



UNIVERSIDADE FEDERAL DO TOCANTINS
CÂMPUS UNIVERSITÁRIO DE PALMAS
CURSO DE CIÊNCIA DA COMPUTAÇÃO

MODELO DE POSICIONAMENTO DE NÓS SENSORES ATRAVÉS DA
UTILIZAÇÃO DE UM ALGORITMO GENÉTICO SATISFAZENDO AS
RESTRICÇÕES DE K -COBERTURA E M -CONNECTIVIDADE

MATHEUS MACHADO VILARINO

PALMAS (TO)

2018

MATHEUS MACHADO VILARINO

MODELO DE POSICIONAMENTO DE NÓS SENSORES ATRAVÉS DA
UTILIZAÇÃO DE UM ALGORITMO GENÉTICO SATISFAZENDO AS
RESTRICÇÕES DE K -COBERTURA E M -CONNECTIVIDADE

Trabalho de Conclusão de Curso II apresentado
à Universidade Federal do Tocantins para
obtenção do título de Bacharel em Ciência da
Computação, sob a orientação do(a) Prof.(a)
Dr. Rafael Lima de Carvalho.

Orientador: Dr. Rafael Lima de Carvalho

PALMAS (TO)

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal do Tocantins

V697m Vilarino, Matheus Machado.
Modelo de posicionamento de nós sensores através da utilização de um algoritmo genético satisfazendo as restrições de k-Cobertura e m-Conectividade. / Matheus Machado Vilarino. – Palmas, TO, 2018.
56 f.

Monografia Graduação - Universidade Federal do Tocantins –
Câmpus Universitário de Palmas - Curso de Ciências da Computação,
2018.
Orientador: Rafael Lima de Carvalho

1. Algoritmo Genético. 2. Redes de Sensores Sem Fio. 3. K -
Cobertura. 4. M - Conectividade. I. Título

CDD 004

TODOS OS DIREITOS RESERVADOS – A reprodução total ou parcial, de qualquer forma ou por qualquer meio deste documento é autorizado desde que citada a fonte. A violação dos direitos do autor (Lei nº 9.610/98) é crime estabelecido pelo artigo 184 do Código Penal.

Elaborado pelo sistema de geração automática de ficha catalográfica da UFT com os dados fornecidos pelo(a) autor(a).

MATHEUS MACHADO VILARINO

MODELO DE POSICIONAMENTO DE NÓS SENSORES ATRAVÉS DA
UTILIZAÇÃO DE UM ALGORITMO GENÉTICO SATISFAZENDO AS
RESTRIÇÕES DE K -COBERTURA E M -CONNECTIVIDADE

Trabalho de Conclusão de Curso II apresentado à UFT – Universidade Federal do Tocantins – Câmpus Universitário de Palmas, Curso de Ciência da Computação foi avaliado para a obtenção do título de Bacharel e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Data de aprovação: 7 / 6 / 2018

Banca Examinadora:

Prof. Dr. Rafael Lima de Carvalho

Prof. Dr. Warley Gramacho da Silva

Prof. Me. Tiago da Silva Almeida

*A todos aqueles que de alguma
forma estiveram e estão
próximos de mim, fazendo esta
vida valer cada vez mais a pena.*

AGRADECIMENTOS

Agradeço ao meu orientador, professor Dr. Rafael Lima de Carvalho, por aturar todos os meus atrasos na entrega das pequenas porções desta monografia ao longo do semestre e por me mostrar o caminho que eu precisava seguir para concluir este trabalho.

Agradeço aos meu pais, pela força, apoio e incentivo para a minha formação.

Agradeço à Aline e Camila, por revisar meu texto após uma longa jornada de insistência para que elas fizessem tal.

E agradeço também Odilo, por me perturbar incessantemente para que eu terminasse de escrever este trabalho, mesmo nos finais de semana e feriados.

RESUMO

O problema de cobertura em redes de sensores sem fio consiste em: dados n alvos (ou pontos de observação) encontrar um esquema de cobertura de forma a contemplar os n pontos, utilizando-se o menor número de nós sensores possível. Alguns critérios de redundância podem ser incorporados neste problema, tais como o grau de conectividade de cada nó sensor (m - conectividade) e o grau de cobertura de cada alvo (k - cobertura), dentre outros. Neste trabalho, são abordados os problemas da cobertura de nós sensores com as restrições de k -cobertura e m -conectividade, simultaneamente. Por ser um problema NP-Completo, é proposto a utilização de um algoritmo genético específico para o problema de posicionamento de sensores, com a aplicação de uma modificação da função de *crossover* baseado no Algoritmo Genético Flexível, utilização do Diagrama de Voronoi e uma função de perturbação dos nós sensores para realizar um pré-processamento no posicionamento dos nós. Os resultados experimentais mostram que o algoritmo proposto obteve um bom desempenho com relação ao número de nós sensores selecionados, escolhendo a menor quantidade de nós sensores e mantendo a k - cobertura e m - conectividade da rede, após aplicadas as modificações descritas.

Palavra-chave: k -Cobertura. m -Conectividade. Algoritmo Genético. Redes de Sensores Sem Fio.

ABSTRACT

The coverage problem in wireless sensor networks consists of: given n targets (or observation points) find a coverage scheme in order to contemplate the n points, using the least number of sensor nodes. Some redundancy criteria can be incorporated in this problem, such as the degree of connectivity of each sensor node (m - connectivity) and the degree of coverage of each target (k - coverage), among others. In this work, the problems of covering sensor nodes with the k -coverage and m -connectivity constraints are addressed simultaneously. Because it is a NP-Complete problem, it is proposed to use a specific genetic algorithm for the sensor positioning problem, with the application of a modification of the crossover function based on the Flexible Genetic Algorithm and use of the Voronoi Diagram and a function of perturbation of the sensor nodes to perform a preprocessing in the positioning of the nodes. The experimental results show that the proposed algorithm obtained a good performance in relation to the number of selected sensor nodes, choosing the least amount of sensor nodes and maintaining the k - coverage and m - connectivity of the network, after applying the modifications described.

Keywords: k -Coverage. m -Connectivity. Genetic Algorithm. Wireless Sensor Network.

LISTA DE FIGURAS

Figura 1 – Exemplo de rede 2-coberta e 1-conectada	14
Figura 2 – Exemplo de estrutura básica de uma RSSF que transmite seus dados, processa-os e os envia para uma base remota via internet.	18
Figura 3 – Classificação dos problemas de cobertura	24
Figura 4 – Cobertura de região (área).	27
Figura 5 – Cobertura de pontos.	28
Figura 6 – Cobertura de barreira.	29
Figura 7 – Esquema de um Algoritmo Genético básico.	32
Figura 8 – Exemplo de codificação binária de um cromossomo.	34
Figura 9 – Exemplo de roleta utilizada para seleção dos melhores indivíduos. . .	37
Figura 10 – Exemplo de mutação flip-bit único.	39
Figura 11 – Exemplo das células formadas no Diagrama de Voronoi.	44
Figura 12 – Exemplo da codificação dos cromossomos utilizada no projeto.	46
Figura 13 – Crossover de Permuta de Sub-área.	50
Figura 14 – Variância do grau de precisão da função de avaliação (<i>fitness</i>) durante a evolução (com restrições de $k = 1$ e $m = 1$).	54
Figura 15 – Melhor indivíduo encontrado ao final da evolução (com valores de $k = 1$ e $m = 1$).	54
Figura 16 – Comparação da média dos resultados do número de nós sensores selecionados.	55

LISTA DE TABELAS

Tabela 1 – Relação dos valores dos pesos testados e o comportamento dos objetivos em porcentagem	52
Tabela 2 – Valores de variância das execuções	53

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Objetivos	15
1.2	Organização da Monografia	15
2	REDES DE SENSORES SEM FIO (RSSFS)	17
2.1	Características/Objetivos das RSSFs	19
2.2	Aplicações	20
3	PROBLEMAS DE COBERTURA	23
3.1	Fatores que afetam a cobertura de redes	23
3.2	Classificação dos problemas de Cobertura	24
4	ALGORITMOS GENÉTICOS	30
4.1	Características dos Algoritmos Genéticos	31
4.2	Estrutura de um Algoritmo Genético Básico	32
4.3	Operadores Genéticos	33
5	METODOLOGIA	41
5.1	O Objeto de Estudo	41
5.2	O Algoritmo Genético Utilizado	45
5.3	Implementação do Algoritmo	51
5.4	Comparação dos Resultados	51
6	RESULTADOS E DISCUSSÕES	52
7	CONCLUSÃO	57
	REFERÊNCIAS	58

1 INTRODUÇÃO

As redes sem fio têm, cada vez mais, chamado a atenção de indústrias, instituições de pesquisa e da população em geral devido às suas possibilidades de aplicações, que vão desde o simples roteamento de internet doméstica, até a realização de transmissão de dados cruciais numa expedição de exploração à Marte realizada pela NASA. Outra aplicação desse sistema é o que chama-se de Redes de Sensores Sem Fio (ou *Wireless Sensor Networks*), que consistem em uma rede sem fio com sensores autônomos que são distribuídos em uma determinada área ou região para monitorar as condições físicas ou ambientais da mesma.

Segundo Lewis (2004), as Redes de Sensores Sem Fio (RSSF) são as principais responsáveis por coletar e reunir informações necessárias de determinados ambientes, como edifícios, indústrias, casas, navios, monitoramento de tráfego, vigilância em campo de batalha, monitoramento de incêndio, dentre outros. Como esses sensores são implantados, geralmente, em ambientes hostis, remotos ou inacessíveis e que, tais sensores são espalhados sem seguir um padrão específico, eles acabam gerando um obstáculo conhecido como problema de cobertura (JUNBIN; MING; XIAOYAN, 2014).

De acordo com Junbin, Ming e Xiaoyan (2014), o problema de cobertura é de grande relevância atualmente nas RSSFs, onde muitos trabalhos foram dedicados à estudar e propor maneiras de resolver problemas dedicados à cobertura dessas redes. Isso inclui o monitoramento, a conservação de energia dos sensores, o prolongamento do tempo de vida da rede garantindo a cobertura de áreas ou alvos e a relação de *cobertura x conectividade*, ao implantar uma rede de sensores.

Os problemas de cobertura fazem parte da classe NP-completude (KE; LIU; TSAI, 2007; KO, 2011; YU et al., 2016; JIAN et al., 2017), muitos algoritmos foram desenvolvidos para solucionar os problemas de cobertura sendo que estes, geralmente, são orientados naquilo que se deseja cobrir (sejam áreas ou pontos), no mecanismo de implantação de sensores (estocástico ou determinístico) ou outras propriedades (como menor consumo de energia e conectividade de rede) (JUNBIN; MING; XIAOYAN, 2014).

Ainda segundo Junbin, Ming e Xiaoyan (2014), o problema de cobertura de área é o problema mais conhecido e divulgado, sendo assim o mais amplamente estudado. O objetivo da cobertura de área é cobrir ou monitorar uma área ou região, sob a restrição de que qualquer nó sensor possa ser coberto na área monitorada. A cobertura de área visa um modo de planejar/escalar os nós sensores na rede, de modo a maximizar o tempo de vida da rede.

O problema de cobertura de pontos visa cobrir um conjunto de pontos, também chamados de alvos, sob a restrição de que todos os pontos devem ser cobertos na área

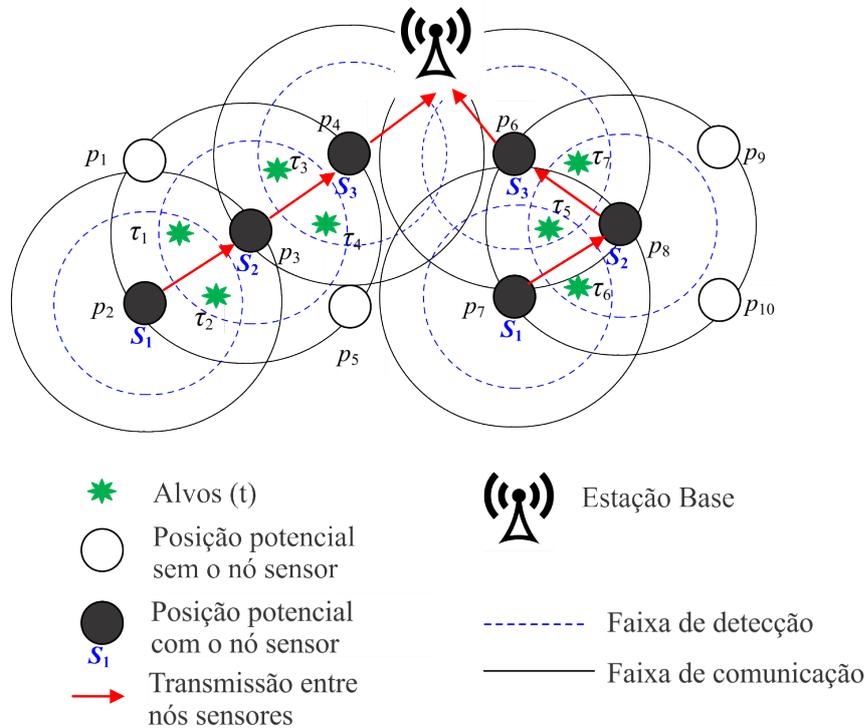
monitorada. Assim como a cobertura de área, o problema de cobertura de pontos visa um modo de planejar o posicionamento dos nós sensores de maneira à maximizar o tempo de vida da rede.

Outro problema comum é a cobertura de barreira, cujo objetivo é detectar as chances de um objeto em movimento ser encontrado ao cruzar a região de implantação de RSSFs. Esse problema tem como objetivo minimizar a probabilidade de ocorrência de uma penetração não detectada através da barreira (rede de sensores).

Com base nas considerações feitas, torna-se plausível dizer que as problemáticas de cobertura mencionadas são extremamente relevantes, pois, elas mostram o quão bem os sensores percebem o ambiente ao qual estão inseridos, proporcionando assim uma medida confiável a respeito da qualidade de serviço (*Quality of Service - QoS*) das redes de sensores sem fio.

Contudo, é um desafio manter a conectividade destes sensores, pois a sua faixa de transmissão é limitada assim como sua fonte de energia após certo tempo de operação, ainda deve-se considerar as falhas de hardware (tais como erro da central de processamento ou do transmissor, etc) e danos causados por eventos externos. Tendo esses pontos em vista, percebe-se o quão importante é garantir a cobertura dos alvos e a conectividade dos nós sensores de modo que a rede continue operacional caso uma certa quantidade de nós venham a falhar (GUPTA; KUILA; JANA, 2016).

Figura 1 – Exemplo de rede 2-coberta e 1-conectada, adaptado de (GUPTA; KUILA; JANA, 2016).



Caracterizando o problema abordado neste trabalho: dado um conjunto de alvos e um conjunto de posições em potencial, pré-fixadas, deve-se selecionar o menor número de posições potenciais para posicionar os nós sensores de tal forma que essa configuração cumpra a k -cobertura dos alvos e a m -conectividade dos nós sensores. Um alvo é classificado como coberto se o mesmo está dentro do alcance de comunicação de um nó sensor e o nó sensor é capaz de comunicar-se com a estação base diretamente ou por intermédio de outros nós sensores. Para exemplificar esse problema, uma rede com 10 posições em potencial para implantação dos nós sensores, $\{p_1, p_2, p_3, \dots, p_{10}\}$ e sete alvos $\{\tau_1, \tau_2, \dots, \tau_7\}$ é apresentada na Figura 1 onde os nós sensores estão posicionados/implantados em 6 posições das 10 posições apresentadas. Como pode ser observado, o alvo τ_2 na Figura está coberto porque está dentro da faixa de comunicação do nó sensor posicionado no ponto p_2 e é capaz de comunicar-se com a estação base através dos nós sensores posicionados nos pontos p_3 e p_4 . Em termos gerais, k -cobertura quer dizer que cada alvo deve ser coberto por pelo menos k sensores, ou seja, o alvo continuará coberto mesmo que $k - 1$ nós sensores falhem. O mesmo se aplica à m -conectividade, onde cada nó sensor está diretamente conectado com outros m nós sensores, isto é, um nó sensor continuará conectado mesmo que $m - 1$ nós sensores falhem/desconectem (GUPTA; KUILA; JANA, 2016).

