$  Conjunto de nós sensores desativados;
3  $S \leftarrow$  Conjunto de nós sensores;
4 enquanto Descoberto  $\neq \emptyset$  faça
5   para cada  $l \in S$  faça
6      $C_l = VerificaCobertura(l, Descoberto)$ ;
7   fim para cada
8    $MelhorNo = Max_{l \in S}(C_l)$ ;
9    $y_{MelhorNo} \leftarrow 1$ ;
10   $S^a \leftarrow S^a + \{MelhorNo\}$ ;
11  Descoberto  $\leftarrow$  AtualizaConjuntoPontosDescoberto();
12   $S^d \leftarrow S^d - \{MelhorNo\}$ ;
13  se  $S^d = \emptyset$  então
14    Concluir Procedimento;
15  fim se
16 fim enqto
17 retorna  $S^a$ 

```

A terceira parte da Heurística Lagrangeana viabiliza a conectividade. O algoritmo consiste em dividir cada nó sensor i em dois nós sensores i e i' onde a aresta (i, i') é a energia de ativação. Para os nós sensores já ativos a aresta (i, i') possui peso 0. A Figura 3.2 ilustra um grafo com os nós sensores duplicados. Com o novo grafo formado é calculado o caminho mínimo e com a solução do caminho mínimo são ativados os nós

sensores pertencentes ao caminho de cada nó sensor l até sorvedouro. O Algoritmo 6 mostra o processo de garantir a conectividade.

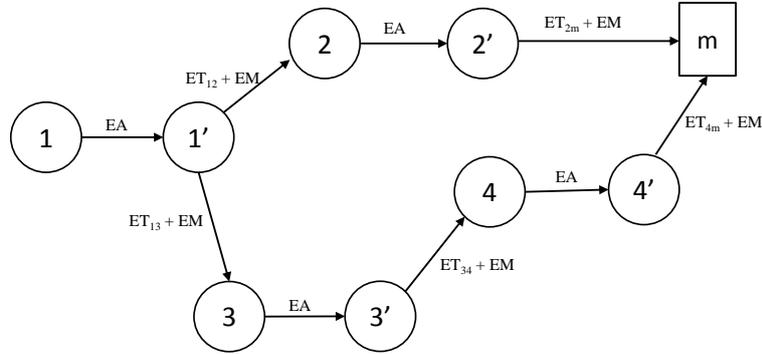


Figura 3.2. Grafo com nós sensores duplicados.

Algoritmo 6: Ativar Caminho

Entrada: S^a

Saída: S^a

- 1 para cada $l \in S^a$ faça
 - 2 Gera grafo com nós duplicados;
 - 3 $CalculaCaminhoMinimo(l)$;
 - 4 para cada $i \in Caminho_l$ faça
 - 5 $y_i \leftarrow 1$;
 - 6 $S^a \leftarrow S^a + \{i\}$;
 - 7 fim para cada
 - 8 fim para cada
 - 9 retorna S^a
-

3.4 Considerações Finais

Este capítulo apresentou a Abordagem Periódica para o PCD-RSSFs que consiste em escolher, para cada período, a melhor solução e repetir este procedimento periodicamente. O capítulo apresentou uma modelagem matemática de Programação Linear Inteira para o PCD-RSSFs e uma proposta de Relaxação Lagrangeana para obtenção

de limites inferiores e uma Heurística Lagrangeana para obtenção de limites superiores. O próximo capítulo apresenta a Abordagem Multiperíodo para o PCD-RSSFs que ao contrário da Abordagem Periódica possui uma visão global dos períodos.

Capítulo 4

Abordagem Multiperíodo

Outra abordagem utilizada para tratar o Problema de Controle de Densidade em Redes de Sensores Sem Fios (PCD-RSSFs) é a Abordagem Multiperíodo. A Abordagem Multiperíodo define um tempo esperado de vida da rede e o divide em períodos, que podem ou não ter a mesma duração. A solução para cada período é escolhida tendo visão global da rede e dos períodos [Nakamura, 2010]. Isso permite que em alguns períodos ocorram pequenas falhas na cobertura para que nos períodos seguintes não se tenha grandes regiões descobertas.

A Figura 4.1 exemplifica o que pode acontecer nas Abordagens Periódica e Multiperíodo. A Abordagem Periódica escolhe a melhor solução a cada período. A Abordagem Multiperíodo escolhe a solução de cada período levando em conta todos os outros períodos, assim, no período 1 ocorre uma pequena falha na cobertura para no período n não ter uma grande região descoberta e desconexa.

Assim como a Abordagem Periódica, a Multiperíodo foi modelada com Programação Linear Inteira e resolvida por um *software* de otimização.

4.1 Formulação Matemática

A Abordagem Multiperíodo escolhe a melhor solução tendo visão global da rede e dos períodos. O conjunto de nós sensores disponíveis para cada período é definido por restrições inclusas no modelo e os pontos de demanda não cobertos são adicionados à função objetivo com uma penalidade (EH) de não cobertura.

Baseada na formulação do Modelo Matemático Periódico foi proposto um modelo Multiperíodo com o acréscimo de uma restrição que indica a quantidade máxima de períodos que um nó sensor pode ficar ativo, duas restrições que indicam quando a energia de ativação deve ser contabilizada na função objetivo e um índice t para modelar

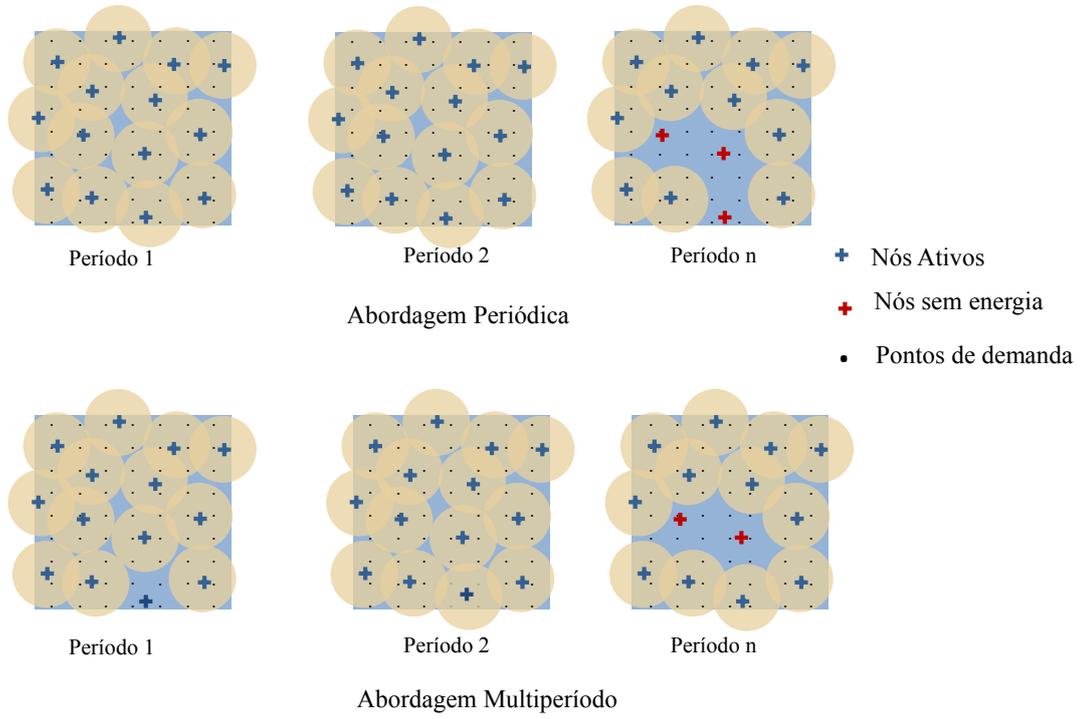


Figura 4.1. Comparação entre as duas abordagens

os períodos. Assim o modelo matemático é definido como:

Os parâmetros utilizados na formulação são:

S conjunto de nós sensores.

D conjunto de pontos de demanda.

M conjunto de nós sensores que são sorvedouros.

T conjunto de períodos.

A^s conjunto de arcos que conectam sensores com outros sensores.

A^m conjunto de arcos que conectam sensores com sorvedouros.

I^j conjunto de arcos (i, j) que entram em um nó sensor $j \in S$.

O^i conjunto de arcos (i, j) que saem de um nó sensor $i \in S$.

C_{lj} Matriz de conectividade que possui valor 1 se o nó sensor l alcança o ponto de demanda j e 0 caso contrário.

EA_i energia de ativação do nó sensor $i \in S$.

EM_i^t energia de manutenção do nó sensor $i \in S$.

ET_{ij} energia de transmissão ente os nós sensores i e j , $\{i, j\} \in \{A^s \cup A^m\}$.

EH Penalidade de não cobertura.

n Indica a quantidade de períodos que um nó sensor pode ficar ativo.

As variáveis do modelos são:

x_{ij}^t variáveis que possuem valor 1 se o nó sensor i está cobrindo o ponto de demanda j no período t , e 0 caso contrário.

z_{lij}^t variáveis que possuem valor 1 se o arco (i, j) está no caminho entre o nó sensor l e um nó sorvedouro no período t , e 0 caso contrário.

w_l^t variável que recebe valor 1 se o nó l é ativado no período t , e 0 caso contrário.

y_i^t variável binária que recebe 1 se o nó i está ativo no período t , e 0 caso contrário.

h_j^t variáveis que possuem valor 1 se o ponto de demanda j não está coberto no período t , e 0 caso contrário.

A formulação proposta é apresentada abaixo. A função objetivo (4.1) minimiza o consumo de energia da rede. A solução ótima para a formulação matemática indica o conjunto de nós sensores que garantem a melhor cobertura possível e a conectividade do nós sensores, a um menor custo de energia. O segundo termo da função objetivo penaliza pontos de demanda não cobertos.