Este trabalho, verifica o desempenho do método aplicado no trabalho estudado por

Gupta, Kuila e Jana (2016), adaptando o algoritmo genético utilizado por uma variante mais moderna e robusta, apresentado em Zhang et al. (2017), obedecendo as restrições de k -cobertura e m -conectividade estabelecidas.

1.1 Objetivos

Objetivo Geral

Utilização de algoritmo genético para obtenção da melhor configuração de uma rede de sensores sem fios, levando em consideração os alvos a serem detectados, de modo a prover a k - cobertura dos alvos e a m - conectividade dos nós sensores, sendo $\forall k, 1 \leq k \leq n$, e, $\forall m, 1 \leq m \leq p$, com n e p sendo números inteiros maiores que 0 (zero). Além disso, selecionar a menor quantidade possível de nós sensores implantados, satisfazendo as restrições anteriores.

Objetivos Específicos

Os objetivos específicos do presente projeto são:

1. Estudar métricas usadas para implantação de uma rede de sensores sem fio;
2. Definir um algoritmo, usando técnicas de IA (em especial algoritmo genético), que sejam capazes de proporcionar a k - cobertura e a m - conectividade dos nós de uma rede de sensores sem fio;
3. Adaptação do algoritmo genético utilizado para um algoritmo moderno e atual abordado por Zhang et al. (2017), chamado de Algoritmo Genético Flexível;
4. Realizar testes e comparar com outros modelos de posicionamento.

1.2 Organização da Monografia

No Capítulo 2 é apresentado o contexto do problema, neste caso especificamente as redes de sensores sem fio, descrevendo tanto as suas características, assim como, as possíveis aplicações destas redes. Posteriormente, no Capítulo 3, são introduzidos alguns problemas e suas classificações, no que tange a cobertura de rede, bem como modelos de implantação utilizados para mitigar este tipo de problema. Os algoritmos genéticos são abordados no Capítulo 4 em um contexto elucidativo, apresentando a história, as características e a estrutura básica utilizada em todo algoritmo genético. Por conseguinte, no Capítulo 5, é exposta a metodologia empregada neste trabalho, sendo este, um detalhamento do passo à passo que será empregado para alcançar os objetivos explicitados anteriormente. Na sequência, o Capítulo 6 apresenta os resultados alcançados bem como uma discussão acerca de tais resultados nesta monografia, nele é descrito os passos tomados

para alcançar tais resultados e, além disso, são feitas algumas observações/ponderações a respeito da implicação dos resultados alcançados.

2 REDES DE SENSORES SEM FIO (RSSFS)

É possível coletar dados de todos os fenômenos que ocorrem na natureza. Podem ser coletados dados de suas características, interações com o meio e efeitos dessas interações. Estes dados são captados com a utilização de uma estrutura de rede composta por nós sensores sem fios, também conhecida como Redes de Sensores Sem Fio (RSSFs), tais dados podem ser então processados, armazenados e posteriormente usados para os mais variados propósitos.

Estas redes de sensores sem fio são compostas por um grande número de nós sensores, que são densamente implantados dentro ou próximos à algum alvo ou área. A posição de seus sensores não precisa ser projetada ou pré-determinada, assim permitindo a implantação aleatória dos nós sensores em terrenos inacessíveis ou em casos de operações de socorro devido a ocorrência de desastres. Além disso, as redes de sensores possuem um foco cooperativo, onde os nós sensores usam suas habilidades de processamento para realizar cálculos simples e transmitir apenas os dados necessários e parcialmente processados para os próximos nós (AKYILDIZ; SU; CAYIRCI, 2002).

Normalmente, os nós sensores são compostos por 4 componentes básicos, são eles:

- Unidade de Detecção;
- Unidade de Processamento;
- Unidade transceptora¹;
- Unidade de Energia.

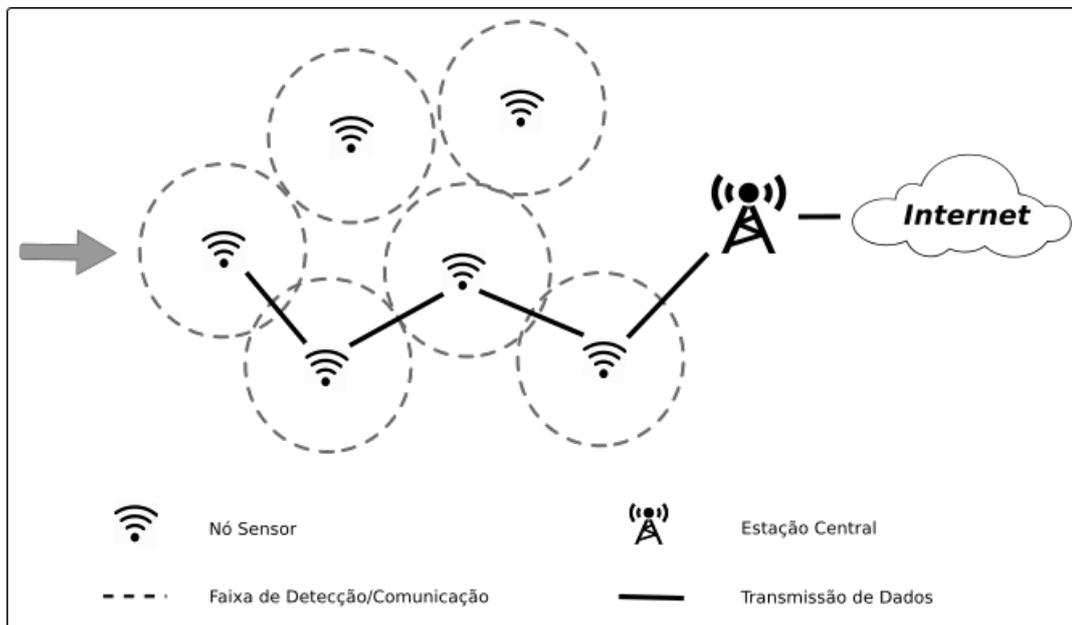
As **unidades de detecção** geralmente são compostas por duas subunidades distintas, sendo estes os sensores e os conversores analógicos-digitais (CADs). Os sinais analógicos produzidos pelos sensores com base no fenômeno observado são convertidos em sinais digitais pelo CAD, e depois são alimentados na unidade de processamento. A **unidade de processamento**, que geralmente está associada a uma pequena unidade de armazenamento, gerencia os procedimentos que fazem o nó sensor colaborar com os outros nós para realizar as tarefas de detecção atribuídas. A **unidade transceptora** é responsável por conectar o nó à rede. E por fim, um dos componentes mais importantes de um nó sensor é a sua **unidade de energia**, ela é responsável por manter todo o nó sensor em funcionamento distribuindo energia para onde for necessário, essas unidades de energia podem ser auxiliadas/mantidas por uma unidade de geração (ou extração) de energia, como células solares, por exemplo (AKYILDIZ; SU; CAYIRCI, 2002).

¹Um transceptor é um dispositivo que combina um transmissor e um receptor utilizando componentes de circuito comuns para ambas funções num só aparelho

Cada nó sensor é modificado de acordo com o ambiente em que é inserido, ou seja, se um nó sensor for implantado sob o solo então ele terá transceptores muito potentes de forma a superar o bloqueio que a camada de solo ocasiona, assim como se o nó sensor for implantado em ambiente marítimo o mesmo deverá receber algum revestimento que suporte pressão da água, proteja contra umidade, seja à prova d'água, etc (RASHID; REHMANI, 2015).

As RSSFs utilizam os nós sensores para detectar mudanças nos arredores dos ambientes e retransmitir os dados entre si até que estes dados cheguem à uma estação central remota. Em vista disso, esta estação central pode ter a mesma configuração dos nós sensores regulares ou pode ser um dispositivo especial com uma alta capacidade de processamento de dados, que por sua vez conecta a rede de sensores sem fio com outras redes externas (a internet, por exemplo) ou pode ainda ser apenas uma estação que faz uma ligação (via internet) e transmite os dados coletados para um centro de monitoramento/-controle remoto (RASHID; REHMANI, 2015).

Figura 2 – Exemplo de estrutura básica de uma RSSF que transmite seus dados, processa-os e os envia para uma base remota via internet.



A Figura 2 demonstra uma RSSF simples com 6 nós sensores e uma estação central. O nó sensor indicado pela seta marca qual nó sensor detectou uma mudança, a partir deste momento o nó que detectou a mudança começa a transmitir dados sobre esta detecção para os próximos nós, então os nós adjacentes recebem esses dados e continuam retransmitindo-os até que estes dados atinjam o nó central. Ao alcançar o nó central os dados são processados e transmitidos via internet para uma estação de controle remoto.

2.1 Características/Objetivos das RSSFs

As RSSFs são projetadas para permitir um grande tráfego e processamento de informações, tais como detecção, classificação e rastreamento (MANSIAHIA, 2016), suas principais características são o baixo custo, energeticamente eficiente, poder computacional, eficácia de comunicação, segurança e privacidade, tolerância à falhas, escalabilidade e comunicação multi-saltos (AHMED et al., 2012).

Baixo Custo: Nas RSSFs, normalmente, centenas ou milhares de nós sensores são implantados para realizar as medições necessárias. Assim, para reduzir o custo total da rede, o custo do nó sensor deve ser mantido tão baixo quanto possível.

Energeticamente Eficiente: A energia nas RSSFs é usada para os mais diferentes fins, como computação, comunicação e armazenamento de dados. O nó sensor, no geral, consome mais energia comparada a qualquer outro componente para comunicação. Se eles ficarem sem energia, eles se tornam inválidos porque não se tem nenhuma opção para recarregar-los. Assim, os protocolos e desenvolvimento de algoritmos devem considerar o consumo de energia na fase de projeto.

Poder Computacional: Normalmente os nós tem capacidades computacionais limitadas, pois, o custo e a energia precisam ser considerados.

Eficácia de Comunicação: As redes geralmente se comunicam por meio de ondas de rádio através de um canal sem fio. O canal de comunicação pode ser bidirecional ou unidirecional. Em ambientes desatendidos e desfavoráveis, é difícil executar as RSSFs sem que os mesmos apresentem algum obstáculo. Assim, o hardware e o software para comunicação devem levar em consideração a robustez, segurança e resistência.

Segurança e Privacidade: Cada nó do sensor deve ter mecanismos de segurança suficientes para evitar acesso não autorizado, ataques e danos não intencionais das informações dentro do nó do sensor. Além disso, mecanismos de privacidade adicionais também devem ser incluídos.

Tolerância à Falhas e Escalabilidade: Em geral, as RSSFs são redes dinâmicas. O nó sensor pode vir a falhar por esgotamento da bateria ou outras circunstâncias, o canal de comunicação pode ser interrompido, etc.. Com isso, um nó sensor extra pode ser adicionado à rede resultando em mudanças frequentes na topologia da rede. Assim, os nós devem ser incorporados com a função de reconfiguração, autoajuste.

Comunicação Multi-Saltos: Devido ao grande número de nós sensores que são implantados no RSSF, a maneira mais viável de se comunicar com a estação base é através da ajuda de nós intermediários para roteamento. Se algum nó precisa se comunicar com o outro nó ou com a estação base que está além da sua frequência de rádio (faixa de detecção), deve-se “saltar” por nós intermediários, utilizando o caminho de roteamento até alcançar o destino.

Como observa-se nas características acima explicitadas, o armazenamento de in-

formações, a energia disponível para a rede e o raio de comunicação dos nós sensores são limitados. Este limite de recursos nos leva a planejar diferentes procedimentos/estratégias para uma melhor configuração da rede de modo a tirar o máximo proveito dos recursos disponíveis, sem perder qualidade do serviço (QoS) oferecido e maximizando o tempo de vida da rede.

2.2 Aplicações

O grande sucesso das RSSFs é, em grande parte, atribuído à sua ampla gama de possibilidades de aplicações. Essas aplicações utilizam das mais variadas formas e abordagens para coletar informações da maneira mais precisa e econômica possível (MANSHAHIA, 2016). A seguir são detalhadas algumas das aplicações possíveis com as RSSFs.

Monitoramento de Tráfego Urbano: A quantidade de veículos circulando nas ruas vem aumentando cada dia mais em razão do crescimento populacional atual, com isso, os engarrafamentos são cada vez mais frequentes mesmo nas pequenas cidades. Estes engarrafamentos acarretam problemas econômicos, prendendo as pessoas e diminuindo o fluxo de mercadorias e bens de serviço, assim, diminuindo a produtividade dos negócios. Outro problema ocasionado pelos engarrafamentos é a alta chance de acidentes devido às paradas e arrancadas repentinas além, também, do estresse ocasionado pela lentidão do trânsito (RASHID; REHMANI, 2015).

Uma das abordagens do monitoramento de tráfego consiste em implantar sensores em entrepostos e/ou nos carros, assim os sensores juntam dados relativos à posição, velocidade, clima, gerenciamento de estacionamento, fluxo de tráfego em tempo real, condições das estradas, monitoramento de atividades criminais, etc..

Aplicações de Auxílio à Estacionamento: As pessoas tem enfrentado cada vez mais problemas para encontrar vagas de estacionamento devido aos congestionamentos e ao crescente número de veículos nas cidades. Rashid e Rehmani (2015) afirmam que o ato de andar (no veículo) procurando uma vaga para estacionar contribui com cerca de 8% no aumento do tráfego das cidades, além também do gasto de tempo que se tem durante essa procura. Algumas cidades tentam sanar esse problema cobrando taxas de estacionamento, essa solução pode influenciar na diminuição da poluição emitida pelos carros enquanto buscam estacionamento além de desafogar as ruas com carros que só estão à procura de estacionamento.

As RSSFs trazem para este problema informações em tempo real a respeito de vagas que se encontram livres ou ocupadas, auxiliando e otimizando o tempo do motorista que pode então saber exatamente onde estacionar seu carro. Além de comodidade, as RSSFs auxiliam também na segurança dos veículos estacionados, monitorando atividades suspeitas e reportando informações importantes para os órgãos públicos de segurança.

Monitoramento de Poluição Aérea: O avanço das indústrias trouxe inúmeros produtos que facilitam a nossa vida cotidianamente, porém, as mesmas indústrias, no geral, poluem o meio no qual vivemos. Uma forma de poluição facilmente notada, principalmente nas grandes cidades ou em áreas industriais, é a poluição aérea, onde as fábricas soltam gases emitidos durante sua produção, sendo que estes gases são nocivos para a saúde humana.

As RSSFs são implantadas em muitas cidades com elevado grau de poluição aérea para observar-se a concentração dos gases no meio da cidade. As redes coletam os dados dos gases e de ambiente e a partir disso é possível fazer previsões da movimentação destes gases e promover planos de contingência ou evacuação, caso seja necessário. Como essas redes usam *links* sem fio em vez de instalações com fio elas acabam adicionando mobilidade para examinar leituras em várias áreas diferentes (MANSIAHIA, 2016).

Vigilância: Violência urbana e terrorismo são pautas recorrentes em estudos hoje em dia. A cada dia que passa, tem-se um número cada vez maior de vidas perdidas além da perda de bens (propriedades), causado pelo crescente aumento das práticas maliciosas ao redor do mundo. Paralelamente, o mercado ilegal realiza a circulação de itens ilegais de forma indiscriminada e sem a fiscalização necessária, alimentando as redes criminosas que provocam esses eventos trágicos (RASHID; REHMANI, 2015).

O monitoramento de vídeo é o método mais convencional de vigilância, onde as câmeras são fixadas em pontos estratégicos de modo a capturar imagens de possíveis atividades criminosas. O problema é a complexidade de fazer uma interpretação do que é apresentado nos vídeos de modo automático, necessitando assim sempre do fator humano (um vigilante) para fazer a identificação do objeto de interesse.

Para este problema, a RSSF apresenta-se como uma solução efetiva e de baixo custo financeiro. Ela proporciona um serviço de vigilância contínuo de longo prazo, usando uma rede entrelaçada de dispositivos de monitoramento (nós sensores) que retransmitem as informações entre si e para uma estação base, abrangendo, de modo geral, uma visão global da situação (RASHID; REHMANI, 2015).

Ainda segundo Rashid e Rehmani (2015), um exemplo do uso desta rede é a implantação de sensores móveis em táxis ou ônibus programados para detectar radiação nuclear em áreas urbanas. Qualquer pessoa que entrar em um táxi, ônibus, etc., terão seus pertences analisados pelos sensores de detecção de radiação e os resultados enviados para a estação remota central.

Monitoramento da Qualidade da Água: O monitoramento da qualidade da água envolve a análise das propriedades da água em barragens, rios, lago, oceanos, reservas de água subterrânea, etc.. A utilização de uma grande quantidade de sensores sem fio distribuídos permite um monitoramento mais eficiente e próximo da realidade e da produção de um mapa da qualidade da água (MANSIAHIA, 2016).

Monitoramento da Saúde: A saúde é um direito fundamental para qualquer nação,

porém, ela nem sempre contempla toda a população de determinado país, seja por falta de pessoal especializado, falta de estrutura adequada ou até mesmo dificuldade de acesso ao paciente. Com as salas de emergência sempre lotadas, falta de médicos e tráfego lento e congestionado para chegar ao hospital, acaba sendo um desperdício de tempo e de saúde para o paciente se deslocar de sua casa até o hospital. Portanto, proporcionar uma melhora dos recursos de saúde é uma necessidade fundamental para os pacientes.

Uma das soluções dessa sobrecarga de paciente em salas de emergência, segundo Rashid e Rehmani (2015), seria a assistência médica remota, sem a necessidade da presença física do médico. Esse acesso à saúde remota em áreas rurais já é uma realidade em países como a China e a Índia. O papel das redes de sensores sem fio entra no monitoramento dos sinais vitais do paciente, batimentos cardíacos, pulsação, nível de oxigenação do sangue, temperatura corporal, etc., que são continuamente transmitidos para uma base de dados acessível pelo médico do paciente para que o mesmo possa realizar um diagnóstico o mais correto possível com mais informações até do que um médico convencional (presente fisicamente) poderia ter acesso.

3 PROBLEMAS DE COBERTURA

A questão da cobertura pode ser vista como um problema de decisão, cujo objetivo é determinar se cada ponto ou região na área de interesse está coberto (dentro do raio de transmissão dos sensores que formam a rede) por pelo menos k -sensores, sendo k um valor inteiro pré-definido. A resposta desse problema mostra o quão bem um alvo é monitorado ou rastreado pelos sensores (Qualidade de Serviço).

Pensado nas RSSFs é importante estar atento à qualidade da *conectividade*, sendo este um quesito extremamente importante, pois, trata diretamente da comunicação entre os nós e o fluxo de dados na rede. Por definição, uma RSSF é dita *conectada* se cada nó pode, diretamente ou indiretamente, se conectar com outros nós. O objetivo de uma rede conectada é encontrar um subconjunto mínimo de sensores ativos cujos dados extraídos do ambiente possam alcançar os nós base (nós centrais). Nas RSSFs, a conectividade ainda atua como uma propriedade fundamental tanto representando o *status* da rede, apresentando a densidade de nós e os intervalos de detecção e comunicação, como também auxiliando no desenvolvimento de planos de trabalho como padrões de implantação e algoritmos de processamento eficientes para a rede (GUPTA; KUMAR; JAIN, 2016).

3.1 Fatores que afetam a cobertura de redes

Os principais fatores que afetam a cobertura de rede segundo Gupta, Kumar e Jain (2016) são:

Área de Detecção - É onde um sensor pode detectar se um objeto ou alvo está dentro de sua faixa de detecção de forma determinística (um sensor pode detectar um objeto enquanto o objeto está dentro de seu intervalo de detecção) ou a probabilidade de detecção (é uma função da distância entre o objeto e o sensor) dependendo do seu modelo de detecção. Via de regra, supõe-se que os sensores tenham o mesmo intervalo. Por exemplo, a área de detecção é considerada isotrópica (caracteriza as substâncias/objetos que possuem as mesmas propriedades físicas independentemente da direção considerada, por exemplo, uma área circular em 2-D). Além disso, existem vários mecanismos que são extensíveis a qualquer área de detecção convexa, não uniforme ou áreas de detecção irregular.

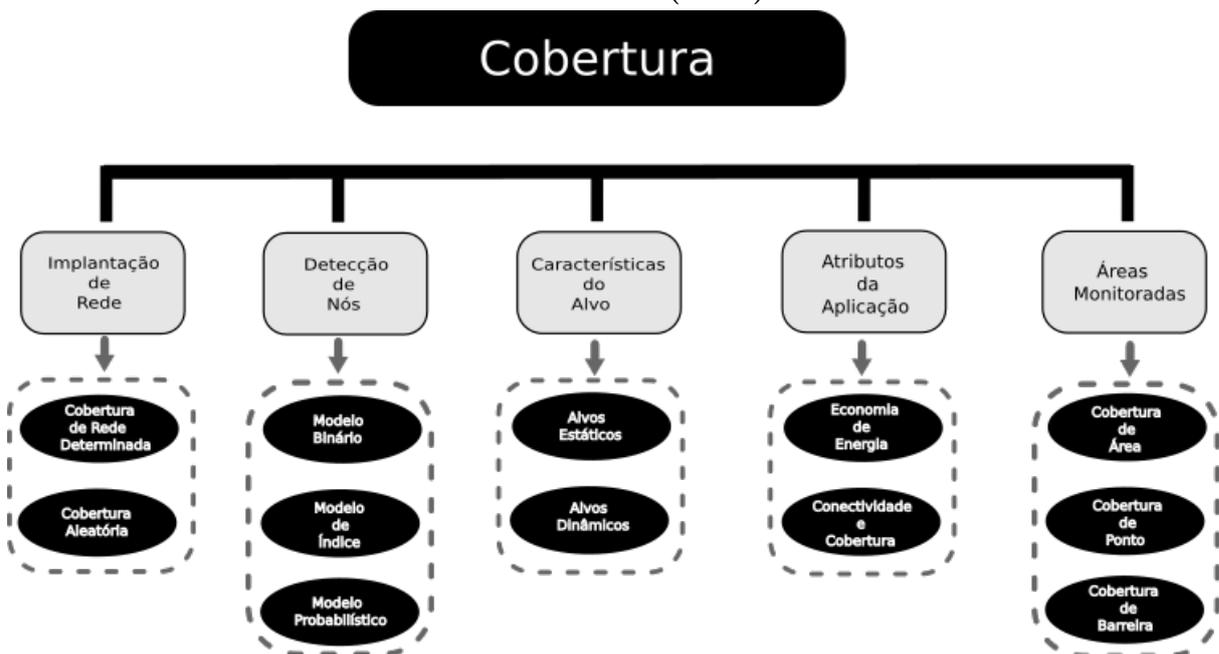
Intervalos de Comunicação - Diferentemente da maioria dos sensores com intervalo de transmissão invariável, o transceptor de rádio de alguns sensores é capaz de alterar o seu poder de transmissão de maneira contínua para alcançar diferentes intervalos de comunicação. Na prática, os intervalos de comunicação reais também podem ser afetados por muitos fatores externos, como a altura do sensor e objetos que o circulam, como paredes, limitando seus intervalos de comunicação.

Mobilidades do Sensor - O desempenho da cobertura da rede de sensores estacionários (parados) pode ser determinado pela configuração inicial da rede e permanecer inalterável ao longo do tempo após a implantação. Entretanto, no caso dos sensores móveis, a rede pode melhorar ou manter o desempenho da cobertura pela mobilidade do sensor. É extremamente valioso nas situações em que os mecanismos de implantação ou a manutenção da cobertura falham. A cobertura da rede móvel depende não apenas das configurações iniciais, mas também da movimentação dos sensores em função do tempo.

3.2 Classificação dos problemas de Cobertura

Geralmente, existem muitos critérios diferentes (fatores) que podem afetar o desempenho de cobertura das RSSFs, como apresentado na Figura 3. Embora seja inviável cobrir todos os fatores possíveis, a seguir é feita uma revisão de uma ampla gama destes fatores que têm um efeito significativo no desempenho da cobertura das redes.

Figura 3 – Classificação dos problemas de cobertura, adaptado de Gupta, Kuila e Jana (2016).



Implantação de Rede

A implantação de rede contempla 2 (duas) modalidades de distribuição dos nós sensores, sendo elas, a modalidade determinística e a modalidade aleatória:

Cobertura Determinística de Rede: Estas redes, no geral, são baseadas em alguns parâmetros pré-definidos tais como o formato da rede, posição de cada sensor, etc.. Nessa cobertura, os sensores são implantados de uma maneira pré-definida, porém, em muitos

casos é quase impossível implantar os sensores de maneira determinística. A atribuição de nós sensores é muito mais fácil em uma cobertura padronizada do que seria num modelo aleatório. Um obstáculo tipicamente estudado de cobertura de uma rede determinada é o problema da galeria de arte (*art gallery problem*). Neste problema, a sala a ser monitorada é considerada como um polígono e os sensores (aqui chamados de “guardas”) são representados por pontos na sala. O objetivo é garantir que cada parte da sala seja monitorado por pelo menos um dos guardas (nós sensores). Como a posição dos guardas é inicialmente especificada de tal maneira que seja possível garantir o objetivo, o problema acaba se qualificando como um problema de cobertura determinada (GUPTA; KUMAR; JAIN, 2016).

Cobertura Aleatória: Ao contrário das cobertura determinística, esta cobertura não apresenta nenhuma informação pré-definida a respeito da localização dos sensores e formato da rede. A topologia e a formação da rede mudam de acordo com o tempo. Um exemplo o campo de batalha, onde um alvo pode mover sua localização em função do tempo e mudanças topológicas. Na cobertura aleatória, caso os nós sejam do tipo estacionários (imóveis, parados), eles são colocados bem próximos de modo a conseguir a cobertura desejada, enquanto que nos nós móveis, a mobilidade é usada para mudar a localização ideal. Assim, o objetivo da cobertura aleatória é manter a cobertura e ao mesmo tempo, minimizar o consumo de energia (ZHOU et al., 2006).

Modelos de Detecção (sensores)

De acordo com Zhu et al. (2012), Os nós sensores utilizados nas RSSFs geralmente têm características teóricas e físicas amplamente diferentes. Assim, vários modelos de complexidade variável podem ser construídos com base nas necessidades de aplicativos e no ambiente de trabalho. Pode-se destacar 2 (dois) tipos de modelos amplamente utilizados: O modelo binário de disco e o modelo probabilístico. Tais modelos são descritos da seguinte maneira:

Modelo Binário de Disco: O modelo mais simples é o modelo de disco binário, segundo o qual um nó é capaz de detectar apenas a partir de pontos que estão dentro de seu alcance de detecção e não de qualquer ponto além dele. Assim, neste modelo, o intervalo de detecção para cada nó é confinado dentro de um disco circular de raio r , e é comumente referido como o raio de detecção.

$$c_{xy}(S_i) = \begin{cases} 1, & \text{Se } dist(S_i, P) < r \\ 0, & \text{Caso Contrário} \end{cases} \quad (1)$$

Esta equação define se um ponto c_{xy} está sendo detectado pelo sensor S_i . Assim, é feita a verificação se a distância do ponto P até o sensor S_i é menor que o raio de detecção

r , indicando o valor 1 caso seja verdadeiro ou 0, caso contrário.

Modelo Probabilístico: O modelo probabilístico é uma percepção mais real, que pode ser tomado como uma extensão do modelo binário de disco, onde, r_e ($r_e < r$) é a medida da incerteza da detecção do sensor, $\alpha = d(S_i, P) - (r - r_e)$, e λ e β são parâmetros que medem a probabilidade de detecção quando um alvo está há uma distância maior do que r_e mas ainda está dentro da distância do sensor. Este modelo reflete o comportamento de dispositivos sensores de alcance, como sensores infravermelhos e de ultra-som.

$$c_{xy}(S_i) = \begin{cases} 0, & \text{Se } r + r_e \leq d(S_i, P) \\ e^{-\lambda\alpha^\beta}, & \text{Se } r - r_e < d(S_i, P) < r + r_e \\ 1, & \text{Se } \text{dist}(S_i, P) < r \end{cases} \quad (2)$$

Características do Alvo

Segundo Gupta, Kumar e Jain (2016), os problemas de cobertura podem ser classificados de acordo com as características dos alvos a serem cobertos, a seguir é feita a caracterização de duas destas características, os alvos estáticos e alvos dinâmicos:

Cobertura de Alvo Estático (imóvel): Alvos estáticos são alvos estacionários (ou seja, que não são capazes de se mover). Um exemplo de alvo estático seria uma árvore. Esse tipo de cobertura funciona com o objetivo de maximizar a cobertura e minimizar a redundância de nós sensores. Esta é a abordagem mais simples e que pode ser vista mesmo nas situações da vida diária, como no monitoramento da temperatura.

Cobertura de Alvo Dinâmico: Ao contrário do estático, o alvo dinâmico tem a capacidade de se mover. Uma pessoa andando pode ser representado como um alvo dinâmico. O foco principal desse tipo de cobertura é o movimento do alvo dinâmico. Ele é bem mais complicado se comparado com o alvo estático devido à complexidade de conseguir a localização exata do alvo em movimento.

Atributos da Aplicação

Cobertura com Economia de Energia: A cobertura com economia de energia visa descobrir se o consumo de energia pelos nós na rede é feito de forma eficiente ou não. O consumo de energia tem um grande impacto na existência da rede. Por causa de recursos limitados, esse tipo de cobertura é feito dividindo os nós sensores em subconjuntos de nós “ativos” (nós que estão realizando atividades de transmissão, recepção e/ou processamento de dados, etc) e “suspensos” (nós que estão em um estado de baixo consumo de energia, como um *stand by* de um aparelho de televisão) em diferentes sequências. Este tipo de cobertura é feito para maximizar a vida da rede com a preservação dos recursos energéticos

(GUPTA; KUMAR; JAIN, 2016).

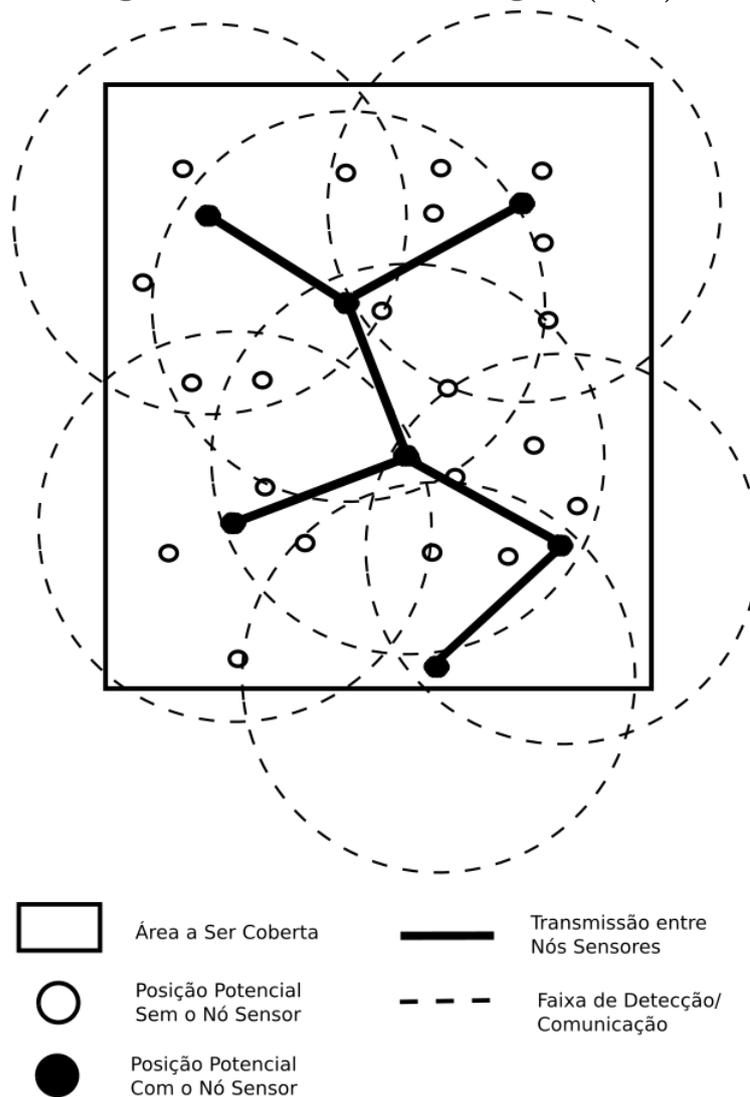
Cobertura de Conectividade: A cobertura de conectividade nos mostra como lidar com os requisitos de comunicação e o grau de cobertura ao mesmo tempo e desempenha um papel importante no controle de cobertura. A cobertura de conectividade pode ser categorizada como:

- Cobertura de conectividade de sensor ativo - essa cobertura trata do estado “ativos” e “suspensos” dos nós em rotação (nós implantados na área).
- Cobertura do caminho conectado - esse tipo de cobertura trata do procedimento de seleção dos nós sensores conectados para obter o máximo efeito.