$$\begin{aligned} \text{Min} \quad & \sum_{l \in S} \sum_{t \in T} (EA_l w_l^t + EM_l^t y_l^t + \sum_{(i,j) \in A^s \cup A^m} ET_{ij} z_{lij}^t) \\ & + \sum_{j \in D} \sum_{t \in T} EH h_j^t \end{aligned} \quad (4.1)$$

As restrições (4.2), (4.3), e (4.4) tratam o problema de cobertura. As restrições (4.2) garantem que pelo menos um nó sensor deve cobrir cada ponto de demanda, a variável h_j^t é incluída na restrição possibilitando a não cobertura de um ponto de demanda. As restrições (4.3) garantem que um nó sensor inativo para sensoriamento não deve atender um ponto de demanda. As restrições (4.4) indicam os limites para as variáveis x e h .

$$\sum_{l \in S} (x_{lj}^t C_{lj}) + h_j^t \geq 1, \forall j \in D, \forall t \in T \quad (4.2)$$

$$x_{lj}^t C_{lj} \leq y_l^t, \forall l \in S, \forall j \in D, \forall t \in T \quad (4.3)$$

$$0 \leq x, h \leq 1 \quad (4.4)$$

As restrições (4.5), (4.6), (4.7) e (4.8) estão relacionadas ao problema de conectividade. As restrições (4.5) e (4.6) garantem a conservação de fluxo entre cada sensor $l \in S$ ativo e o nó sorvedouro m e as restrições (4.7) e (4.8) garantem que o fluxo só é possível entre os nós sensores ativos.

$$\begin{aligned} \sum_{(i,j) \in I^j(A^s)} z_{ij}^t - \sum_{(j,k) \in O^j(A^s \cup A^m)} z_{ijk}^t &= 0, \\ \forall j \in (S - \{l\}), \forall l \in S, \forall t \in T \end{aligned} \quad (4.5)$$

$$\begin{aligned} \sum_{(i,j) \in I^j(A^s)} z_{ij}^t - \sum_{(j,k) \in O^j(A^s \cup A^m)} z_{ijk}^t &= -y_l^t, \\ \forall j = l, \forall l \in S, \forall t \in T \end{aligned} \quad (4.6)$$

$$\sum_{j \in SUM} z_{ij}^t \leq |S| y_i^t, \forall l \in S, \forall i \in S, \forall t \in T \quad (4.7)$$

$$\sum_{i \in S} z_{ij}^t \leq |S| y_j^t, \forall l \in S, \forall j \in S, \forall t \in T \quad (4.8)$$

As restrições (4.9) e (4.10) tratam a relação entre as variáveis w e y , o período em que o nó foi ativo e se o nó estava ou não ativo no período anterior. É utilizado para indicar quando a energia de ativação deve ser contabilizada na função objetivo.

$$w_l^1 - y_l^1 \geq 0, \quad \forall l \in S \quad (4.9)$$

$$w_l^t - y_l^t + y_l^{t-1} \geq 0, \quad \forall l \in S, \forall t \in T \text{ e } t \geq 2 \quad (4.10)$$

As restrições (4.11) garantem a quantidade mínima de nós sensores que devem ficar ativos a cada período e as restrições (4.12) indicam o número máximo de períodos que um nó sensor pode ficar ativo. Esta restrição caracteriza o aspecto multiperíodo do modelo.

$$\sum_{l \in S} y_l^t \geq A/\pi r^2 \quad \forall t \in T \quad (4.11)$$

$$\sum_{t \in T} y_l^t \leq n \quad \forall l \in S \quad (4.12)$$

As restrições (4.13) definem as variáveis y e z como booleanas.

$$y, z \in \{0, 1\} \quad (4.13)$$

A Abordagem Multiperíodo exige mais esforço computacional que a Abordagem Periódica, pois resolve todos os períodos simultaneamente e isto a torna inviável de ser resolvida no ótimo para instâncias grandes. Além disso, a abordagem necessita estimar um tempo de vida da rede e nem sempre isso pode ser feito adequadamente, pois os nós sensores estão sujeitos à falhas e um período pode ser prejudicado caso uma falha ocorra.

4.2 Considerações Finais

Este capítulo apresentou a Abordagem Multiperíodo para o PCD-RSSFs. A abordagem escolhe a melhor solução em termos de consumo de energia e garantia de cobertura somados todos os períodos. Para isto considera visão global da rede e dos períodos.

O objetivo deste capítulo é propor uma modelagem matemática de Programação Linear Inteira para o problema com o intuito de comparar as duas abordagens apresentadas. Assim como na Abordagem Periódica, o modelo matemático é resolvido pelo *software* de otimização CPLEX e os resultados são comparados no capítulo 6. Sabendo que o Problema de Controle de Densidade exige muito esforço computacional para ser resolvido, é proposto um Algoritmo Genético para tratá-lo. Este é apresentado no próximo capítulo.

Capítulo 5

Algoritmo Genético

O Problema de Controle de Densidade em Redes de Sensores Sem Fios (PCD-RSSFs) é um problema que exige muito esforço computacional, por isso a utilização de métodos exatos para resolvê-lo nem sempre são a melhor escolha, tornando interessante o uso de heurísticas ou meta-heurísticas. O Algoritmo Genético é uma meta-heurística utilizada quando não se tem conhecimento completo do problema e por ser simples de implementar [Noronha et al., 2001]. Cronologicamente, este foi o primeiro algoritmo proposto neste trabalho gerando um conhecimento mais profundo do PCD-RSSFs e posteriormente, após análises das duas abordagens, ele foi melhorado.

Os Algoritmos Genéticos são baseados na teoria da evolução de Darwin onde os indivíduos mais adaptados sobrevivem. Tem como requisito a representação da solução no formato de um código genético, uma função de aptidão para avaliar a qualidade de uma solução e os métodos de geração de uma nova população. O funcionamento básico consiste em um processo iterativo de criação de uma população de indivíduos e avaliação dos indivíduos através de uma função de aptidão, também chamada de *fitness*. Para a criação de uma população são utilizados três operadores genéticos: elitismo, cruzamento e mutação [Abraham et al.,]. Assim como na teoria de Darwin, a operação de cruzamento consiste em passar de pai para filho as características, ou seja, os indivíduos são combinados e geram novos indivíduos. A operação de mutação consiste na evolução dos indivíduos, ou seja, os indivíduos sofrem mudanças em alguns de seus genes. A operação de elitismo é utilizada como um critério de escolha dos indivíduos que permanecerão na nova população. Esta operação consiste em manter na população os indivíduos de melhor *fitness*. A operação que será feita por cada indivíduo é definida pela roleta.

Nos Algoritmos Genéticos alguns termos da biologia são utilizados, entre eles tem-se:

- **Geração:** refere-se a uma iteração em que uma população é gerada.
- **População:** representa um conjunto de indivíduos.
- **Indivíduo:** representa uma solução candidata, é composta por um conjunto de genes.
- **Gene:** indica uma característica específica.
- **fitness:** função de avaliação.

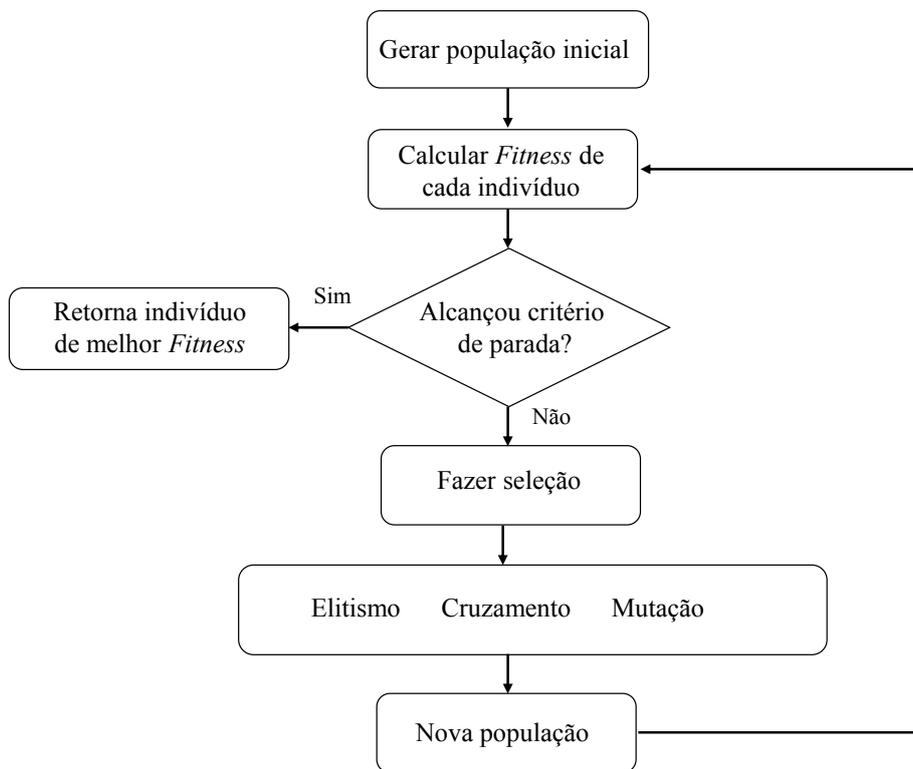


Figura 5.1. Funcionamento básico genético.

O funcionamento básico do genético é representado na Figura 5.1. O processo evolutivo começa criando uma população inicial. Para cada indivíduo da população é calculado o valor do *fitness* que indica o quão boa é uma solução. Enquanto um critério de parada não é alcançado, uma nova população é gerada a partir da população atual. Os indivíduos que tiverem melhores valores de *fitness* são os que farão elitismo, ou seja, serão copiados para a nova população. Os demais indivíduos serão criados a partir do cruzamento e da mutação. Com a nova população formada, o processo de calcular *fitness* é repetido para cada indivíduo. Quando o critério de parada é alcançado, o indivíduo que possui melhor *fitness* é retornado como solução.