Áreas Monitoradas

Cobertura Regional

Figura 4 – Cobertura de região (área).

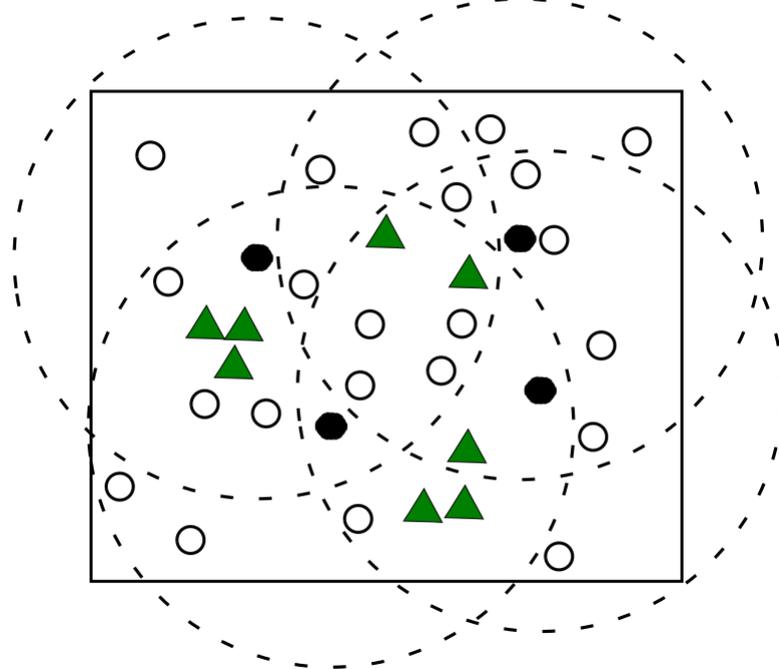


Na cobertura regional, segundo os trabalhos de Sangwan e Singh (2015) e trabalhos de Fan e Jin (2010), cada ponto está sob vigilância de pelo menos um sensor. Desde que cada ponto exija monitoramento, neste tipo de cobertura os nós sensores são densamente implantados no qual resultam em cobertura sobreposta. A proteção da Amazônia contra o desmatamento é um exemplo de cobertura de região.

A Figura 4 apresenta um exemplo da cobertura regional, onde, toda a área retangular precisa estar dentro da faixa de detecção dos nós sensores. Observa-se que mesmo que haja sobreposição de algumas partes das faixas de detecção dos nós sensores, o objetivo permanece atendido.

Cobertura de Ponto (alvo)

Figura 5 – Cobertura de pontos.



O objetivo é cobrir um conjunto de pontos (alvo) com localização conhecida que precisam ser monitorados. O esquema de cobertura de pontos concentra-se na determinação das posições exatas dos nós sensores, garantindo uma cobertura eficiente para um número limitado de pontos imóveis (alvos). Geralmente, ele pode ser resolvido como um caso especial do problema de cobertura da área quando o número dos nós do sensor pode ser desconsiderado (FAN; JIN, 2010).

A Figura 5 demonstra uma configuração de rede que satisfaz o problema da cobertura de pontos. Os nós sensores são posicionados de tal maneira que sua faixa de detecção alcance o maior conjunto de pontos possíveis até cobrir o conjunto de pontos por completo.

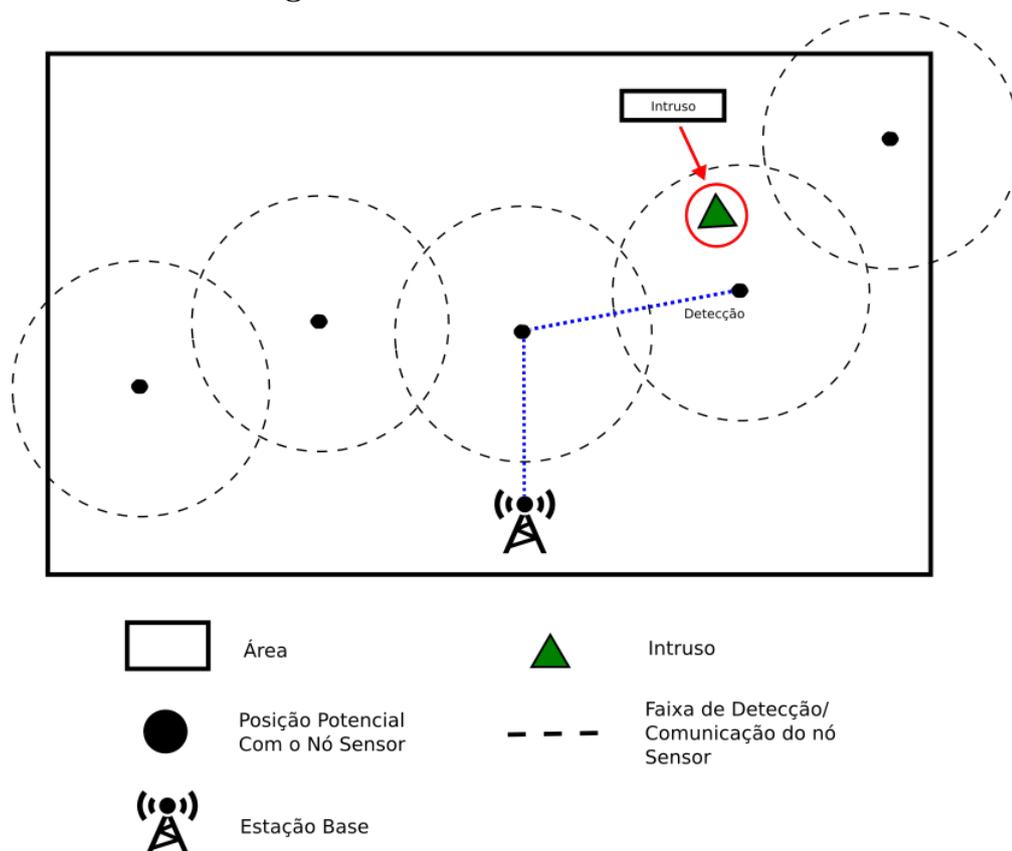
Cobertura de Barreira

A cobertura de barreira trata do cálculo do movimento de objetos na área alvo. As chances ou probabilidades podem ser determinadas pela taxa de movimento do objeto e pelas intensidades de detecção dos sensores para cada ponto do caminho seguido pelo objeto. Com base neste cálculo, a densidade dos nós sensores pode ser calculada. Pode-se descobrir que os nós sensores devem ser implantados densamente na região. A cobertura de Barreira pode ainda ser classificada como k - barreira fraca (*Weak k -barrier*) ou k - barreira forte (*strong k -barrier*) (SANGWAN; SINGH, 2015).

k -barreira fraca - Este tipo de cobertura garante que qualquer alvo que atravesse a região alvo juntamente com o caminho ortogonal seja detectado por, pelo menos, k -sensores.

k -barreira forte - Essa cobertura garante que o alvo seja detectado por k -sensores, no entanto, o caminho seguido pelo alvo não importa.

Figura 6 – Cobertura de barreira.



A Figura 6 traz um exemplo simples de cobertura de barreira, onde a rede é montada de modo a formar uma barreira em uma determinada área e, um intruso entra na área de detecção desta barreira. Nesse momento, um sinal de detecção é enviado a partir do nó sensor que percebeu o intruso, esse sinal é propagado até alcançar em uma estação base onde a informação será processada e tratada da maneira desejada.

4 ALGORITMOS GENÉTICOS

Os algoritmos genéticos (AG) fazem parte de um ramo dos algoritmos evolucionários¹, assim, realizam uma técnica de busca que baseia-se no processo natural de evolução das espécies. Estas são técnicas heurísticas, ou seja, os algoritmos genéticos não necessariamente encontram a solução ótima do problema e, quando encontram, nem sempre conseguem o mesmo resultado novamente (LINDEN, 2006).

Segundo Koza (1995), o algoritmo genético (AG) transforma uma população de objetos individuais, cada um com um valor de aptidão associado, em uma nova geração da população usando os princípios Darwinianos de reprodução e sobrevivência dos mais apto. Estas populações são submetidas à alguns métodos chamados **operadores genéticos**, sendo estes métodos a *seleção*, *recombinação (crossover)* e a *mutação*.

Como os AGs são técnicas heurísticas de otimização global, elas não param ao encontrarem um máximo local (LINDEN, 2006). Assim como na evolução natural, os AGs, ao encontrar um indivíduo que é o melhor em tal situação, não encerram sua execução, ela continua procurando por resultados ainda melhores. Na evolução natural isso ocorre nos momentos de mudança de ambiente, por exemplo, uma bactéria que pode ser a melhor adaptada em ambientes sem antibióticos, mas, no momento em que houver mudanças neste ambiente e o mesmo começar a ter antibióticos ao ar livre, as outras bactérias que eram mais fracas tornam-se as únicas sobreviventes, por serem as melhores adaptadas.

Cada indivíduo na população representa uma possível solução do problema. O algoritmo genético procura por uma boa solução (ou a melhor) através da reprodução da população durante sucessivas gerações (KOZA, 1995). Assim, a codificação dos indivíduos é um ponto crucial nos AGs, pois, se feita de forma inteligente, ela incluirá as peculiaridades do problema (restrições sobre qual nó sensor ativar ou desligar, por exemplo) e permitirá evitar testes de viabilidade de cada uma das soluções geradas.

Os AGs utilizam, no geral, a forma de reprodução sexuada, aqui chamada de recombinação. É a recombinação que tem a responsabilidade de fazer com que a população evolua: ela aceita 2 (dois) indivíduos chamados de *pais* e produz 2 (dois) novos indivíduos, chamados *descendentes*, trocando “*substrings*” de seus indivíduos pais (TOMASSINI, 1995). Já a mutação, para Holland (1992), é essencialmente ruído de fundo que é introduzido para prevenir uma convergência prematura, devido à uniformização da população, para um resultado ótimo local através de modificações aleatórias, porém, é aplicada de forma menos frequente (assim como na natureza) do que a recombinação.

A reprodução e a recombinação apenas são aplicadas em indivíduos selecionados da população. Essa seleção é feita de forma que os indivíduos mais aptos sejam mais fre-

¹Os algoritmos evolucionários são algoritmos que usam modelos computacionais dos processos de evolução como uma forma de resolver problemas.

quentemente selecionados do que os menos aptos, fazendo com que as boas características dos mais aptos predominem na nova população. Os menos aptos não devem ser descartados da população, pois, isso causaria uma rápida **convergência genética** de todas as soluções para um mesmo conjunto de características e evitaria uma busca mais ampla pelo espaço de soluções². A convergência genética é tida como uma população com baixa diversidade genética, em razão de possuir genes similares, não conseguindo evoluir a não ser pela ocorrência de mutações (LINDEN, 2006).

4.1 Características dos Algoritmos Genéticos

Os AGs podem encontrar soluções diferentes a cada execução, mesmo quando possuem a mesma população inicial e o mesmo conjunto de parâmetros, ou seja, estes algoritmos utilizam técnicas probabilísticas³, e não determinísticas⁴.

Segundo Linden (2006), os AGs são programas simples que precisam apenas de informações locais relativas ao quão bem essas informações se adequam à solução do problema em questão. Essa simplicidade é o que torna os algoritmos genéticos tão aplicáveis em problemas reais, que em geral, incluem **descontinuidades duras**. Descontinuidades duras são situações onde os dados são discretos (sem continuidade) ou não possuem derivadas. É muito comum em situações do mundo real onde é necessário alocar recursos. Assim, não se pode calcular derivadas ou gradientes, o que acaba impedindo o uso de técnicas numéricas tradicionais, que fazem fortes exigências sobre as características das funções que não podem ser atendidas em problemas reais.

Vários componentes dos algoritmos genéticos são invariáveis de um problema para outro, tornando os AG altamente genéricos. Isso favorece sua implementação em orientação à objetos, permitindo o reaproveitamento do código para a solução de vários problemas diferentes.

Para Holland (1992), os AGs possuem uma notável capacidade de concentrar sua atenção nas partes mais promissoras de um espaço de solução, isso é um resultado direto de sua capacidade de combinar trechos contendo soluções parciais. O algoritmo genético explora as regiões de maior recompensa (melhor avaliação), do espaço da solução, porque gerações sucessivas de reprodução e cruzamento produzem um número crescente de cadeias nessas regiões. O algoritmo favorece então as sequências de caracteres mais ajustadas como pais e, portanto, as sequências acima da média (que se enquadram nas regiões de destino) terão mais descendentes na próxima geração.

Para Linden (2006), a busca dos AGs é diferente quando comparada à outros esquemas aleatórios, pois, realiza uma busca direcionada e não trabalha com caminhadas

²Na evolução natural os menos aptos conseguem se reproduzir, porém, com menos frequência do que os mais aptos.

³Técnicas baseadas na aleatoriedade.

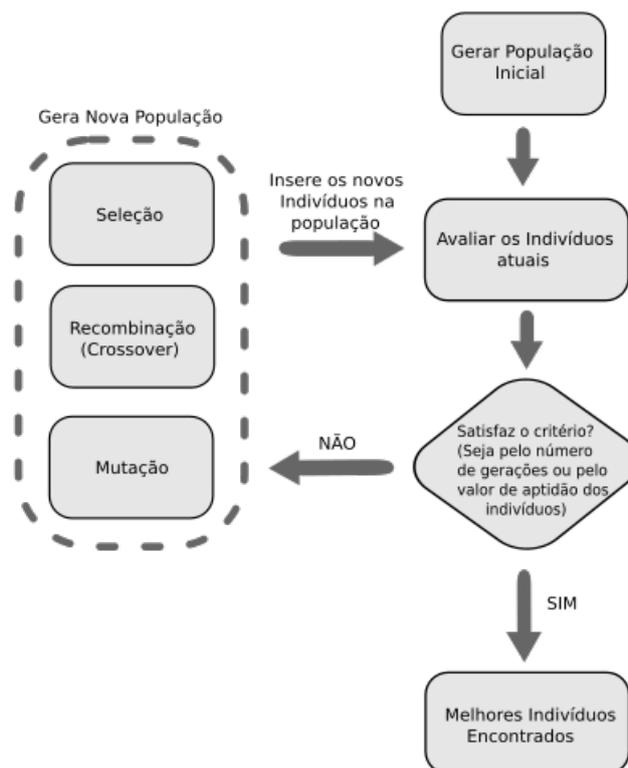
⁴Técnicas baseadas na relação de causalidade.

aleatórias (*random walks*) pelo espaço de soluções, direcionando sua busca através do mecanismo de seleção, assim como na natureza. Essa busca é feita usando-se o valor da função de avaliação (*fitness*) como guia na escolha dos indivíduos reprodutores. Com certeza existem fatores estocásticos (com origem em eventos aleatórios) que podem fazer “retrocessos” no processo da busca das soluções, porém procura-se utilizar características existentes na instância atual para tentar direcionar o algoritmo para a solução correta. Assim, entende-se que os AGs não são simplesmente estocásticos, mas que funcionam com uma busca direcionada no espaço das soluções.

4.2 Estrutura de um Algoritmo Genético Básico

A Figura 7 representa um esquema simples do funcionamento de um algoritmo genético básico.

Figura 7 – Esquema de um Algoritmo Genético básico.