5.1 Algoritmo Genético Proposto

O funcionamento do Algoritmo Genético proposto, as características das operações de cruzamento e mutação e a representação da solução são descritas nesta seção.

5.1.1 Representação da Solução

A solução é definida como um vetor binário onde cada gene representa um nó sensor. Um gene com valor igual a 1 indica que o nó sensor está ativo e com valor igual a 0 indica que está desativado. A figura 5.2 ilustra a solução de um período onde os nós sensores 1, 4, 6, 9 e 10 estão ativos.

1	0	0	1	0	1	0	0	1	1
---	---	---	---	---	---	---	---	---	---

Figura 5.2. Representação de uma solução do genético para um período.

5.1.2 Cruzamento

Na operação de cruzamento são utilizados dois pais e a cada cruzamento são gerados dois novos cromossomos. Para a escolha dos genes que serão copiados de cada pai, é utilizada uma máscara, representada por um vetor binário, que também é definido aleatoriamente. Para o primeiro cromossomo, se a posição i da máscara é igual 0, então o gene i do primeiro pai é copiado, caso contrario, o gene i do segundo pai é copiado. Para o segundo cromossomo, se a posição i da máscara é igual 0, então o gene i do segundo pai é copiado, caso contrario, o gene i do primeiro pai é copiado. A figura 5.3 ilustra a operação de cruzamento.

5.2 Mutação

O gene que fará a operação é escolhido aleatoriamente. A cada mutação somente um gene é mudado. Se o gene possuir valor igual a 1 então o nó sensor está ativo e será desativado. Se o gene possuir valor igual a 0 então o nó sensor está desativado e só poderá ser ativo se não atingiu a quantidade máxima de períodos que um nó pode ficar ativo. Senão outro nó sensor será escolhido.

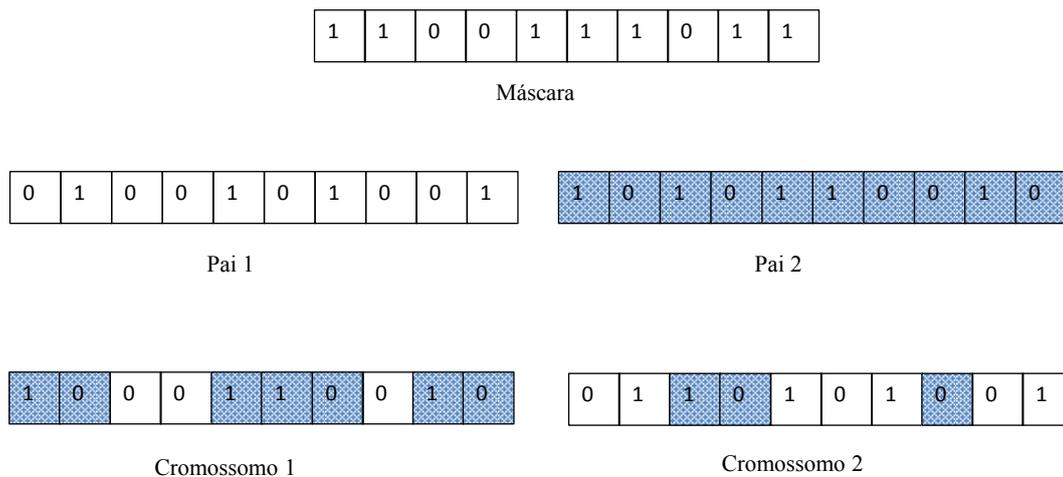


Figura 5.3. Operação de Cruzamento: Utiliza a máscara para indicar qual gene será copiado de cada pai. Se a $mascara_{[i]} = 1$ então o cromossomo1 recebe o gene do pai2, caso contrário recebe o gene do pai1. Se a $mascara_{[i]} = 0$ então o cromossomo2 recebe o gene do pai1, caso contrário recebe o gene do pai2.

5.2.1 Funcionamento Básico

O Algoritmo Genético proposto simula as abordagens Periódica e Multiperíodo por isso é dito ser híbrido. Consiste em duas etapas: uma fase de geração de soluções e outra de refinamento.

Inicialmente, na fase de geração de soluções, é definida a quantidade de períodos assim como é feito na Abordagem Multiperíodo. Sabendo o total de períodos é gerada a solução de cada período utilizando o Algoritmo Genético. Desta forma a solução de cada período é formada sem visão global simulando o aspecto da Abordagem Periódica.

Após a escolha da solução de cada período é formado um conjunto com todas as soluções e realizada a fase de refinamento. A fase de refinamento tenta melhorar a solução dos períodos tendo visão global dos períodos, pois estes já possuem uma solução inicial, simulando o aspecto da Abordagem Multiperíodo.

5.2.1.1 Fase de Geração de Soluções

O algoritmo começa gerando uma população inicial. Esta população é formada aleatoriamente e leva em consideração a quantidade de períodos que um nó sensor pode ficar ativo, ou seja, uma solução só ativa um nó sensor que ainda possa ser usado. Para cada indivíduo da população é calculado o valor de *fitness* cujo objetivo é avaliar a qualidade do indivíduo. A função de *fitness* utilizada foi a função objetivo do modelo matemático proposto no Capítulo 3.

Enquanto o critério de parada não for alcançado, neste caso a quantidade máxima de iterações, uma nova população é gerada. A nova população é formada através das operações de elitismo, cruzamento e mutação. Quando o critério de parada é alcançado, o indivíduo de melhor *fitness* é retornado como solução. Este processo é repetido para todos os períodos, formando um conjunto de soluções.

Com o conjunto de soluções, composto pela solução de cada período, a fase de refinamento é executada com o objetivo de equilibrar o atendimento dos requisitos em todos os períodos.

5.2.1.2 Fase de Refinamento

A Abordagem Multiperíodo tem vantagem de ter visão global da rede e dos períodos e com isso consegue equilibrar o atendimento dos requisitos em todos os períodos, mesmo que seja necessário permitir falhas na cobertura em períodos iniciais. Baseado nestes conceitos é proposta a fase de refinamento cujo objetivo é equilibrar a quantidade de nós sensores ativos em cada período e diminuir a quantidade total de pontos de demanda descobertos, o que normalmente, na Abordagem Periódica, acontece nos últimos períodos. O Algoritmo Genético é utilizado para gerar a solução de cada período e formar um conjunto de soluções que é utilizado como entrada na fase de refinamento, assim simulando visão global, já que se tem uma solução inicial.

O funcionamento básico consiste em escolher um nó sensor que possa sair do período 1 e entrar no período t , desde que a solução do período t seja melhorada com a inclusão do nó sensor e não deixe pontos de demanda descobertos no período 1 ou se a função de *fitness* for melhorada. Esse processo é repetido para o período 2 com o período $t - 1$ e assim sucessivamente. A figura 5.4 ilustra a fase de refinamento com o conjunto de soluções geradas no Algoritmo Genético, e a figura 5.5 mostra um exemplo em que o nó sensor 5 é desativado no período 1 e ativado no período t .

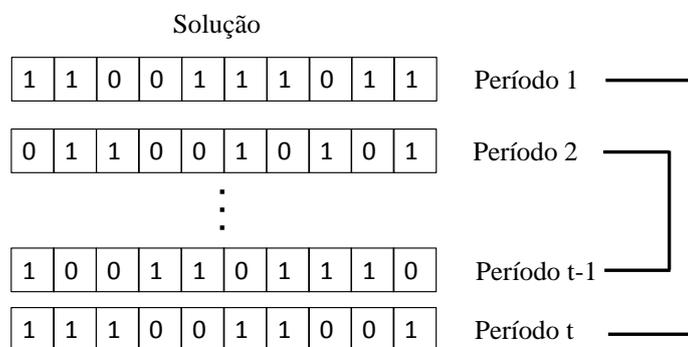


Figura 5.4. Conjunto de soluções gerado com o Algoritmo Genético.

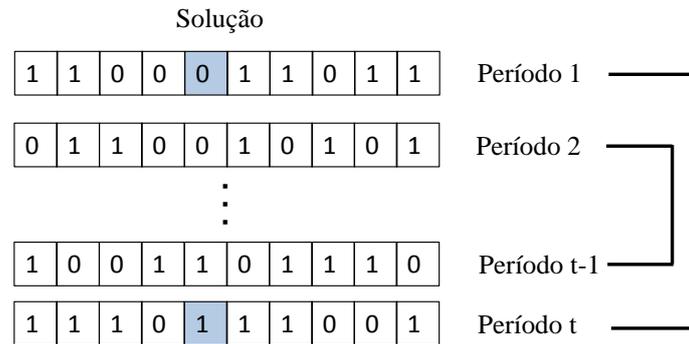


Figura 5.5. Fase de refinamento onde um nó sensor sai da solução do período 1 e vai para a solução do período t.

Ao final é retornado o conjunto de soluções indicando a solução para cada período.

5.3 Considerações Finais

Este capítulo apresentou um Algoritmo Genético Híbrido baseado no funcionamento das Abordagens Periódica e Mutiperíodo. Para a escolha da solução de cada período é utilizada a Abordagem Periódica que escolhe a melhor solução para cada período. Depois o algoritmo utiliza uma fase de refinamento baseada nos conceitos da Abordagem Mutiperíodo. Daí o termo Algoritmo Híbrido. A ideia é escolher a solução de todos os períodos de acordo com a Abordagem Periódica e em seguida aplicar a fase de refinamento para tentar equilibrar o atendimento dos requisitos de todos os períodos, sugerindo um comportamento semelhante a Abordagem Mutiperíodo. Os resultados deste algoritmo, da solução ótima dos modelos matemáticos e Heurística são apresentados no próximo capítulo.