Em suma, esse processo pode ser resumido nos seguintes pontos:

1. Inicializar a população de cromossomos;
2. Avaliar cada cromossomo da população, individualmente;

3. Levando em conta a avaliação, selecionar os “pais” para gerar novos cromossomos;
4. Aplicar os operadores de mutação e recombinação aos pais selecionados para gerar os indivíduos da nova população;
5. Eliminar os antigos indivíduos da população;
6. Avaliar todos os novos indivíduos e inseri-los na população;
7. Se o tempo de execução acabar ou o melhor indivíduo satisfizer a exigência, retornar o indivíduo, caso contrário, retornar ao item 3.

Embora esta visão resumida dos algoritmos genéticos nos traga uma noção básica de seu funcionamento, o que ela esconde é a complexidade que existe no processo de obtenção de uma representação cromossomial adequada ao problema e de uma função de avaliação (*fitness*) que reprima soluções infactíveis (processo de busca direcionada) e que avalie corretamente o grau de pertinência de cada cromossomo (LINDEN, 2006).

4.3 Operadores Genéticos

Operadores genéticos são operadores que realizam o papel de guiar o algoritmo genético em direção à solução de determinado problema. Eles são usados para criar e manter a diversidade genética (*mutação*), combinar soluções existentes (também conhecidas como cromossomos) em novas soluções (*crossover*) e selecionar os melhores entre as soluções (seleção) (KENNEDY; EBERHART, 2001).

A seguir é feito um detalhamento a respeito destes operadores e as razões do uso de cada um deles.

Representação dos Cromossomos

A forma de representação dos indivíduos é fundamental para o algoritmo genético, ela consiste em uma maneira de transformar a informação de um problema do mundo real em uma forma que possa ser tratada pelo computador. Quanto melhor adaptada ao problema, melhores serão os resultados obtidos.

Cada pedaço dessa representação é chamado de **gene**, analogamente às partes que compõem um cromossomo biológico.

As adequações da representação cromossômica serão diferentes, dependendo do problema estudado, porém, é interessante que algumas regras gerais sejam seguidas (LINDEN, 2006):

- A representação dos cromossomos deve ser a mais simples possível;
- Se houver soluções proibidas ao problema, então elas não devem ter representação;

- Se o problema impuser condições, seja qual for o tipo, estas devem estar implícitas na representação.

A representação mais simples e amplamente utilizada pelos desenvolvedores de algoritmos genéticos é a binária, ou seja, um cromossomo é uma sequência de bits, onde cada gene é representado por um bit. Essa representação foi inicialmente adotada por Holland (1975) em seu livro, e, devido à simplicidade dessa representação, ela acabou se tornando amplamente adotada por pesquisadores no mundo todo.

Figura 8 – Exemplo de codificação binária de um cromossomo.



A Figura 8 demonstra um indivíduo codificado de forma binária, onde, o valor de cada célula do vetor pode variar entre 0 (zero) e 1 (um). Nos problemas de cobertura, comumente é utilizada esta forma de representação. Nesta representação, cada célula do vetor denota um nó sensor e o valor da célula informa se o sensor está posicionado (representado pelo valor 1) ou não posicionado (representado pelo valor 0).

Tamanho da População

Em Kennedy e Eberhart (2001), os autores citam a dissertação de De Jong's (1995) que oferece algumas diretrizes com relação à inicialização dos parâmetros dos algoritmos genéticos e que ainda hoje são utilizadas, sendo elas, inicializar com uma taxa relativamente alta de recombinação (*crossover*), uma taxa baixa de mutação e um tamanho populacional moderado (apesar de que essas quantidades não são especificadas no livro). O custo benefício do tamanho populacional é bastante evidente, é evidente que uma maior população terá uma busca mais completa no espaço de busca das soluções porém, terá um maior custo computacional. Assim, geralmente são usadas populações de algumas dúzias de indivíduos até centenas, dependendo, principalmente, da quantidade de genes dos indivíduo. O tamanho “ótimo” para uma população (se isso existir) dependerá do problema abordado.

Inicialização da População

A inicialização da população, em geral, é feita de forma aleatória apesar de que as vezes é mais conveniente iniciar a população com pelo menos um ou mais indivíduos selecionados heurísticamente, e claro, o problema abordado é que vai ditar isso. Assim, o algoritmo genético é inicializado de uma forma mais direcionada. Esse preenchimento da população com indivíduos pré selecionados não é incomum no desenvolvimento de algoritmos genéticos. Porém, é necessário que, independente do processo utilizado, a população

dos AGs devam representar uma grande variedade de indivíduos distintos (KENNEDY; EBERHART, 2001).

Para Lacerda e Carvalho (1999), A população inicial pode ser gerada de várias maneiras. Se uma população inicial pequena for gerada aleatoriamente, provavelmente, algumas regiões do espaço de busca não serão representadas.

Lacerda e Carvalho (1999) completam informando que este problema pode ser minimizado gerando a população inicial de maneira uniforme (ou seja, com pontos igualmente espaçados como se preenchessem uma grade). Outra alternativa é gerar a primeira metade da população de forma aleatória e gerar a segunda metade a partir da primeira, porém, invertendo os bits. Isso garante que cada posição da cadeia de bits tenha um representante na população com os valores 0 e 1.

Uma técnica denominada “*seeding*” pode ser útil em muitos problemas práticos. Esta técnica consiste em inserir, na população inicial, soluções encontradas por outros métodos de otimização. Isso garante que a solução gerada pelo AG não seja pior que as soluções geradas por este método (LACERDA; CARVALHO, 1999).

Avaliação dos indivíduos (Função *Fitness*)

Esta função é um ponto chave no processo de evolução da população dos algoritmos genéticos, é a maneira que eles utilizam para definir a qualidade dos indivíduos da população como uma solução do problema abordado. De um modo geral, esse operador genético calcula um valor numérico que denota o quão bom os parâmetros representados nos cromossomos resolvem o problema abordado, e é com este valor numérico retornado que o operador de seleção de pais realiza a escolha dos indivíduos aptos à “procriar”, diferenciando assim os indivíduos adaptados (boa solução para o problema) e os inadaptados (más soluções do problema) (LINDEN, 2006).

Devido a generalidade dos algoritmos genéticos, a função de avaliação (*Fitness*) é, em vários casos, a única ligação do programa com o problema, devido ao fato de que a função de avaliação só julga a qualidade da solução do indivíduo que está sendo apresentado, sem armazenar informações sobre as técnicas de resolução do problema. Ou seja, com isso, o mesmo algoritmo genético pode ser utilizado para encontrar a solução de qualquer função de n variáveis sem a necessidade de alterar sua estrutura de dados e procedimentos adotados, necessitando apenas alterar a função de avaliação (LINDEN, 2006).

Um problema comum à muitas implementações da função de avaliação é que quando o algoritmo genético itera um certo número de gerações, o valor de avaliação da maioria (e às vezes de todos) os indivíduos ficam bastante altos. Em casos que o valor de avaliação pode variar de 0 à 1, a maioria dos valores de avaliação pode ficar próximo de 0,9 ou maior, por exemplo. Isso acaba reduzindo a diferença da avaliação entre os indivíduos que propiciam uma seleção efetiva para a escolha dos pais (KENNEDY;

EBERHART, 2001).

Um meio de contornar essa situação é igualando o espaço entre os valores da avaliação. Por exemplo, no espaço de valores de avaliação entre 0 e 1, atribuindo o valor 1 para o membro da população mais apto (mais próximo da solução ótima), 0,875 para o segundo e 0,125 para o menos apto. Neste caso os membros da população são classificados com base na sua avaliação e suas hierarquias são divididas pelo número de indivíduos para fornecer um limiar de probabilidade para a seleção. Atribuir o valor 0 para um indivíduo pode fazer com que o mesmo fique inelegível para reprodução.

Na função de avaliação deve-se adaptar todo o conhecimento que engloba o problema, tanto no que tange suas restrições, quanto os seus objetivos de qualidade. Esta função precisa refletir, de forma numérica, os objetivos a serem alcançados na solução do problema, sendo assim, ela mesma acaba sendo resultante das condições impostas pelo problema (LINDEN, 2006).

Seleção

De acordo com Lacerda e Carvalho (1999), o método de seleção é o responsável por simular o mecanismo de seleção natural que ocorre nas espécies, onde os pais mais adaptados geram mais filhos, e os menos adaptados também podem gerar descendentes. Ele privilegia os indivíduos com o retorno da função de avaliação mais alta, sem ignorar os indivíduos com resultados mais baixos. Essa decisão é necessária, pois, indivíduos com essa avaliação baixa podem ter características que sejam favoráveis à criação/geração de um indivíduo que seja a melhor solução do problema.

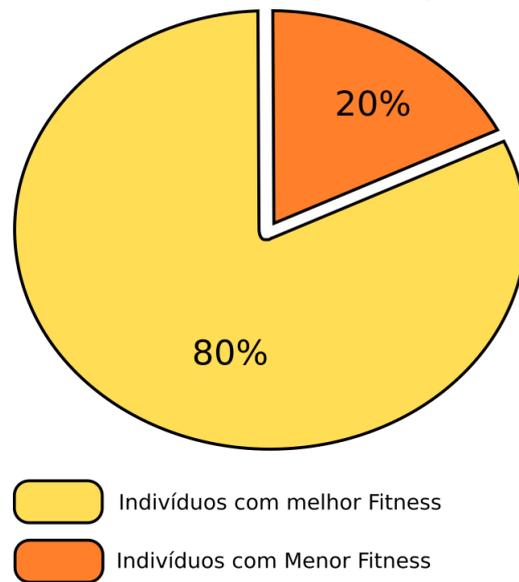
Existem diversas formas de seleção, a seguir são destacadas algumas delas:

Seleção por Roleta: No método de seleção por roleta (POZOA et al., 2018), cada cromossomo recebe um pedaço proporcional à sua avaliação (a soma dos pedaços não pode passar de 100%). Assim, para indivíduos com uma nota alta na avaliação, é dada uma porção maior da roleta, de modo contrário, indivíduos com avaliação mais baixa é dada uma menor porção da roleta, como podemos ver na Figura 9.

Segundo Linden (2006), a função de rodar a roleta⁵ deve ser aleatória, escolhendo um número entre 0 e 100 (representando a porcentagem que corresponde cada indivíduo na roleta) ou entre 0 e 360 (representando a posição do círculo).

⁵Claro que “rodar a roleta” é apenas uma expressão para representar o conjunto de conceitos abstratos que são executados para simular uma roleta na versão computacional.

Figura 9 – Exemplo de roleta utilizada para seleção dos melhores indivíduos.



Na Figura 9, a maior porção da roleta é configurada para os indivíduos com o maior valor de fitness, assim, tais indivíduos tem maiores chances de serem selecionados para cruzamento do que os indivíduos de menor valor de fitness.

Exemplo de pseudocódigo:

Algorithm 1: Seleção por Roleta

```

1  $T \leftarrow$  soma dos valores de avaliação de todos os indivíduos da população ;
2  $S \leftarrow 0$  ;
  /* Repita N vezes para selecionar N indivíduos          */
3 for  $i \leftarrow 0$  to  $N$  do
4    $S \leftarrow S +$  Avaliação do indivíduo  $i$  ;
5    $r \leftarrow$  Valor aleatório entre 0 e  $T$  ;
6   if  $S \geq r$  then
7     Seleccione o indivíduo corrente ;
8 end

```

Seleção por Torneio: Neste método, um número n de indivíduos é escolhido aleatoriamente para formar uma subpopulação temporária. Desta subpopulação, os indivíduos vão depender de uma probabilidade k pré-definida. Se o valor gerado na execução for maior que o valor de k , então os indivíduos do subconjunto são selecionados para reprodução (POZOA et al., 2018).

Exemplo de pseudocódigo:

Algorithm 2: Seleção por Torneio

```

1  $k \leftarrow 0.75$  ;
   /* Repita N vezes                                     */
2 for  $i \leftarrow 0$  to  $N$  do
3   Escolha 2 (dois) indivíduos da população aleatoriamente ;
4    $r \leftarrow$  Valor aleatório entre 0 e 1 ;
5   if  $r < k$  then
6     O melhor indivíduo é escolhido ;
7   else
8     O pior indivíduo é escolhido ;
9 end

```

Elitismo: Para evitar que o melhor indivíduo seja perdido, Lacerda e Carvalho (1999) utilizam o método do elitismo. No método do elitismo, primeiro é feita a cópia dos melhores cromossomos (ou os poucos melhores cromossomos) para a nova população. O resto da população é construída utilizando alguns dos métodos descritos anteriormente. Com o elitismo é possível aumentar rapidamente o desempenho do AG, tendo em vista que este previne a perda da melhor solução já encontrada.

Operador de Recombinação (*Crossover*)

A recombinação, mais conhecida como *crossover*, em suma é uma abstração do modo de combinação sexuada das espécies na natureza. Ela pode ser implementada de modo que seja possível configurar uma taxa da probabilidade de combinação, fazendo de tal modo que apenas quando um número, gerado aleatoriamente, for menor do que esta taxa, seja feita a combinação dos genes (KENNEDY; EBERHART, 2001).

Outros algoritmos evolucionários usam mutação aleatória aliada à seleção como principal método de busca. Porém, a vida natural encontrou e utiliza um dos melhores e mais fundamentais métodos de pesquisa, a reprodução sexuada. O seu sucesso é perceptível, tendo em vista que é altamente disseminada tanto no reino animal quanto no reino vegetal (KENNEDY; EBERHART, 2001). A reprodução sexuada se aproveita das diferenças e similaridades entre os indivíduos de uma população. Exemplificando, se temos um indivíduo com características que o protegem das intempéries do ambiente, enquanto outro tem uma pelagem que o protege de predadores. Então, “acasalando” esses dois indivíduos, tem-se a possibilidade de que a descendência não tenha nenhuma dessas vantagens, temos também a possibilidade de que os descendentes tenham em algum grau alguma das duas vantagens, ou ainda, a possibilidade de que ambas as características estejam presentes nos descendentes. A seleção irá decidir, à longo prazo, quais dessas

possibilidades são mais adaptáveis, e quem se adapta melhor sobrevive.

Nos algoritmos genéticos, os descendentes tem a mesma probabilidade de receber qualquer gene de qualquer pai. Nos seres biológicos, essa combinação pode deixar seções de genes intactas, ou seja, uma fatia contínua de cromossomos de um dos pais é combinada com uma fatia de outro pai, ao contrário de simplesmente misturar tudo aleatoriamente. Devido à isso, os AGs tem várias maneiras de implementar o *crossover* (LINDEN, 2006).

Uma das implementações mais simples é o crossover de ponto. A partir dos pais selecionados, um ponto de corte é definido. Este ponto de corte é uma posição entre os genes do cromossomo (cada indivíduo de n genes possui $n - 1$ pontos de corte), sendo assim um ponto de separação dos genes que compõem o material genético dos pais. Depois de sorteado o ponto de corte, os pais são separados em duas partes: uma parte é a que fica à esquerda do ponto de corte e a segunda parte é a que fica à direita do ponto.

A partir da separação é possível obter os descendentes dos pais seccionados. O primeiro filho é composto pela junção (concatenação) da parte esquerda do primeiro pai com a parte direita do segundo. O segundo é composto pelas partes que sobram, o que implica dizer que, a metade direita do primeiro pai com a metade esquerda do segundo pai.

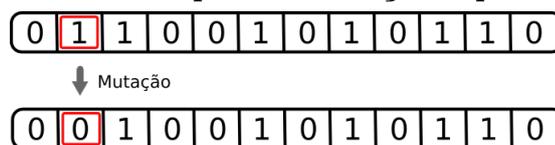
Conforme afirma Lacerda e Carvalho (1999), o processo de recombinação assemelha-se ao que ocorre na natureza durante a formação do cromossomo de um indivíduo gerado pela reprodução sexuada. Porém a natureza não se limita à apenas um corte.

Analogamente, é evidente a possibilidade de fazer o crossover de até n cortes, porém, o custo computacional e a complexidade do programa crescem junto com a quantidade de pontos seccionais (LACERDA; CARVALHO, 1999).

Operador de Mutação

Finalizado o crossover, o próximo passo é aplicar o fator de mutação nos descendentes. A mutação, no geral, tem uma taxa de probabilidade muito baixa ocorrendo em alguns poucos indivíduos da população (em torno de 0,01% à 0,5%), segundo (KENNEDY; EBERHART, 2001). A mutação atua modificando os genes dos indivíduos de forma estocástica (maneira aleatória), bit por bit.

Figura 10 – Exemplo de mutação flip-bit único.



A Figura 10 representa a mutação utilizada neste trabalho. Primeiramente, é gerado um valor aleatório, se este valor gerado for menor do que a probabilidade de mutação acontece, então, a mutação de tal indivíduo. Assim como na Figura 10, na

mutação o índice selecionado do cromossomo tem seu valor alterado ao contrários, ou seja, onde era 0 (zero) vira 1 (um) e onde era 1 (um), vira 0 (zero).

É importante que o fator de mutação seja baixo, quanto mais alto a probabilidade de mutação, mais parecido o algoritmo será da técnica chamada *random walk*, isso pode acabar prendendo o AG em máximos locais ou invés de evitá-los, não convergindo para uma solução ótima (LINDEN, 2006).

5 METODOLOGIA

Este projeto visa encontrar o menor número de nós sensores necessários para implantação em redes que requerem k -cobertura dos alvos e m -conectividade dos nós sensores. O trabalho de Gupta, Kuila e Jana (2016) é utilizado como base do projeto, onde os autores utilizam um algoritmo genético e definem uma função de avaliação otimizada para alcançar a menor quantidade de nós implantados visando a k -cobertura e a m -conectividade. Além disso, o algoritmo utilizado é modificado a partir do trabalho de Zhang et al. (2017) para fins de comparação.

5.1 O Objeto de Estudo

O trabalho dos autores Gupta, Kuila e Jana (2016), visa, através de uma meta-heurística (algoritmo genético), conseguir uma forma otimizada de implantar nós sensores em uma rede de sensores sem fios (WSN) dado um conjunto de possíveis posições onde tais nós sensores poderiam ser implantados e um conjunto de alvos. Na modelagem proposta, os nós sensores devem obedecer à restrição de que cada nó precisa estar pelo menos conectado diretamente com outros m nós sensores, isto é, cada nó, do conjunto dos sensores, deve estar m -conectado. Os alvos também devem seguir a restrição de estar dentro da faixa de detecção de pelo menos k nós sensores, ou seja, cada alvo, do conjunto dos alvos, deve estar pelo menos k -coberto.

Os alvos são espalhados numa área bi-dimensional juntos com as possíveis posições de implantação dos nós sensores. Ambos, alvos e posições potenciais são estáticas. Os alvos ainda só são considerados cobertos se estiverem dentro do raio de detecção do sensor e cada sensor pode detectar mais de um alvo simultaneamente.

Formulação do Problema

A formulação do problema, desenvolvida por Gupta, Kuila e Jana (2016), é definida da seguinte maneira:

Dado um conjunto de N alvos e K possíveis posições, selecionar a menor quantidade de possíveis posições de implantação dos sensores de modo que a rede tenha as propriedades de k -cobertura e de m -conectividade (para algum valor de k e m).

Para prosseguir é necessário descrever algumas definições utilizadas por Gupta, Kuila e Jana (2016):

- O conjunto de alvos é representado por $T = \{t_1, t_2, \dots, t_N\}$;
- O conjunto de possíveis posições de implantação dos nós sensores é representado por $P = \{p_1, p_2, \dots, p_K\}$;

- N é a quantidade de alvos da área/região;
- M é o subconjunto das posições potenciais selecionadas dentre as K posições possíveis de implantação dos sensores;
- R_{com} é o raio de comunicação de cada nó sensor;
- R_{sen} é a faixa de detecção de cada nó sensor;
- $dist(t_i, s_j)$ representa a distância entre o alvo t_i e o nó sensor s_j ;
- $Cov(t_i)$ representa o conjunto de nós sensores que estão detectando o alvo t_i , ou seja, representa os sensores que cobrem o alvo t_i . Formalmente, temos o seguinte:

$$Cov(t_i) = \{s_j | dist(t_i, s_j) \leq R_{sen}, \forall j, 1 \leq j \leq M\} \quad (3)$$

- $TCov(s_i)$ representa o conjunto de alvos t_j que são cobertos pelo nó sensor s_i , portanto:

$$TCov(s_i) = \{t_j | dist(t_j, s_i) \leq R_{sen}, \forall j, 1 \leq j \leq N\} \quad (4)$$

- $Com(s_i)$ representa o conjunto de nós sensores que estão dentro da faixa de comunicação do sensor s_i , ou seja, os sensores que estão conectados com o sensor s_i , assim:

$$Com(s_i) = \{s_j | dist(s_i, s_j) \leq R_{com}, \forall j, 1 \leq j \leq M\} \quad (5)$$

Assim, s_i pode transmitir dados para qualquer $Com(s_i)$, sendo que $Com(s_i) \subseteq S$

Para representar as restrições de k -cobertura e m -conectividade tem-se as variáveis b_{ij} e c_{ij} e a variável q_i para representar as posições potenciais que foram preenchidas ou não. A partir destas restrições, tem-se as seguintes variáveis de decisão:

$$b_{ij} = \begin{cases} 1, & \text{Se o alvo } t_i \text{ está coberto por } s_j \\ 0, & \text{Caso Contrário} \end{cases} \quad (6)$$

$$c_{ij} = \begin{cases} 1, & \text{Se um sensor } s_i \text{ está diretamente conectado à outro sensor } s_j \\ 0, & \text{Caso Contrário} \end{cases} \quad (7)$$

$$q_i = \begin{cases} 1, & \text{Se a posição potencial } p_i \text{ está selecionada para implantação, } 1 \leq i \leq K \\ 0, & \text{Caso Contrário} \end{cases} \quad (8)$$

Formalizando essas restrições, tem-se: A função objetivo, que encontra a menor quantidade de posições necessárias para implantar os nós sensores e ainda satisfazer as restrições de cobertura e conectividade.

$$\text{Minimizar } Z = \sum_{i=1}^K q_i \quad (9)$$

Sujeito à:

$$\sum_{j=1}^M b_{ij} \geq k, \forall i, 1 \leq i \leq N \quad (10)$$

$$\sum_{j=1}^M c_{ij} \geq m, \forall i, 1 \leq i \leq M \quad (11)$$

A restrição (10) garante que todo alvo t_i esteja coberto por no mínimo k nós sensores, satisfazendo a k -cobertura de todos os alvos. A restrição (11) garante que todo nó sensor s_i esteja conectado diretamente à pelo menos outros m sensores, satisfazendo a condição de m -conectividade de todos os sensores.

Aquisição de Possíveis Posições de Implantação dos Nós Sensores

No trabalho de Gupta, Kuila e Jana (2016) os pontos potenciais de implantação dos nós sensores são gerados de forma aleatória, porém, é possível que quando gerados aleatoriamente, os pontos não possam de alguma maneira satisfazer as condições de k -cobertura e m -conectividade. A partir dessa reflexão, foi decidido usar o Diagrama de Voronoi para mitigar esta situação.

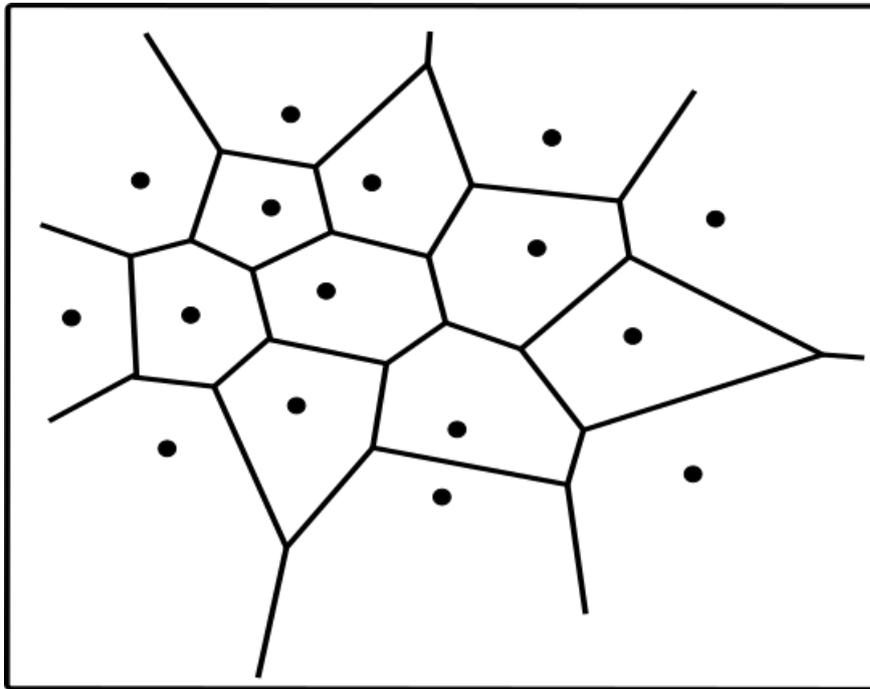
O Diagrama de Voronoi divide uma área em regiões, chamadas células de Voronoi, contendo todo o espaço que está próximo à algum objeto (neste trabalho os objetos serão os alvos). A Figura 11 mostra um exemplo simples dos polígonos formados ao redor dos pontos determinados. O tamanho das células representam o quão grande o objeto é, neste caso o tamanho das células terá dimensões uniformes devido à todos os nós sensores apresentarem o mesmo tamanho (MELO; FRANK; BRANTINGHAM, 2017). A

representação matemática formal do Diagrama de Voronoi é descrito da seguinte forma:

$$Vor_i = \{x | dist(x, p_i) \leq dist(x, p_j), j \neq i\} \quad (12)$$

Nesta equação, x é um espaço métrico plano, p é o conjunto de pontos $\{p_1, \dots, p_i, p_j, \dots, p_n\}$ no plano, e a $dis(x, p_i)$ é a distância entre todos os pontos x e um específico ponto p . Assim, o Diagrama de Voronoi, a grosso modo, é um conjunto de polígonos denotados por Vor_i , onde $Vor_i = \{Vor_1, \dots, Vor_n\}$. No geral, o Diagrama de Voronoi divide a distância entre 2 pontos pela metade e, uma vez que estes pontos médios estejam conectados, eles formam polígonos em torno dos pontos (alvos).

Figura 11 – Exemplo das células formadas no Diagrama de Voronoi.



Após formados esses polígonos, os seus vértices são definidos como pontos potenciais de implantação dos nós sensores.

Correção do número de pontos potenciais

Devido à característica de geração de polígonos do Diagrama de Voronoi, o número de posições potenciais gerados será sempre o mesmo caso o número de alvos e suas respectivas posições no plano permaneçam inalterados. No experimento proposto, foram necessárias a realização de testes com 100, 200, 300, 400 e 500 posições potenciais para fins de comparação dos resultados. Para isso, foram gerados de forma aleatória o restante dos pontos necessários, ou seja, se o Diagrama de Voronoi gerar por volta de 150 pon-

tos potenciais e forem necessários 200 pontos para os testes, estes 50 pontos potenciais restantes serão gerados de forma aleatória pelo plano.

Perturbação dos pontos potenciais

Em busca de melhores resultados, foi implementada uma perturbação nos pontos potenciais gerados pelo Diagrama de Voronoi (juntamente com os pontos criados como correção para os testes). Essa perturbação modifica a posição no plano de todos os pontos potenciais existentes, da seguinte forma:

1. É feita uma iteração sobre cada ponto p_i existente;
2. A partir de cada ponto p_i é gerada uma subárea circular, sendo p_i o centro desta subárea, cujo valor do raio é 10;
3. O conjunto de pontos $C = \{c_1, c_2, \dots, c_K\}$ que compõem a subárea deste círculo são sorteados, o ponto c_1 escolhido da subárea substituirá o atual ponto potencial p_i selecionado.

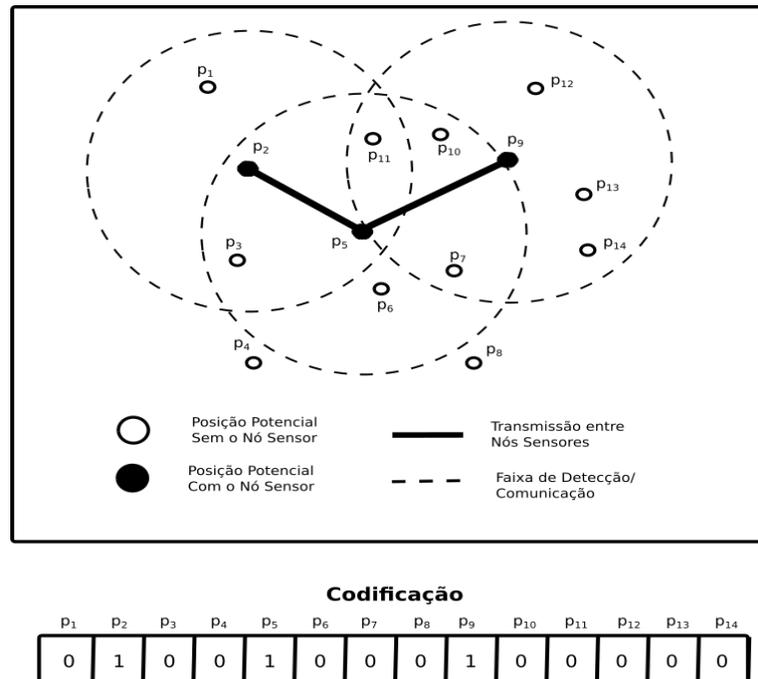
Os resultados desta perturbação são comparados com os resultados dos mesmos pontos potenciais sem a aplicação da perturbação.

5.2 O Algoritmo Genético Utilizado

Representação dos Indivíduos da População

Neste trabalho, os cromossomos (indivíduos) são representados por um vetor de zeros (0) e uns (1). O tamanho de cada cromossomo é exatamente igual ao número de posições potenciais de implantação dos nós sensores. Para cada cromossomo, se o valor do n ésimo gene (n ésima posição) for igual à 1, isso quer dizer que o sensor que representa aquela n ésima posição foi implantado, da mesma forma, o n ésimo gene que possui o valor 0 representa que o n ésimo nó sensor representado por aquele gene não foi implantado.

Figura 12 – Exemplo da codificação dos cromossomos utilizada no projeto.



A Figura 12 mostra exatamente como é feita a representação de cada cromossomo do problema. A sequência de bits abaixo da Figura representa os pontos possíveis de implantação dos nós sensores. Pode-se observar que, os pontos p_2 , p_5 e p_9 estão marcados para implantação, sendo assim, eles são representados pelo valor 1 na sequência de bits. Os demais nós não serão implantados, portanto, estão assinalados com o valor 0.

População Inicial

A população inicial é gerada estocasticamente, produzindo um conjunto de cromossomos em que cada gene do cromossomo é representado binariamente.

Função de Avaliação (*Fitness*)

O valor da avaliação de um cromossomo representa a qualidade do mesmo como solução do problema enfrentado. No trabalho de Gupta, Kuila e Jana (2016), os autores tem como objetivo selecionar o menor número de posições em potencial para implantação de nós sensores, dado um conjunto de tais posições pré-definidas, de tal modo que os alvos devem ser k -cobertos e os nós implantados devam ser m -conectados, para algum valor definido de k e m .

A função de avaliação foi construída baseada nas restrições impostas pelo problema, os parâmetros da função utilizados por Gupta, Kuila e Jana (2016) são definidos a seguir:

1. Escolha/seleção do menor número de potenciais posições de implantação. Assumindo que serão selecionadas M posições em potencial dentre K posições para im-

plantar os nós sensores. Sendo assim, o primeiro objetivo será o seguinte:

$$\text{Objetivo 1: Minimizar } F_1 = \frac{M}{K} \quad (13)$$

A equação (13) representa a razão entre a quantidade de nós selecionados para ser implantados e a quantidade total de nós. A sua grandeza varia de 0 à 1 e demonstra a porcentagem de indivíduos selecionados para implantação, ou seja, quanto menor o valor de F_1 melhor o resultado.