Capítulo 6

Resultados Computacionais

Os testes realizados avaliaram diversos aspectos das abordagens, dos modelos e algoritmos propostos para o Problema de Controle de Densidade em Redes de Sensores sem Fio (PCD-RSSFs) e são discutidos abaixo:

Comparação dos resultados da Relaxação Lagrangeana com a solução da Relaxação Linear e com o valor ótimo do modelo matemático Periódico.

Comparação do GAP de dualidade da Relaxação Lagrangeana, utilizando como limite superior a solução gerada pela Heurística Lagrangeana.

Comparação da solução do modelo matemático da Abordagem Periódica com a solução do modelo matemático da Abordagem Multiperíodo.

Comparação dos resultados da Heurística Lagrangeana com o valor ótimo do modelo matemático Periódico e com os Algoritmos GAF, HGAF e Genético.

Os resultados são avaliados considerando o consumo de energia, a porcentagem de cobertura e o tempo de execução. Os algoritmos foram feitos em linguagem C e o modelo matemático foi resolvido pelo *software* de otimização CPLEX.

6.1 Instâncias

Para a geração das instâncias, foi considerado o tamanho da área, o raio de comunicação, o raio de sensoriamento e a quantidade de nós sensores. O algoritmo de geração de instâncias tem como saída arquivos que indicam a quantidade de nós sensores, a quantidade de pontos de demanda, a matriz de conectividade com a energia de transmissão que é representada pelas distâncias entre os nós sensores e a matriz de cobertura de pontos de demanda que indica se um nó sensor alcança um ponto de demanda. As instâncias não são continuidade de outras menores, ou seja, a instância com 36 nós sensores não é formada pela instância de 25 nós sensores acrescentada de mais 11 nós

sensores.

O posicionamento dos nós sensores na área de monitoramento foi gerado utilizando grade irregular. Onde os nós sensores são distribuídos em locais pré-definidos somado de um desvio aleatório nas coordenadas (x, y) . A figura 6.1 ilustra uma grade irregular.

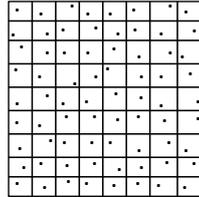


Figura 6.1. Grade irregular com os nós sensores dispostos na área de monitoramento após o desvio aleatório em suas coordenadas (x, y) .

6.2 Parâmetros de Entrada

Tem-se como parâmetros de entrada:

Área de Monitoramento: 10m x 10m

Localização do Sorvedouro: Coordenada(0.5 , 0.5).

Número de Pontos de Demanda: 100, que corresponde a 1 ponto de demanda por m^2

Energia de Ativação: 10 mAh

Energia de Manutenção: 1.2 mAh

Penalidade de não Cobertura (EH): 1000

Os dados referentes a energia de ativação e energia de manutenção foram baseados nos dados do nó sensor MICAz¹. Os demais valores foram baseados no trabalho de Nakamura (2010). O valor da penalidade de cobertura foi definido de forma que os algoritmos evitem deixar pontos de demanda descobertos. Vale ressaltar que uma penalidade muita alta pode prejudicar o objetivo principal, minimizar o consumo de energia, pois a penalidade está inclusa na função objetivo. Por outro lado uma penalidade de cobertura baixa pode resultar em soluções com muitos pontos de demanda descobertos.

¹Mais detalhes em: <http://www.bullseye.xbow.com:81/Products/productdetails.aspx?sid=164>

A porcentagem de cobertura é calculada somando-se a quantidade de pontos de demanda cobertos em cada período e dividindo pela quantidade total de pontos de todos os períodos. Por exemplo, para uma área com 100 pontos de demanda e dois períodos a quantidade total de pontos de todos os períodos é 200. Se o algoritmo cobre 90 pontos no primeiro período e 100 no segundo período, então a porcentagem de cobertura é $\frac{90+100}{200} = 95\%$.

Os testes consideram uma rede homogênea, plana e com sorvedouro fixo, localizado no canto superior esquerdo. Também foi considerado que para dois períodos $n = 1$ (a quantidade de períodos que um nó pode ficar ativo) e para três e seis períodos $n = 2$. A tabela 6.1 detalha os testes executados. Para melhor compreensão, cada conjunto de testes é denominado Bateria.

Método	Bateria 1	Bateria 2	Bateria 3	Bateria 4
Solução Ótima do modelo Periódico	X		X	X
Solução Ótima do modelo Multiperíodo			X	
Relaxação Lagrangeana	X	X		
Heurística Lagrangeana		X		X
Relaxação Linear	X			
Algoritmo Génético				X
GAF				X
HGAF				X

Tabela 6.1. Divisão do que cada bateria de teste compara.

Para as quatro baterias de teste os resultados são mostrados em tabelas que indiquem a quantidade de períodos, o consumo de energia e os tempos de execução. As colunas referentes ao consumo de energia de cada heurística mostram o valor correspondente a soma do consumo de energia de acordo com a quantidade de períodos. Por exemplo, para dois períodos o valor mostrado é a soma do consumo de energia do período 1 com o período 2. O mesmo acontece para as colunas que mostram os tempos de execução. Por exemplo, para dois períodos o tempo mostrado é a soma do tempo gasto no período 1 com o período 2. Para três períodos o tempo é o mesmo que o de dois períodos, pois foi considerado $n = 2$ (um nó sensor pode ficar ativo por dois períodos), assim a solução de um período é replicada.

6.3 Bateria 1

Nesta bateria são comparados os resultados da Relaxação Lagrangeana com a solução da Relaxação Linear e com o valor ótimo do modelo matemático Periódico. A Relaxa-

ção Linear segue o mesmo modelo matemático proposto para a Abordagem Periódica exceto nas restrições de integralidade que são relaxadas, assim, aceitando valores reais.

As instâncias utilizadas são descritas na tabela 6.2.

Quantidade de nós sensores	Raio de Sensoriamento (m)	Raio de Comunicação (m)
144	3	6
169	3	7

Tabela 6.2. Descrição das instâncias da bateria 1.

A bateria compara o GAP de dualidade entre o limite inferior (LI) gerado com a Relaxação Linear e o limite superior (LS) representado pela solução ótima do modelo matemático Periódico. Também compara o GAP de dualidade entre a Relaxação Lagrangeana e a solução ótima. O GAP é utilizado para avaliar a qualidade da solução, seu valor indica que a solução viável está no máximo a GAP% do valor ótimo, assim quando o valor for 0 indica que alcançou o valor ótimo. É calculado pela fórmula:

$$GAP = 100 \times \frac{LS - LI}{LS} \quad (6.1)$$

Os resultados são mostrados nas tabelas 6.3 e 6.4. Pode-se perceber que os GAP's para a Relaxação Lagrangeana são menores que o da Relaxação Linear. A diferença entre os GAP's das duas relaxações varia entre 9,53% e 35,94% conforme mostrado na tabela 6.3 e entre 12,16% e 35,26% conforme a tabela 6.4. Isto indica que a utilização da Relaxação Lagrangeana é mais interessante para gerar limites inferiores para o problema. Além disso, a Relaxação Lagrangeana fornece limites inferiores gerados com soluções de valores inteiros o que facilita na geração de soluções viáveis a partir do limite inferior.

Outra métrica avaliada foi o tempo gasto na geração das soluções. As tabelas 6.5 e 6.6 mostram os tempos de cada método. É notável que a Relaxação Linear e a solução ótima consomem mais tempo que a Relaxação Lagrangeana e isso se justifica pelo fato de ambas serem resolvidas pelo CPLEX utilizando algoritmos de complexidade exponencial enquanto que a Relaxação Lagrangeana utiliza as heurísticas propostas. Também pode-se perceber que o tempo de execução aumenta de acordo com a quantidade de períodos, porém para a Relaxação Lagrangeana este aumento é mais contido e menos acentuado que os outros dois métodos. Vale destacar que o tempo de execução para 2 e 3 períodos é o mesmo, pois a solução para três períodos é a mesma que a de dois períodos com um período repetido.

Qtdd Períodos	Instância	LI Relaxação Linear	LI Relaxação Lagrangeana	Solução Ótima	GAP Relaxação Linear (%)	GAP Relaxação Lagrangeana (%)
1	FileModelo0	45,78	78,06	89,9517	49,10%	13,22%
	FileModelo1	46,50	76,42	89,8825	48,27%	14,98%
	FileModelo2	46,32	71,80	88,4239	47,62%	18,80%
	FileModelo3	45,91	77,08	89,2333	48,56%	13,62%
	FileModelo4	47,16	80,52	92,8001	49,18%	13,24%
2	FileModelo0	94,58	159,14	183,89	48,57%	13,46%
	FileModelo1	94,21	155,34	192,47	51,05%	19,30%
	FileModelo2	93,92	141,21	177,51	47,09%	20,45%
	FileModelo3	93,64	153,39	182,13	48,59%	15,78%
	FileModelo4	95,77	162,43	197,40	51,48%	17,72%
3	FileModelo0	140,13	194,71	223,85	37,40%	13,02%
	FileModelo1	140,57	191,01	232,36	39,50%	17,79%
	FileModelo2	140,00	175,78	215,93	35,17%	18,60%
	FileModelo3	139,46	188,61	221,36	37,00%	14,80%
	FileModelo4	142,78	200,02	230,20	37,98%	13,11%
6	FileModelo0	288,03	350,96	406,29	29,11%	13,62%
	FileModelo1	287,51	353,89	423,08	32,04%	16,35%
	FileModelo2	287,29	323,81	383,36	25,06%	15,54%
	FileModelo3	286,74	348,88	410,07	30,08%	14,92%
	FileModelo4	290,24	371,54	428,82	32,32%	13,36%

Tabela 6.3. Resultados com 144 nós sensores da bateria 1.

Qtdd Períodos	Instância	LI Relaxação Linear	LI Relaxação Lagrangeana	Solução Ótima	GAP Relaxação Linear (%)	GAP Relaxação Lagrangeana (%)
1	FileModelo0	46,26	70,86	89,8855	48,54%	21,16%
	FileModelo1	45,56	73,16	91,9027	50,42%	20,39%
	FileModelo2	45,66	77,32	89,7694	49,13%	13,87%
	FileModelo3	45,27	73,73	88,5776	48,89%	16,76%
	FileModelo4	46,00	73,85	90,1339	48,96%	18,06%
2	FileModelo0	93,49	144,71	181,55	48,50%	20,30%
	FileModelo1	92,74	151,40	184,21	49,66%	17,81%
	FileModelo2	93,44	156,57	191,54	51,22%	18,26%
	FileModelo3	92,51	147,55	178,14	48,07%	17,18%
	FileModelo4	93,83	154,64	182,26	48,52%	15,16%
3	FileModelo0	139,62	179,83	221,44	36,95%	18,79%
	FileModelo1	138,13	188,12	226,11	38,91%	16,80%
	FileModelo2	138,88	191,54	231,31	39,96%	17,20%
	FileModelo3	137,46	181,49	216,72	36,57%	16,26%
	FileModelo4	139,59	190,24	222,39	37,23%	14,46%
6	FileModelo0	284,11	332,57	398,50	28,71%	16,54%
	FileModelo1	282,78	346,24	415,52	31,95%	16,67%
	FileModelo2	285,62	345,22	419,55	31,92%	17,72%
	FileModelo3	282,70	334,00	394,77	28,39%	15,39%
	FileModelo4	285,52	346,72	414,68	31,15%	16,39%

Tabela 6.4. Resultados com 169 nós sensores da bateria 1.

Qtdd Períodos	Instância	Tempo Relaxação Linear (s)	Tempo Relaxação Lagrangeana (s)	Tempo Solução Ótima (s)
1	FileModelo0	690,09	25,95	1534,33
	FileModelo1	610,50	27,80	1301,72
	FileModelo2	705,18	190,78	2158,55
	FileModelo3	690,90	175,15	1220,17
	FileModelo4	656,35	173,90	1609,41
2	FileModelo0	1376,19	43,90	12390,5
	FileModelo1	1200,78	42,17	2999,9
	FileModelo2	1420,56	341,97	3321,43
	FileModelo3	1365,80	342,29	2848,16
	FileModelo4	1332,69	345,79	2819,84
3	FileModelo0	1376,19	523,90	12390,5
	FileModelo1	1200,78	522,72	2999,9
	FileModelo2	1420,56	522,40	3321,43
	FileModelo3	1365,80	522,28	2848,16
	FileModelo4	1332,69	523,35	2819,84
6	FileModelo0	3898,47	1027,50	13743,56
	FileModelo1	3475,38	1029,87	8157,49
	FileModelo2	3900,08	1024,49	4018,05
	FileModelo3	3769,93	1026,70	4170,26
	FileModelo4	11003,29	1036,07	7421,15

Tabela 6.5. Tempo de execução dos testes com 144 nós sensores da bateria 1.

Qtdd Períodos	Instância	Tempo Relaxação Linear (s)	Tempo Relaxação Lagrangeana (s)	Tempo Solução Ótima (s)
1	FileModelo0	1721,47	282,37	3733,6
	FileModelo1	1745,74	281,36	2903,00
	FileModelo2	1755,81	284,31	2725,57
	FileModelo3	1740,18	281,04	3106,69
	FileModelo4	1773,61	283,25	3444,48
2	FileModelo0	3422,93	564,74	6812,37
	FileModelo1	3491,48	562,71	6020,33
	FileModelo2	3511,61	568,62	2725,57
	FileModelo3	3480,37	562,08	6017,74
	FileModelo4	3547,21	566,50	6905,09
3	FileModelo0	3422,93	863,14	6812,37
	FileModelo1	3491,48	859,32	6020,33
	FileModelo2	3511,61	867,53	5875,46
	FileModelo3	3480,37	855,70	6017,74
	FileModelo4	3547,21	860,88	6905,09
6	FileModelo0	9533,63	1698,69	9888,42
	FileModelo1	10156,92	1697,31	9146,63
	FileModelo2	9495,86	1707,53	5480,07
	FileModelo3	10182,20	1687,68	10182,48
	FileModelo4	9711,23	1700,28	21638,57

Tabela 6.6. Tempo de execução dos testes com 169 nós sensores da bateria 1.

6.4 Bateria 2

A bateria 2 compara o GAP de dualidade da Relaxação Lagrangeana, utilizando como limite superior a solução gerada pela Heurística Lagrangeana. As instâncias utilizadas são descritas na tabela 6.7.

Quantidade de nós sensores	Raio de Sensoriamento (m)	Raio de Comunicação (m)
36	3	7
144	3	6

Tabela 6.7. Descrição das instâncias da bateria 2.

Os resultados para um período são mostrados na tabela 6.8, para dois períodos são mostrados na tabela 6.9, para três períodos na tabela 6.10 e para seis períodos na tabela 6.11.

Instância	LI Relaxação Lagrangeana	LS Heurística Lagrangeana	Tempo Relaxação Lagrangeana (s)	Solução Ótima	Tempo Solução Ótima (s)	GAP (%)
F0_36_7	106,20	109,87	38,54	109,87	11,36	3,33%
F1_36_7	106,44	107,10	56,55	107,10	2,54	0,62%
F2_36_7	107,53	110,81	48,40	110,81	4,62	2,96%
F3_36_7	106,25	107,21	57,54	107,21	2,94	0,89%
F4_36_7	105,02	106,71	65,45	106,71	2,56	1,59%
F0_144_6	78,06	107,22	25,95	89,95	1534,33	27,20%
F1_144_6	76,42	104,38	30,08	89,88	1301,72	26,79%
F2_144_6	71,80	89,32	175,99	88,42	2158,55	19,62%
F3_144_6	77,08	106,46	161,15	89,23	1220,17	27,60%
F4_144_6	80,52	106,61	152,90	92,80	1609,41	24,48%

Tabela 6.8. Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 1 períodos.

Instância	LI Relaxação Lagrangeana	LS Heurística Lagrangeana	Tempo Relaxação Lagrangeana (s)	Solução Ótima	Tempo Solução Ótima (s)	GAP (%)
F0_36_7	233,24	233,24	85,07	233,24	13,06	0,00%
F1_36_7	233,75	233,75	104,67	233,75	4,84	0,00%
F2_36_7	236,03	236,03	90,68	236,03	6,93	0,00%
F3_36_7	238,60	238,60	111,08	238,60	5,89	0,00%
F4_36_7	217,94	217,94	139,29	217,94	4,24	0,00%
F0_144_6	159,14	201,17	43,90	183,90	12390,50	20,89%
F1_144_6	155,34	216,67	42,17	192,48	2999,90	28,31%
F2_144_6	141,21	195,82	341,97	177,51	3321,43	27,89%
F3_144_6	153,39	217,91	342,29	182,14	2848,16	29,61%
F4_144_6	162,43	217,97	345,79	197,40	2819,84	25,48%

Tabela 6.9. Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 2 períodos.

Instância	LI Relaxação Lagrangeana	LS Heurística Lagrangeana	Tempo Relaxação Lagrangeana (s)	Solução Ótima	Tempo Solução Ótima (s)	GAP (%)
F0_36_7	275,78	283,11	213,57	283,11	13,06	2,59%
F1_36_7	278,86	280,85	117,14	280,85	4,84	0,71%
F2_36_7	281,47	286,84	187,73	286,84	6,93	1,87%
F3_36_7	282,80	285,80	356,95	285,80	5,89	1,05%
F4_36_7	260,68	264,65	371,53	264,65	4,24	1,50%
F0_144_6	194,71	241,12	523,90	223,85	12390,50	19,25%
F1_144_6	191,01	256,55	522,72	232,36	2999,90	25,55%
F2_144_6	175,78	234,25	522,40	215,93	3321,43	24,96%
F3_144_6	188,61	257,14	522,28	221,37	2848,16	26,65%
F4_144_6	200,02	260,77	523,35	230,20	2819,84	23,30%

Tabela 6.10. Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 3 períodos.

Instância	LI Relaxação Lagrangeana	LS Heurística Lagrangeana	Tempo Relaxação Lagrangeana (s)	Solução Ótima	Tempo Solução Ótima (s)	GAP (%)
F0_36_7	6519,50	6528,76	451,86	6528,76	13,90	0,14%
F1_36_7	521,70	526,35	556,53	526,35	5,65	0,88%
F2_36_7	2526,80	2533,47	496,63	2533,47	7,46	0,26%
F3_36_7	4556,67	4562,46	652,46	4562,46	6,45	0,13%
F4_36_7	6496,97	6502,96	522,17	6502,96	4,96	0,09%
F0_144_6	350,96	435,54	1027,50	406,30	13743,56	19,42%
F1_144_6	353,89	447,89	1029,87	423,09	8157,49	20,99%
F2_144_6	323,81	401,68	1024,49	383,37	4018,05	19,39%
F3_144_6	348,88	454,52	1026,70	410,08	4170,26	23,24%
F4_144_6	371,54	463,43	1036,07	428,82	7421,15	19,83%

Tabela 6.11. Comparação entre os limites da relaxação lagrangeana com 36 e 144 nós sensores e 6 períodos.

Percebe-se que para instâncias menores a Relaxação Lagrangeana em conjunto com Heurística Lagrangeana possui bom desempenho, alcançando a solução ótima em algumas instâncias. Isso pode ser notado na tabela 6.8, em que a Heurística Lagrangeana alcançou o ótimo embora o GAP não seja zero, e na tabela 6.9 em que o GAP é zero para as instâncias com 36 nós sensores.