2. k -cobertura dos alvos. Como especificado anteriormente, $Cov(t_i)$ representa o conjunto de nós sensores que estão dentro da faixa de detecção do alvo t_i . O custo de cobertura de um alvo é definido como:

$$CovCost(t_i) = \begin{cases} k, & \text{Se } |Cov(t_i)| \geq k \\ |Cov(t_i)| - k, & \text{Caso Contrário} \end{cases} \quad (14)$$

Por consequência, o segundo objetivo ficou definido como:

$$\text{Objetivo 2: Maximizar } F_2 = \frac{1}{N \times k} \sum_{i=1}^N CovCost(t_i) \quad (15)$$

O valor resultado desta equação irá variar entre 0 e 1.

Observação: Na equação original em Gupta, Kuila e Jana (2016) o custo de cobertura usava a seguinte fórmula:

$$CovCost(t_i) = \begin{cases} k, & \text{Se } |Cov(t_i)| \geq k \\ k - |Cov(t_i)|, & \text{Caso Contrário} \end{cases} \quad (16)$$

Porém, isso causa uma inconsistência caso o valor da $Cov(t_i)$ for igual a 0, fazendo com que alvos não cobertos sejam avaliados inadequadamente, assim, atrapalhando a avaliação correta do indivíduo, o que, conseqüentemente, ocasionará em um resultado final equivocado.

3. m -conectividade dos sensores. A função $Com(s_i)$ representa o conjunto de nós sensores que estão dentro da faixa de comunicação do sensor s_i . O cálculo de custo da conectividade, denotado pela função $ConnCost(s_i)$, é calculado da seguinte maneira:

$$ConnCost(s_i) = \begin{cases} m, & \text{Se } |Com(s_i)| \geq m \\ |Com(s_i)| - m, & \text{Caso Contrário} \end{cases} \quad (17)$$

Por consequência, o terceiro objetivo ficou definido como:

$$\text{Objetivo 3: Maximizar } F_3 = \frac{1}{M \times m} \sum_{i=1}^M \text{ConnCost}(s_i) \quad (18)$$

O valor resultado desta equação irá variar entre 0 e 1.

Observação: Novamente, a equação original em Gupta, Kuila e Jana (2016) o custo de conexão é definido da seguinte maneira:

$$\text{ConnCost}(s_i) = \begin{cases} m, & \text{Se } |\text{Com}(s_i)| \geq m \\ m - |\text{Com}(s_i)|, & \text{Caso Contrário} \end{cases} \quad (19)$$

A mudança foi realizada para evitar avaliações com notas mais altas para alvos que não estejam cumprindo o objetivo de m -conectividade.

Conforme os autores Gupta, Kuila e Jana (2016) afirmam, os objetivos acima descritos são conflitantes. Para garantir a k -cobertura e a m -conectividade se faz necessário selecionar uma maior quantidade de nós sensores, o que acaba dificultando o primeiro objetivo que se encarrega de selecionar o menor número de posições potenciais para implantação. Para contornar esta situação, os autores utilizam uma abordagem conhecida como soma ponderada para construir a função de avaliação. Nesta abordagem, um peso W_i é multiplicado por cada objetivo, em seguida, todos os objetivos multiplicados são então somados para converter os múltiplos objetivos em uma única função objetiva, como pode-se observar a seguir:

$$\text{Fitness} = W_1 \times (1.0 - F_1) + W_2 \times F_2 + W_3 \times F_3 \quad (20)$$

Ou seja,

$$\text{Fitness} = W_1 \times \left(1.0 - \frac{M}{K}\right) + W_2 \times \frac{1}{N \times k} \sum_{i=1}^N \text{CovCost}(t_i) + W_3 \times \frac{1}{M \times m} \sum_{i=1}^M \text{ConnCost}(s_i) \quad (21)$$

Nesta abordagem, a soma de $W_1 + W_2 + W_3 = 1$ e $0 \leq W_i \leq 1, \forall i, 1 \leq i \leq 3$ com o objetivo de maximizar a função de avaliação (*Fitness*).

Assim, quanto maior o valor de *fitness*, melhor será o cromossomo. No método de soma ponderada, é necessário ajustar corretamente os valores dos pesos de W_1, W_2, W_3 . Esse ajuste é, no geral, realizado através de testes, considerando-se que é complicado ajus-

tar corretamente os pesos, mesmo para alguém familiarizado com o domínio do problema.

É importante ressaltar que os 3 objetivos, F_1, F_2, F_3 representam diferentes escalas de valores. Deste modo, é feita uma normalização das faixas de valores dos 3 objetivos para a mesma escala. Nesta função de avaliação, os valores de F_1, F_2 e F_3 são calculados de maneira que a escala de todos os 3 variem entre 0 e 1.

Método de Seleção

No algoritmo proposto foi utilizado o método do torneio para escolher os indivíduos mais aptos da população, ou seja, indivíduos com as melhores pontuações da função de avaliação.

Crossover de Permuta de Sub-área

Neste operador, baseado no Algoritmo Genético Flexível desenvolvido por Zhang et al. (2017), os descendentes são gerados através da troca de áreas parciais de dois pais selecionados. O procedimento necessário para executar esta troca é realizado da seguinte forma:

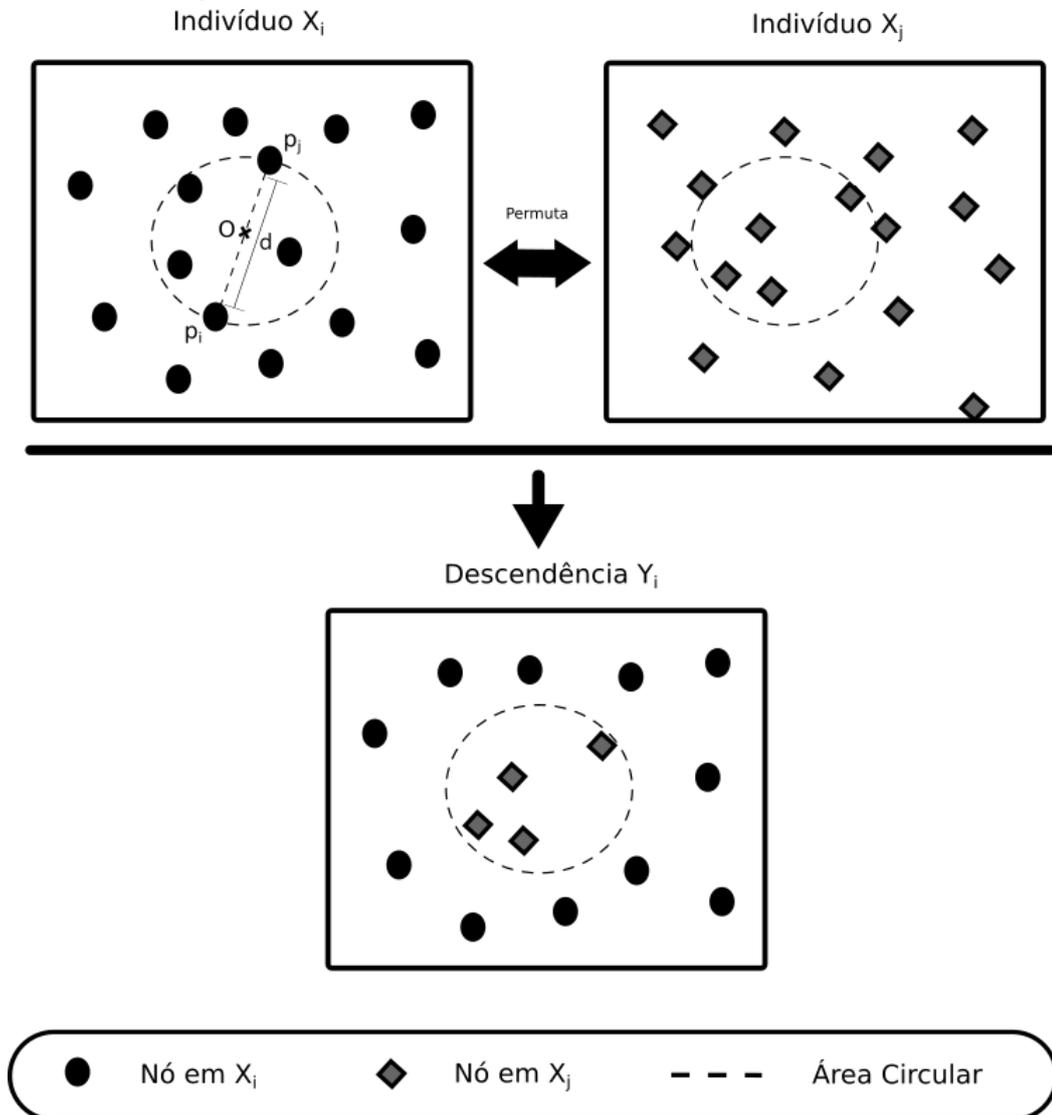
1. Para um indivíduo X_i , gere um número aleatório r entre 0 e 1. Se r for menor que a probabilidade de cruzamento P_c e X_i contém pelo menos dois nós, siga para os passos 2 e 3 para gerar a descendência Y_i . Caso contrário, a descendência Y_i será uma cópia de X_i ;
2. Selecione aleatoriamente outro indivíduo X_j para crossover;
3. Selecione de forma aleatória dois genes de X_i . Calcule o centro O destes 2 genes e a distância d dos mesmos. Desenhe um círculo correspondente com a mesma localização e tamanho em X_j . Troque o conteúdo das sub-áreas X_i e X_j . O *layout* obtido como resultado é armazenado como o novo descendente Y_i .

Este procedimento pode ser ainda formulado como:

$$Y_i = \begin{cases} X_i \otimes X_j & \text{Se } rand_i < P_c \\ X_i & \text{Caso Contrário} \end{cases} \quad (22)$$

Onde $rand_i$ é um número, uniformemente distribuído entre 0 e 1, e o operador \otimes denota a operação realizada no passo 3.

Figura 13 – Crossover de Permuta de Sub-área.



<https://pt.overleaf.com/project/5969236381a6531f6872d213>

A Figura 13 ilustra o procedimento. Os pontos p_i e p_j são os 2 genes selecionados do indivíduo X_i . A partir de então é feito o cálculo do centro O desses 2 genes e também é calculada a distância d entre os mesmos. O círculo é então desenhado tanto no indivíduo X_i quanto no indivíduo X_j , ambos com a mesma localização e tamanho. Por fim, o conteúdo dos 2 círculos (os nós sensores presentes na sub-área) são então trocados.

Mutação

A mutação é o passo seguinte ao *crossover*. Neste operador, os descendentes tem uma probabilidade Pm de sofrerem mutação, sua tarefa principal é ajustar a propriedade dos genes. A mutação é realizada em genes selecionados de cada indivíduo para alterar sua propriedade. As descrições detalhadas da mutação são as seguintes:

Para cada gene em Y_i , é gerado um número real aleatório r entre os valores 0 e 1. Se $r < Pm$, então a perturbação é realizada no gene, trocando o valor para 0.

5.3 Implementação do Algoritmo

Para implementação e execução do algoritmo genético foi utilizada a linguagem python, versão 3.6.4 devido à simplicidade de programação (bibliotecas que facilitam a manipulação de array e matrizes), além do grande arsenal de bibliotecas científicas disponíveis e de fácil utilização, tais como NumPy e SciPy.

Framework Utilizado

Desenvolvido em python, o *framework* Deap (FORTIN et al., 2012), criado para auxiliar no desenvolvimento de aplicações que envolvam programação evolucionária, também é utilizado no projeto para o desenvolvimento do algoritmo genético.

O Deap¹ é desenvolvido pela *Computer Vision and Systems Laboratory* (CVSL) na universidade de Laval, em Quebec, no Canadá. Este *framework* foi planejado para uma rápida prototipação e testes, ele visa o desenvolvimento de algoritmos mais explícitos e tornar mais claras as estruturas de dados utilizados no projeto.

O Deap fornece ainda toda a base necessária comum à um algoritmo genético, como os operadores de seleção, o *crossover* e a mutação, bem como a tipagem do indivíduo, a inicialização da população inicial e a definição de atributos dos operadores genéticos, deixando assim, à cargo do programador apenas a função principal dos AGs, ou seja, a função de avaliação.

Outro ponto positivo do Deap, é que o mesmo não exclui a possibilidade do usuário escrever seus próprios operadores genéticos personalizados para o problema abordado.

5.4 Comparação dos Resultados

Após concluídas as alterações do algoritmo, foram feitas comparações entre o algoritmo apresentado por Gupta, Kuila e Jana (2016) e o algoritmo modificado deste trabalho.

A comparação foi realizada através de tabelas e gráficos mostrando a relação entre a quantidade de nós sensores implantados e a quantidade de possíveis pontos de posicionamento de nós sensores, bem como a relação entre as quantidades das restrições de k -cobertura e m -conectividade com a quantidade de pontos implantados. Os dados obtidos e a discussão dos resultados acontecem no Capítulo 6 deste trabalho.

¹Pode ser encontrado em: <<https://github.com/deap/deap>>.

6 RESULTADOS E DISCUSSÕES

Realizou-se vários testes a partir da implementação do algoritmo projetado. Nesses testes, o algoritmo é executado, tendo como objetivo suprir as restrições de k - cobertura e m - conectividade, sendo que $k \in \{1, 2, 3\}$ e também $m \in \{1, 2, 3\}$. Cada uma dessas variações são aplicadas em 100 alvos, previamente estabelecidos, e com diferentes quantidades de posições potenciais dos nós sensores, sendo estas quantidades testadas 100, 200, 300, 400 e 500. As posições potenciais são espalhadas de acordo com o proposto na metodologia, ou seja, primeiro foi concebido o Diagrama de Voronoi dos alvos, caso a quantidade de pontos gerados não chegasse às quantidades desejadas para o teste, o algoritmo geraria adicionalmente novos pontos aleatoriamente espalhados pelo plano.

Como a função *fitness* é multi-objetivo, foi necessário a realização de alguns testes para identificar quais seriam os melhores valores para os pesos w_1 , w_2 e w_3 dos objetivos de redução do número de nós sensores implantados, verificação da restrição de k - cobertura dos alvos e verificação de m - conectividade dos nós sensores, respectivamente. Os valores dos pesos e o resultado do comportamento de cada um dos objetivos podem ser visualizados na Tabela 1 a seguir:

Tabela 1 – Relação dos valores dos pesos testados e o comportamento dos objetivos em porcentagem

Valor dos Pesos			Objetivos em %		
w1	w2	w3	F1	F2	F3
0,1	0,8	0,1	29	100	100
0,1	0,7	0,2	28	100	100
0,1	0,6	0,3	26	100	100
0,1	0,5	0,4	25	99	100
0,1	0,45	0,45	25	98	100
0,2	0,4	0,4	25	99	100
0,3	0,35	0,35	20	92	100
0,4	0,3	0,3	22	93	100
0,5	0,25	0,25	18	85	100
0,6	0,2	0,2	17	83	100
0,7	0,15	0,15	16	72	100
0,8	0,1	0,1	13	54	100

De acordo com os resultados apresentados na Tabela 1, os melhores valores encontrados nestes testes para os pesos são $w_1 = 0,1$, $w_2 = 0,8$ e $w_3 = 0,1$. Esses pesos

têm como objetivo garantir que a rede mantenha a k - cobertura e a m - conectividade enquanto, ao mesmo tempo, tenta diminuir o número de nós sensores selecionados.

Após definidos os valores dos pesos a serem utilizados na função multi-objetivo, deu-se início à fase de execução do algoritmo genético.

Para obter uma melhor análise dos resultados, são realizadas 30 execuções sobre o número de posições potenciais (100, 200, ..., 500) aplicando cada uma das restrições de k e m sobre este número de sensores. Ou seja, para 100 posições potenciais são feitos testes com as restrições $k \in \{1, 2, 3\}$ e $m \in \{1, 2, 3\}$, onde cada uma destas restrições são executadas 30 vezes. O mesmo procedimento é realizado para 200, 300, 400 e 500 posições potenciais.

Ao fim de cada uma das 30 execuções, são armazenadas as informações da execução, tais como o melhor indivíduo da população, a variância dos resultados do número de sensores implantados desde a população inicial até o término da evolução e o número de sensores implantados do melhor indivíduo.