Com maiores quantidade de nós sensores a Relaxação Lagrangeana com Heurística Lagrangeana possui GAP's maiores, porém ao comparar o limite superior da relaxação com a solução ótima, observa-se que os valores estão próximos com diferenças no consumo de energia variando entre 17,27 e 35,77 para dois e três períodos e entre 18,31 e 44,44 para seis períodos. Além disso, vale destacar que o tempo gasto na relaxação possui comportamento mais contido que a solução ótima, principalmente para quantidades maiores de nós sensores. Com maior número de períodos os GAP's não aumentam muito, assumindo comportamento quase constante e validando o uso

da Relaxação Lagrangeana combinada com Heurística Lagrangeana para gerar soluções para o problema.

6.5 Bateria 3

A bateria 3 compara a solução do modelo matemático da Abordagem Periódica com a solução do modelo matemático da Abordagem Multiperíodo. Como discutido no Capítulo 4, a Abordagem Multiperíodo possui a vantagem de ter visão global da rede e dos períodos, alcançando resultados melhores em algumas instâncias. As instâncias utilizadas são descritas na tabela 6.12. É importante destacar que os testes foram executados com quantidades menores de nós sensores devido a maior complexidade computacional da Abordagem Multiperíodo que torna inviável a resolução do problema com grandes quantidades de nós sensores.

Quantidade de nós sensores	Raio de Sensoriamento (m)	Raio de Comunicação (m)
25	3	7
36	3	6

Tabela 6.12. Descrição das instâncias da bateria 4.

Os resultados são mostrados nas tabelas 6.13 e 6.14. Para um menor número de períodos, mais próximos são os resultados das duas abordagens, tanto em consumo de energia quanto em porcentagem de cobertura. Isto acontece com poucos períodos pois o conjunto de nós sensores disponíveis em cada período é suficiente para atender os requisitos, ao contrário do que acontece com maiores quantidades de períodos. Vale ressaltar que a Abordagem Multiperíodo com um período tem o mesmo comportamento que a Abordagem Periódica. Com um maior número de períodos o conjunto de nós sensores que atendam os requisitos é menor, a tendência da Abordagem Periódica é ter um aumento na falha de cobertura, enquanto que a Abordagem Multiperíodo equilibra essas falhas no decorrer de todos os períodos. Por isso a Abordagem Multiperíodo consegue diminuir as falhas na cobertura e permitir que em alguns casos, o tempo de vida da rede seja estendido por mais períodos. Isto justifica o melhor desempenho da Abordagem Multiperíodo para seis períodos. Por outro lado, a Abordagem Multiperíodo exige maior complexidade computacional e conseqüentemente mais tempo para ser resolvida.

Modelo Matemático Abordagem Periódica					Modelo Matemático Abordagem Multiperíodo		
Qtdd Períodos	Instância	Consumo Energia	Tempo (s)	Cobertura (%)	Consumo Energia	Tempo (s)	Cobertura (%)
2	File0	278,247	0,83	99,50%	275,765	4,97	99,50%
	File1	296,743	0,79	97,00%	294,969	5,22	99,00%
	File2	252,684	1,20	100,00%	251,362	7,87	100,00%
	File3	236,534	0,67	100,00%	236,309	4,56	100,00%
	File4	242,675	1,05	99,50%	238,007	4,92	99,50%
3	File0	337,860	0,83	99,67%	337,363	38,68	99,67%
	File1	358,779	0,79	98,00%	356,847	33,45	99,33%
	File2	305,159	1,2	100,00%	303,835	102,77	100,00%
	File3	284,462	0,67	100,00%	284,237	6,67	100,00%
	File4	298,053	1,05	99,67%	294,491	12,83	99,67%
6	File0	603,679	0,87	96,67%	567,852	157,6	97,67%
	File1	608,747	0,83	89,00%	529,788	178,22	96,00%
	File2	601,632	1,25	95,00%	565,344	595,95	100,00%
	File3	515,823	0,75	97,33%	536,536	978,99	98,33%
	File4	550,280	1,12	96,67%	551,807	276,77	98,33%

Tabela 6.13. Comparação entre o valor ótimo para a Abordagem Periódica e Abordagem Multiperíodo com 25 nós sensores.

Modelo Matemático Abordagem Periódica					Modelo Matemático Abordagem Multiperíodo		
Qtdd Períodos	Instância	Consumo Energia	Tempo (s)	Cobertura (%)	Consumo Energia	Tempo (s)	Cobertura (%)
2	File0	216,949	8,04	100,00%	216,949	27,52	100,00%
	File1	242,953	3,73	100,00%	242,953	51,8	100,00%
	File2	226,619	10,43	100,00%	226,619	42,89	100,00%
	File3	214,177	3,27	100,00%	214,747	29,66	100,00%
	File4	255,101	11,73	100,00%	243,858	44,76	100,00%
3	File0	264,992	8,04	100,00%	264,992	154,31	100,00%
	File1	292,645	3,73	100,00%	292,645	209,75	100,00%
	File2	279,301	10,43	100,00%	279,301	199,35	100,00%
	File3	253,180	3,27	100,00%	253,180	82,09	100,00%
	File4	306,749	11,73	100,00%	296,022	234,03	100,00%
6	File0	507,769	9,57	100,00%	502,065	6766,07	100,00%
	File1	580,130	4,34	100,00%	574,296	1644,26	100,00%
	File2	543,751	11,31	100,00%	542,475	4321,65	100,00%
	File3	503,930	4,15	99,33%	2507,489	3895,69	99,67%
	File4	569,985	12,14	99,00%	2554,639	16415,55	99,67%

Tabela 6.14. Comparação entre o valor ótimo para a Abordagem Periódica e Abordagem Multiperíodo com 36 nós sensores.

6.6 Bateria 4

A bateria 4 compara os resultados da Relaxação Lagrangeana e Heurística Lagrangeana com o valor ótimo do modelo matemático Periódico e com os Algoritmos GAF [Xu et al., 2001], HGAF [Inagaki & Ishihara, 2009] e Genético. Para o Algoritmo Genético são utilizados 15% de elitismo, 5% de mutação e 80% de cruzamento. As instâncias utilizadas são descritas na tabela 6.15.

Quantidade de nós sensores	Raio de Sensoriamento (m)	Raio de Comunicação (m)
144	3	6
169	3	7

Tabela 6.15. Descrição das instâncias da bateria 4.

Os resultados são mostrados nos Gráficos 6.2 e 6.3. HL representa a Heurística Lagrangeana e “Periódico” representa a solução ótima gerada pelo modelo matemático Periódico. Os gráficos comparam o consumo de energia com 2, 3 e 6 períodos. Os algoritmos GAF e HGAF foram escolhidos por serem bem citados na literatura e serem de fácil implementação. Como explicado nas seções 2.4.1 e 2.4.2, estes dois algoritmos ativam uma quantidade fixa de nós sensores para cada período. Para os testes gerados o GAF ativa 16 nós sensores e o HGAF ativa 9 nós sensores por período.

Analisando os gráficos, é possível ver que a Heurística Lagrangeana consome menos energia que os dois algoritmos e isso se justifica pela maior quantidade de nós sensores ativados pelos algoritmos. A Heurística Lagrangeana também é melhor que o Algoritmo Genético visto que a mesma é um método exato enquanto que o Algoritmo Genético é uma heurística. Também é possível notar que a Heurística Lagrangeana possui comportamento parecido com o da solução ótima com consumo de energia próximo.

Em relação ao tempo de execução, os resultados são mostrados nas Tabelas 6.16 e 6.17. Os algoritmos GAF e HGAF são os que têm melhor desempenho, porém a qualidade da solução é prejudicada. O Algoritmo Genético gasta mais tempo, ganhando apenas do modelo ótimo. Isso se justifica pela natureza do problema aplicada as características do Genético. A Relaxação Lagrangeana em conjunto com Heurística Lagrangeana consegue equilibrar consumo de energia x tempo de solução, enfatizando a vantagem de se utilizar a Relaxação Lagrangeana.

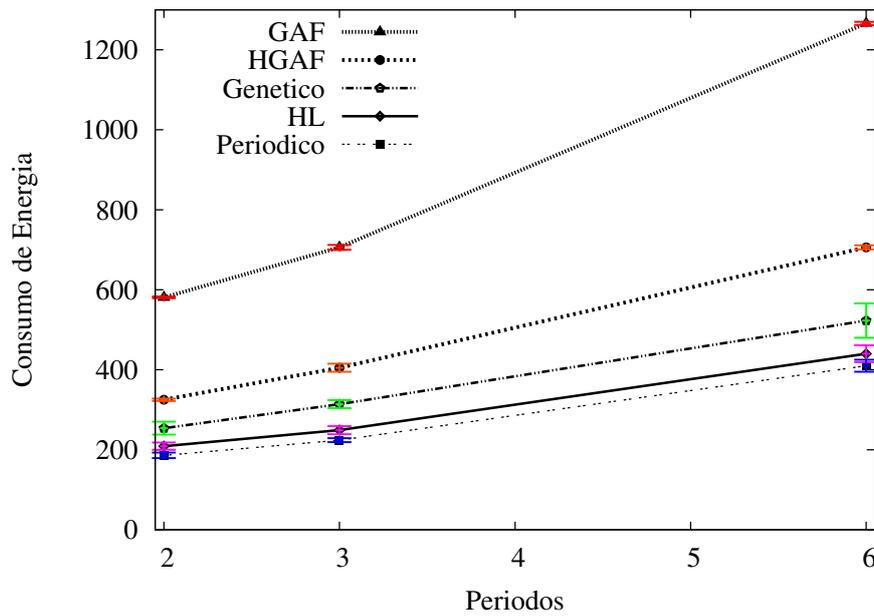


Figura 6.2. Comparação do consumo de energia com 144 nós sensores.

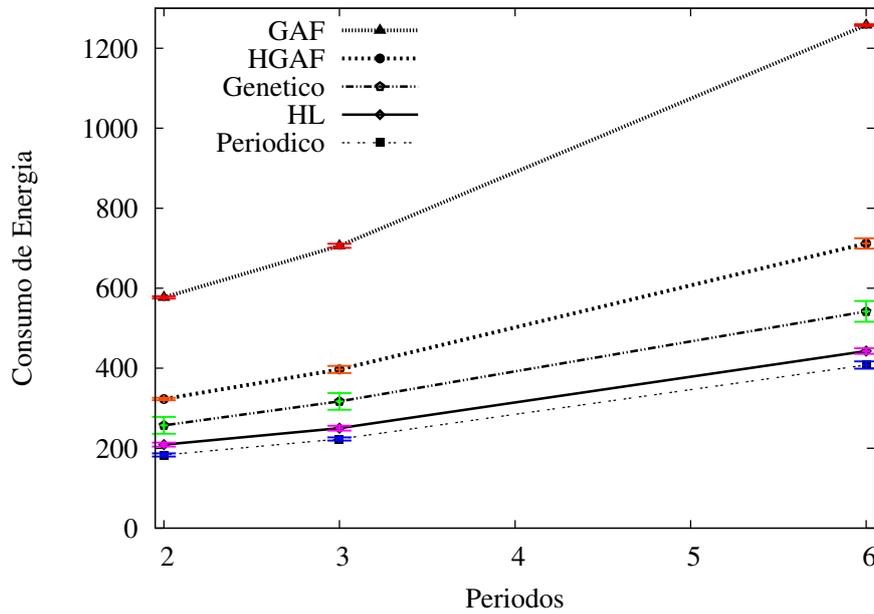


Figura 6.3. Comparação do consumo de energia com 169 nós sensores.

Qtdd Períodos	GAF (s)	HGAF (s)	Relaxação Lagrangeana (s)	Genético (s)	Solução Ótima (s)
2	0,04	7,00	43,90	2377,85	12390,50
	0,04	7,00	42,17	2377,69	2999,90
	0,04	8,00	341,97	2378,86	3321,43
	0,06	8,00	342,29	2377,67	2848,16
	0,03	8,00	345,79	2378,76	2819,84
3	0,04	7,00	523,90	2377,67	12390,50
	0,03	7,00	522,72	2377,87	2999,90
	0,04	8,00	522,40	2378,40	3321,43
	0,04	8,00	522,28	2377,63	2848,16
	0,04	8,00	523,35	2378,91	2819,84
6	0,04	11,00	1027,50	3564,51	13743,56
	0,05	11,00	1029,87	3564,76	8157,49
	0,07	12,00	1024,49	3564,66	4018,05
	0,04	11,00	1026,70	3578,98	4170,26
	0,05	11,00	1036,07	3564,06	7421,15

Tabela 6.16. Comparação dos Tempos para 144 nós sensores.

Qtdd Períodos	GAF (s)	HGAF (s)	Relaxação Lagrangeana (s)	Genético (s)	Solução Ótima (s)
2	0,04	11,00	564,74	2812,806	6812,37
	0,04	12,00	562,71	2814,119	6020,33
	0,02	11,00	568,62	2812,766	2725,57
	0,02	12,00	562,08	2812,865	6017,74
	0,03	11,00	566,50	2864,537	6905,09
3	0,04	11,00	863,14	2812,975	6812,37
	0,04	12,00	859,32	2813,118	6020,33
	0,06	11,00	867,53	2812,604	5875,46
	0,05	12,00	855,70	2812,739	6017,74
	0,04	11,00	860,88	2864,448	6905,09
6	0,05	17,00	1698,69	4217,258	9888,42
	0,04	18,00	1697,31	4216,804	9146,63
	0,06	17,00	1707,53	4216,779	5480,07
	0,05	18,00	1687,68	4217,477	10182,48
	0,06	17,00	1700,28	4216,78	21638,57

Tabela 6.17. Comparação dos Tempos para 169 nós sensores.

6.7 Considerações Finais

Este capítulo apresentou os resultados computacionais divididos em quatro baterias.

Na primeira bateria é comparado o limite inferior da Relaxação Lagrangeana com a solução da Relaxação Linear. Nesta bateria é possível notar que o limite inferior gerado pela Relaxação Lagrangeana é melhor que o limite inferior da Relaxação Linear, pois consegue valores maiores consumindo menos tempo e este é o comportamento esperado para limites inferiores.

Na segunda bateria é comparado o GAP de dualidade da Relaxação Lagrangeana utilizando a Heurística Lagrangeana como limite superior. Neste teste é notado que para instâncias menores a Heurística Lagrangeana consegue chegar no valor ótimo e para instâncias maiores, embora o GAP aumente, o valor do limite superior fica próximo do valor ótimo obtido resolvendo-se o modelo matemático com o software CPLEX.

A terceira bateria compara a solução do modelo matemático das duas abordagens. Como esperado, a Abordagem Multiperíodo consegue resultados melhores no consumo de energia, devido a visão global da rede e dos períodos. Porém, por ser mais complexa a Abordagem Multiperíodo consome mais tempo o que inviabiliza os testes com instâncias maiores.

Por último, na quarta bateria são comparados os resultados da Relaxação Lagrangeana e Heurística Lagrangeana com o valor ótimo do modelo matemático Periódico e com os Algoritmos GAF, HGAF e Genético. Nesta bateria nota-se que a Relaxação Lagrangeana em conjunto com a Heurística Lagrangeana alcançam os melhores resultados tanto em consumo de energia quanto em tempo de solução. Isso se justifica por ser um método exato. A resolução do modelo matemático serve como parâmetro para sabermos quão longe os algoritmos encontram-se do valor ótimo e configura-se como um indicador de qualidade (limite inferior) para algoritmos de Controle de Densidade.

Capítulo 7

Considerações Finais

7.1 Conclusões

As RSSFs possuem recursos limitados devido ao tamanho reduzido dos nós sensores que a formam. Por isso, estratégias que prologuem o tempo de vida da rede, melhor utilizem seus recursos e atendam os requisitos da aplicação são interessantes. Os requisitos do problema são cobertura, conectividade e roteamento. Por cobertura entende-se que deve ser coberta a maior área de monitoramento possível. E por conectividade e roteamento entende-se que deve existir conectividade entre os nós sensores ativos e deve existir uma rota entre cada nó sensor ativo e o sorvedouro.

O Problema de Controle de Densidade tratado neste trabalho consiste em definir um subconjunto de nós sensores para ficarem ativos, dada a área de monitoramento discretizada em pontos de demanda e o conjunto de nós sensores. Este subconjunto deve minimizar o consumo de energia, garantir a cobertura da área e a conectividade entre os nós sensores.

Neste trabalho são propostas duas abordagens, uma Periódica e outra Multiperíodo. A Abordagem Periódica escolhe para cada período a melhor solução sem levar em consideração a topologia dos outros períodos e repete o processo periodicamente. A Abordagem Multiperíodo escolhe a melhor solução a partir de uma visão global da rede e dos períodos, ou seja, leva em consideração todos os períodos para escolher a solução. Ambas as abordagens foram modeladas como problemas de Programação Linear Inteira e resolvidas pelo *software* de otimização CPLEX.

A partir do modelo de Programação Linear Inteira para a Abordagem Periódica foram implementadas uma Relaxação Lagrangeana e uma Heurística Lagrangeana para tratar o PCD-RSSFs. A Relaxação Lagrangeana é um método exato que consiste em relaxar um conjunto de restrições “difíceis” e adicioná-las à função objetivo. Para cada

restrição relaxada é associado um multiplicador de lagrange cuja função é penalizar o não atendimento dessa restrição. Também foi implementada a Relaxação Linear que consiste em relaxar as restrições de integralidade, permitindo que as variáveis assumam valores reais.

Para a Abordagem Multiperíodo foi proposta a modelagem matemática e os resultados comparados com a Abordagem Periódica. Dada a maior complexidade para elaborar algoritmos com a Abordagem Multiperíodo, os demais trabalhos envolvendo-a ficaram como trabalhos futuros.

Outro algoritmo desenvolvido para tratar o PCD-RSSFs foi o Algoritmo Genético Híbrido com uma fase refinamento. O Algoritmo Genético utiliza a Abordagem Periódica para gerar a solução de todos os períodos e com esse conjunto de soluções é feita o refinamento para melhorar a solução. A fase de refinamento foi baseada nos resultados observados na Abordagem Multiperíodo.

Os resultados mostram que a Abordagem Multiperíodo obtém valores melhores, em relação ao consumo total de energia e cobertura, do que a Abordagem Periódica, principalmente com maiores quantidades de períodos. Isso acontece devido a visão global da rede e dos períodos da Abordagem Multiperíodo. Por outro lado, a Abordagem Multiperíodo resolve todos os períodos simultaneamente e por isso exige maior esforço computacional e consome mais tempo.

O Algoritmo Genético pode obter resultados ruins para alguns períodos, não garantindo cobertura de todos os pontos de demanda do período, e melhores para outros. Porém, para algumas instâncias, a solução final é próxima ao valor ótimo.

Já a Relaxação Lagrangeana e Heurística Lagrangeana foram as que obtiveram melhores resultados tanto em consumo de energia e garantia de cobertura quanto em tempo de geração da solução. O limite inferior da Relaxação Lagrangeana também foi melhor que o limite inferior gerado com a Relaxação Linear.

As heurísticas implementadas foram comparadas com dois algoritmos da literatura, o GAF e o HGAF. Em comparação com ambos, a Relaxação Lagrangeana e Heurística Lagrangeana têm a vantagem de funcionar mesmo com poucos nós sensores, enquanto que os algoritmos podem não funcionar adequadamente devido a falta de nós sensores em algumas grades. Além disso, a Relaxação Lagrangeana consome menos energia, pois ativa menos nós sensores enquanto os algoritmos ativam um número fixo de nós sensores.

7.2 Trabalhos Publicados

Os trabalhos publicados são listados abaixo em ordem cronológica do mais recente ao mais antigo:

Peñaranda, A. G., Araújo, A. R. M. & Nakamura, F. G. Deriving Lower Bounds for Energy Consumption in Wireless Sensor Networks. *In* Symposium on Computers and Communications. Split, Croácia, 2013.