Os valores de variância, conforme são apresentados pela Tabela 2, demonstram uma variação baixa e uniforme, ou seja, os valores estão sempre muito próximos à média, fazendo com que os resultados tendam à um mesmo valor. Isso garante uma qualidade nos dados alcançados pelas avaliações, pois, apesar das numerosas repetições dos testes, estes acabam convergindo para a mesma faixa de valores.

Tabela 2 – Valores de variância das execuções

		Nº de Posições Potencias				
		100	200	300	400	500
Restrições de k - cobertura e m - conectividade	(1, 1)	1.915	1.112	1.426	1.462	0.512
	(1, 2)	2.138	1.912	0.765	1.472	1.973
	(1, 3)	1.195	2.239	1.472	2.582	1.488
	(2, 1)	1.662	1.693	2.312	1.395	1.445
	(2, 2)	2.276	1.809	1.848	1.848	3.356
	(2, 3)	2.912	1.245	1.912	1.982	1.938
	(3, 1)	3.712	3.178	1.765	3.832	2.245
	(3, 2)	2.333	2.383	3.595	3.338	1.645
	(3, 3)	1.839	1.516	2.528	2.476	2.672

Também são gerados dois gráficos, o gráfico da Figura 14 representa a variância do grau de precisão da função de avaliação (*fitness*) durante a evolução, enquanto a Figura 15 representa o melhor indivíduo implantado ao final da evolução.

Figura 14 – Variância do grau de precisão da função de avaliação (*fitness*) durante a evolução (com restrições de $k = 1$ e $m = 1$).

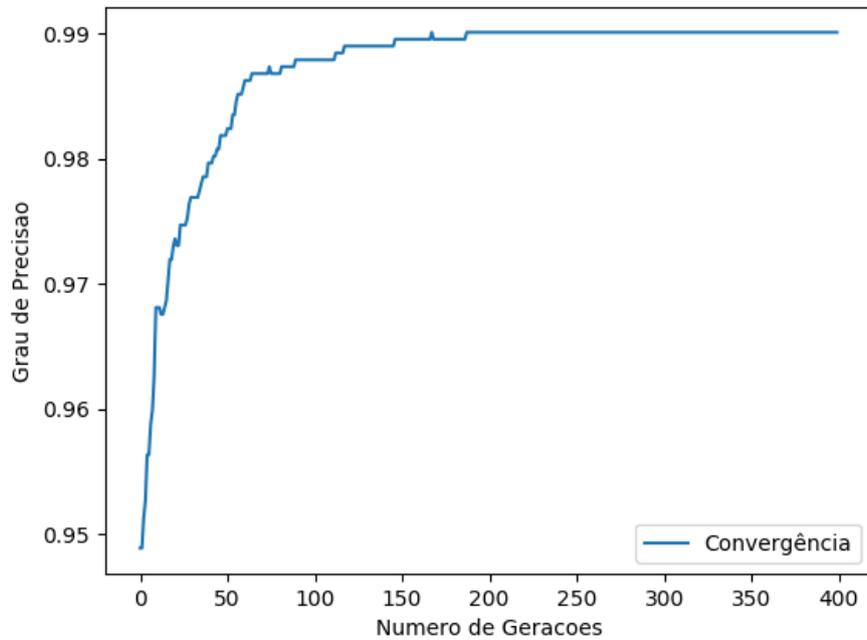
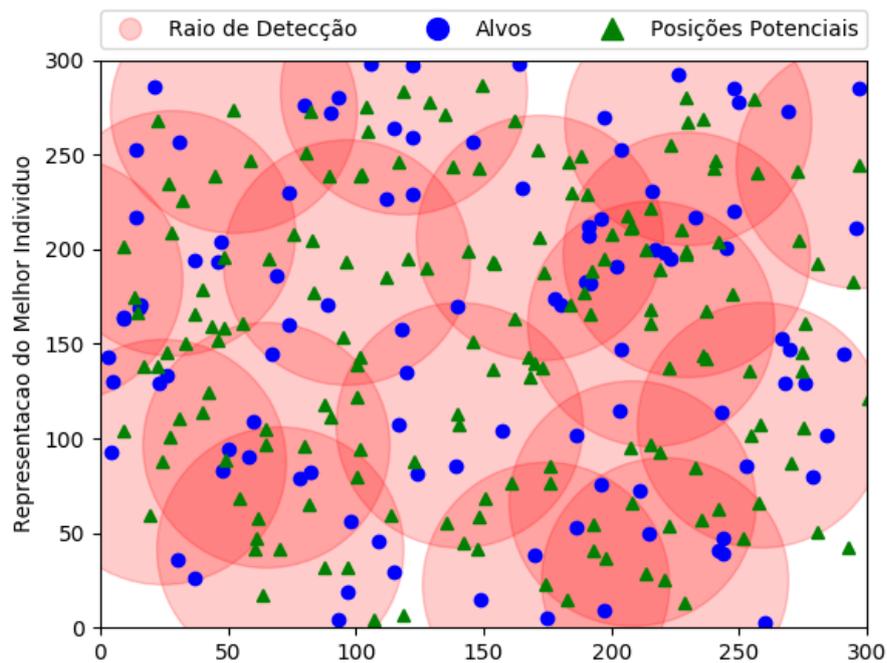


Figura 15 – Melhor indivíduo encontrado ao final da evolução (com valores de $k = 1$ e $m = 1$).

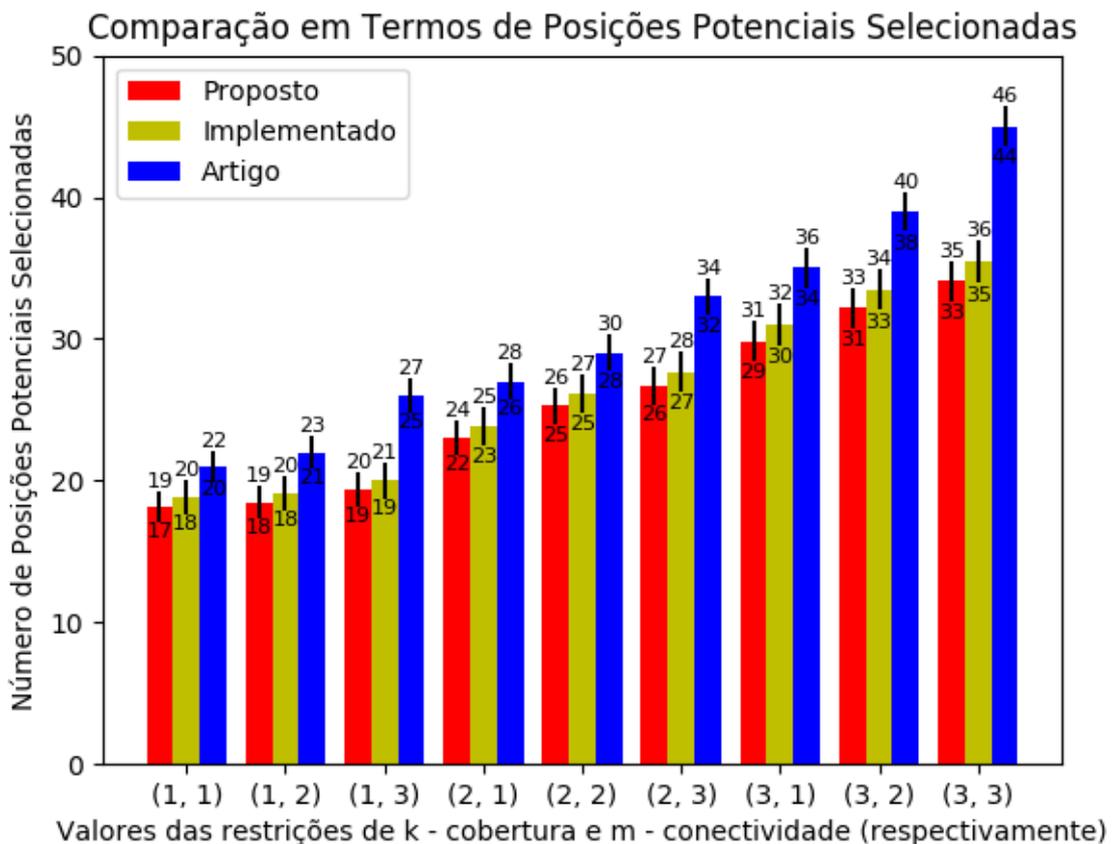


Ao término de cada uma das 30 execuções, é feita e armazenada a média do nú-

mero de posições potenciais implantadas de todos os 30 melhores indivíduos, a média da variância das 30 execuções e o melhor indivíduo encontrado de todas as execuções. Todos estes resultados são armazenados para avaliações posteriores.

De modo geral o algoritmo proposto obteve melhores resultados quando comparados aos apresentados por Gupta, Kuila e Jana (2016). A Figura 16 a seguir faz uma comparação da média dos resultados do número de nós sensores implantados. Essa relação é confrontada entre o algoritmo proposto neste trabalho, o algoritmo de Gupta, Kuila e Jana (2016) - uma implementação reproduzindo o algoritmo sem modificações - e, os resultados originais apresentados por Gupta, Kuila e Jana (2016) em seu artigo.

Figura 16 – Comparação da média dos resultados do número de nós sensores selecionados.



É notável, pela Figura 16, que há uma melhora nos resultados após as modificações propostas por este trabalho.

Observando a Figura 16, pode-se notar que nos resultados apresentados por Gupta, Kuila e Jana (2016) (em azul) destaca-se uma quantidade consideravelmente maior de nós sensores selecionados para implantação do que o resultado do mesmo algoritmo, reproduzido para este trabalho (em amarelo). Fazendo uma observação mais minuciosa, com relação aos valores do erro padrão (que podem variar para mais ou para menos) de cada

uma das restrições executadas, pode-se notar que, mesmo no pior caso, dentre todos os casos testados, o algoritmo proposto obtém um melhor resultado do que o algoritmo proposto por Gupta, Kuila e Jana (2016).

A lógica por trás deste melhor desempenho se deve ao pré-processamento das posições potenciais dos nós sensores, onde tais posições são realocadas de modo à facilitar a cobertura e conectividade desejadas. Vale salientar também que, mesmo o algoritmo sem as modificações, isto é, seguindo diretamente a modelagem feita por Gupta, Kuila e Jana (2016), obteve uma grande melhora nos resultados das execuções, se tratando do número de nós sensores selecionados.

7 CONCLUSÃO

Neste trabalho, foi proposto um Algoritmo Genético para encontrar o menor número de posições para implantação de nós sensores numa rede de sensores sem fio utilizando a cobertura de pontos (alvos), satisfazendo a k - cobertura e a m - conectividade dos nós sensores.

Primeiramente foi apresentada a formulação matemática do problema em questão. Em seguida, foi apresentado o algoritmo genético proposto com a representação cromossômica adequada, construção da função *fitness* apropriada, seleção, *crossover* baseado no Algoritmo Genético Flexível desenvolvido por Zhang et al. (2017) e operações de mutação. Por fim, foram salientadas as funções de realocação das posições potenciais dos nós sensores, equivalentes ao Diagrama de Voronoi e a função de perturbação dos pontos.

O Algoritmo Genético foi executado numerosas vezes, variando o número de posições potenciais e os valores das restrições k e m . Os resultados das execuções são comparados com o trabalho apresentado por Gupta, Kuila e Jana (2016). Tais resultados mostram que este esquema apresentou uma melhora em comparação com o algoritmo desenvolvido por Gupta, Kuila e Jana (2016), em termos de número de posições potenciais selecionadas.

O trabalho proposto tem uma ampla gama de aplicações em grandes indústrias, por exemplo, para monitorar rigorosamente alguns pontos-alvo, como possíveis zonas de incêndio, vazamentos de gás, etc.. No entanto, o algoritmo não abordou a questão da eficiência energética ao selecionar as posições potenciais. Como trabalho futuro, propõe-se desenvolver algum novo algoritmo que complemente o que foi desenvolvido até o momento e levando em consideração a economia de energia.

REFERÊNCIAS

- AHMED, M. R. et al. Wireless sensor network: characteristics and architectures. **International Journal of Electrical, Computer, Energetic, Electronic and Communication Engineering**, p. 4, 2012.
- AKYILDIZ, I.; SU, Y. S. W.; CAYIRCI, E. Wireless sensor networks: a survey. **Elsevier Science B.V.**, p. 30, 2002.
- FAN, G.; JIN, S. Coverage problem in wireless sensor network: A survey. **JOURNAL OF NETWORKS**, p. 8, 2010.
- FORTIN, F.-A. et al. DEAP: Evolutionary algorithms made easy. **Journal of Machine Learning Research**, v. 13, p. 2171–2175, jul 2012.
- GUPTA, N.; KUMAR, N.; JAIN, S. Coverage problem in wireless sensor networks: a survey. **International conference on Signal Processing, Communication, Power and Embedded System (SCOPE5)**, p. 8, 2016.
- GUPTA, S. K.; KUILA, P.; JANA, P. K. Genetic algorithm approach for k-coverage and m-connected node placement in target based wireless sensor networks. **Computers and Electrical Engineering**, p. 14, 2016.
- HOLLAND, J. H. Genetic algorithms. **Scientific american**, JSTOR, v. 267, n. 1, p. 66–73, 1992.
- JIAN, X. et al. Improved discrete particle swarm optimization for solving the practical sensors deployment. **Evolving Systems**, p. 14, 2017.
- JUNBIN, L.; MING, L.; XIAOYAN, K. A survey of coverage problems in wireless sensor networks. **Sensors and Transducers**, p. 7, 2014.
- KE, W.-C.; LIU, B.-H.; TSAI, M.-J. Constructing a wireless sensor network to fully cover critical grids by deploying minimum sensors on grid points is np-complete. **IEEE Transactions On Computers**, p. 6, 2007.
- KENNEDY, J.; EBERHART, R. C. **Swarm Intelligence**. Primeira. [S.l.]: Academic Press, 2001.
- KO, R.-S. The complexity of the minimum sensor cover problem with unit-disk sensing regions over a connected monitored region. **International Journal of Distributed Sensor Networks**, p. 25, 2011.
- KOZA, J. R. Survey of genetic algorithms and genetic programming. **IEEE**, p. 6, 1995.
- LACERDA, E. G. de; CARVALHO, A. de. Introdução aos algoritmos genéticos. **Sistemas inteligentes: aplicações a recursos hídricos e ciências ambientais**, v. 1, p. 99–148, 1999.

- LEWIS, F. L. Wireless sensor networks. **Smart Environments: Technologies, Protocols, and Applications**, p. 18, 2004.
- LINDEN, R. **Algoritmos Genéticos: Uma ferramenta importante da Inteligência Computacional**. Primeira. [S.l.]: Brasport, 2006.
- MANSHAHIA, M. S. Wireless sensor networks: A survey. **International Journal of Scientific & Engineering Research**, p. 7, 2016.
- MELO, S. N. de; FRANK, R.; BRANTINGHAM, P. Voronoi diagrams and spatial analysis of crime. **The Professional Geographer**, p. 13, 2017.
- POZOA, A. et al. **Computação Evolutiva**. 2018. Universidade Federal do Paraná.
- RASHID, B.; REHMANI, M. H. Applications of wireless sensor networks for urban areas: A survey. **Elsevier LTD**, p. 28, 2015.
- SANGWAN, A.; SINGH, R. P. Survey on coverage problems in wireless sensor networks. **Wireless Personal Communications**, Springer, v. 80, n. 4, p. 1475–1500, 2015.
- TOMASSINI, M. A survey of genetic algorithms. **Annual reviews of computational physics III**, 1995.
- YU, J. et al. On connected target k-coverage in heterogeneous wireless sensor networks. **Applied Soft Computing**, p. 21, 2016.
- ZHANG, Y.-H. et al. Flexible genetic algorithm: A simple and generic approach to node placement problems. **Evolving Systems**, p. 11, 2017.
- ZHOU, Z. et al. A study on the coverage problem in wireless sensor networks. **2006 IET International Conference on Wireless, Mobile and Multimedia Networks**, p. 3, 2006.
- ZHU, C. et al. A survey on coverage and connectivity issues in wireless sensor networks. **Journal of Network and Computer Applications**, Elsevier, v. 35, n. 2, p. 619–632, 2012.