Peñaranda, A. G., Araújo, A. R. M. & Nakamura, F. G. Derivando Limites Inferiores para o Consumo de Energia em Redes de Sensores Sem Fio Planas. *In* XVI CLAIO (Congresso Latino-Iberoamericano de Investigación Operativa) / XLIV SBPO (Simpósio Brasileiro de Pesquisa Operacional). Rio de Janeiro, RJ, 2012.

Araújo, A. R. M., Peñaranda, A. G. & Nakamura, F. G. Uma Abordagem de Grids Virtual para Agrupamento e Roteamento em Redes de Sensores Sem Fio com Sorvedouro Móvel. *In* XVI CLAIO (Congresso Latino-Iberoamericano de Investigación Operativa) / XLIV SBPO (Simpósio Brasileiro de Pesquisa Operacional). Rio de Janeiro, RJ, 2012.

Araújo, A. R. M., Peñaranda, A. G. & Nakamura, F. G. Avaliando o Impacto da Representação da Solução no Problema de Cobertura em Redes de Sensores Sem Fio. *In* XVI CLAIO (Congresso Latino-Iberoamericano de Investigación Operativa) / XLIV SBPO (Simpósio Brasileiro de Pesquisa Operacional). Rio de Janeiro, RJ, 2012.

Peñaranda, A. G., Araújo, A., Nakamura, F. G., & Rodrigues, R. D. F. Um algoritmo grasp para o problema de k-cobertura em redes de sensores sem fio. XLIII SBPO (Simpósio Brasileiro de Pesquisa Operacional). Ubatuba, São Paulo, 2011.

Araújo, A. R. M., Peñaranda, A. G., Nakamura, F. G., & Rodrigues, R. D. F. Heurística para o problema de cobertura em redes de sensores sem fio voltado ao rastreamento de animais. XLIII SBPO (Simpósio Brasileiro de Pesquisa Operacional). Ubatuba, São Paulo, 2011.

7.3 Trabalhos Futuros

Como trabalho futuro para a Relaxação Lagrangeana, pretende-se variar o valor de n (parâmetro que indica quantos períodos um nó sensor pode ficar ativo). Uma

alternativa é introduzir o conceito de energia residual para os nós sensores. Assim, ao invés de definir a quantidade máxima de períodos que um nó sensor pode ficar ativo, a energia residual indicaria se o nó sensor pode ficar ativo durante um período.

Para a Abordagem Multiperíodo, deseja-se desenvolver uma Relaxação Lagrangeana, visto que essa abordagem garante resultados melhores em comparação com a Abordagem Periódica.

Por fim, deseja-se executar experimentos com outros cenários, considerando redes heterogêneas, área com obstáculos e implementar simulação avaliando outras métricas como atraso e perdas de pacotes.

Referências Bibliográficas

- [Abraham et al.,] Abraham, A.; Jain, L. C. & Goldberg, R. *Evolutionary multiobjective optimization : theoretical advances and applications*.
- [Aioffi & Mateus, 2007] Aioffi, W. & Mateus, G. (2007). Otimização do controle de densidade com sorvedouros móveis em redes de sensores. *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC)*, pp. 323 – 336.
- [Akyildiz et al., 2002] Akyildiz, I.; Su, W.; Sankarasubramaniam, Y. & Cyirci, E. (2002). Wireless sensor networks: A survey. *Computer Networks*, pp. 393 – 422.
- [Andrade et al., 2010] Andrade, I.; Januario, T.; Pappa, G. & Mateus, G. (2010). An evolutionary algorithm to the density control, coverage and routing multi-period problem in wireless sensor networks. Em *Congress on Evolutionary Computation (CEC)*, pp. 1 – 8.
- [Andrade et al., 2009] Andrade, I.; Mateus, G. & Nakamura, F. (2009). A grasp heuristic to density control: Solving multi-period coverage and routing problems in wireless sensor networks. Em *Symposium on Computers and Communications*, pp. 493 – 499.
- [Bandyopadhyay & Coyle, 2003] Bandyopadhyay, S. & Coyle, E. (2003). An energy efficient hierarchical clustering algorithm for wireless sensor network. *International Conference on Computer Communications (INFOCOM)*, pp. 1713 – 1723.
- [Cheney & Goldstein, 1959] Cheney, E. & Goldstein, A. (1959). Newton’s method for convex programming and tchebycheff approximation. *Numerische Mathematik*, pp. 253–268.
- [Cheng & Yen, 2006] Cheng, Y. & Yen, L. (2006). Range-based density control for wireless sensor networks. *Communication Networks and Services Research Conference (CNSR)*, pp. 17 – 180.

- [Documentation, 2012] Documentation, I. (2012). ILOG CPLEX optimization studio information center. Disponível em: <http://pic.dhe.ibm.com/infocenter/cosinfoc/v12r4/index.jsp>. Acessado em: Maio de 2012.
- [Fisher, 2004] Fisher, M. (2004). The lagrangian relaxation method for solving integer programming problems. *Manage. Sci.*, pp. 1861--1871.
- [Goffin & Vial, 2005] Goffin, J. & Vial, J. (2005). Convex nondifferentiable optimization: an interior point perspective. *2nd School on optimization*.
- [Held et al., 1974] Held, M.; Wolfe, P. & Crowder, H. (1974). Validation of subgradient optimization. *Mathematical Programming*, pp. 62--88.
- [Inagaki & Ishihara, 2009] Inagaki, T. & Ishihara, S. (2009). Hgaf: A power saving scheme for wireless sensor networks. *JIP*, pp. 255 – 266.
- [Karp, 1972] Karp, R. M. (1972). Reducibility among combinatorial problems. *Complexity of Computer Computations*, pp. 85 – 103.
- [Loureiro et al., 2002] Loureiro, A.; Nogueira, J.; Ruiz, L.; Mini, R.; Nakamura, E. & Figueiredo, C. (2002). Rede de sensores sem fio. *Simpósio Brasileiro de Computação - Jornada de Atualização da Informática*, pp. 193 – 234.
- [Machado et al., 2010] Machado, R.; Ansari, N.; Wang, G. & Tekinay, S. (2010). Adaptive density control in heterogeneous wireless sensor networks with and without power management. *IET Communications*, pp. 758 –767.
- [Maculan & Fampa, 2006] Maculan, N. & Fampa, M. (2006). *Otimização Linear*. Editora UNB, 1a edição.
- [Menezes, 2004] Menezes, G. (2004). *Modelo e Algoritmos para a Definição da Densidade, Cobertura e Conectividade em uma Rede de Sensores sem Fio*. Dissertação de mestrado, Instituto de Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil.
- [Mhatre & Rosenberg, 2004] Mhatre, V. & Rosenberg, C. (2004). Homogeneous vs heterogeneous clustered sensor networks: A comparative study. *International Conference on Communications*, pp. 3646 – 3651.
- [Nakamura, 2010] Nakamura, F. (2010). *Algoritmos para Controle de Densidade em Redes de Sensores sem Fio*. Tese de doutorado, Instituto de Ciência da Computação, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil.

- [Nakamura et al., 2004] Nakamura, F.; Quintão, F.; Menezes, G. & Mateus, G. (2004). Planejamento dinâmico para controle de cobertura e conectividade em redes de sensores sem fio. *VI Workshop de Comunicação sem Fio e Computação Móvel*, pp. 182 – 191.
- [Nguyen et al., 2010] Nguyen, N.; Zalyubovskiy, V.; Ha, M. & Choo, H. (2010). Energy-efficient models for coverage problem using sensors with adjustable sensing ranges. Em *Wireless Communications and Networking Conference (WCNC)*, pp. 1 – 6.
- [Noronha et al., 2001] Noronha, T.; Silva, M. & Aloise, D. (2001). Uma abordagem sobre estratégias metaheurísticas. *Revista Eletrônica de Iniciação Científica (REIC) Ano I*.
- [Shang & Shi, 2005] Shang, Y. & Shi, H. (2005). Coverage and energy tradeoff in density control on sensor networks. *International Conference on Parallel and Distributed Systems (ICPADS)*, pp. 564 – 570.
- [Siqueira et al., 2006] Siqueira, I.; Figueiredo, C.; Loureiro, A.; Nogueira, J. & Ruiz, L. (2006). An integrated approach for density control and routing in wireless sensor networks. *International Parallel and Distributed Processing Symposium (IPDPS)*, pp. 104 – 104.
- [Turgut et al., 2002] Turgut, D.; Das, S.; Elmasri, R. & B., T. (2002). Optimizing clustering algorithm in mobile ad hoc networks using genetic algorithmic approach. *Global Telecommunications Conference (GLOBECOM)*, pp. 62 – 66.
- [Wolf, 1960] Wolf, P. (1960). The decomposition algorithm for linear programming. *Operations Research*, pp. 101 – 111.
- [Wu et al., 2007] Wu, X.; Cho, J.; d’Auriol, B. & Lee, S. (2007). Sleep nodes scheduling in cluster-based heterogeneous sensor networks using ahp. *international conference on Embedded Software and Systems*, pp. 437 – 444.
- [Xu et al., 2001] Xu, Y.; Heidemann, J. & Estrin, D. (2001). Geography-informed energy conservation for ad hoc routing. Em *International Conference on Mobile Computing and Networking (MOBICOM)*, pp. 70 – 84.
- [Ye et al., 2002] Ye, F.; Zhong, G.; Lu, S. & Zhang, L. (2002). Peas: A robust energy conserving protocol for long-lived sensor networks. *International Conference on Networks Protocols (ICNP)*, pp. 200 – 201.

[Zang & Hou, 2005] Zang, H. & Hou, J. (2005). Maintaining sensing coverage and connectivity in large sensor networks. *Ad Hoc & Sensor Wireless Networks*, pp. 89 – 124.